KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

RADYO FREKANSI SİNYALLERİ İLE İNSANSIZ HAVA ARAÇLARININ MAKİNE ÖĞRENMESİ TEMELLİ TESPİT EDİLMESİ

EMEL OKKALI

KOCAELİ 2024

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

RADYO FREKANSI SİNYALLERİ İLE İNSANSIZ HAVA ARAÇLARININ MAKİNE ÖĞRENMESİ TEMELLİ TESPİT EDİLMESİ

EMEL OKKALI

Prof. Dr. Kerem KÜÇÜK **Danışman, Kocaeli Üniversitesi**	**.....**
Doç. Dr. Süleyman EKEN **Jüri Üyesi, Kocaeli Üniversitesi**	**.....**
Doç. Dr. Adem TUNCER **Jüri Üyesi, Yalova Üniversitesi**	**.....**

Tezin Savunulduğu Tarih: 17.09.2024

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında,

- Bu tezin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,

beyan ederim.

☒ Bu tez çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☐ Bu tez çalışması kapsamında üretilen veri ve bilgiler ..... tarafından ..... no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....

Emel OKKALI

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki makale, kitap, tebliğ, lisans, patent gibi çalışmalarda kullanımı, danışmanımın isim hakkı saklı kalmak koşuluyla ve her iki tarafın bilgisi dâhilinde bana ait olacaktır.

Tezin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan ***"Lisanüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge"*** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

☐ Enstitü yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.

☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.

☒ Tezim ile ilgili gizlilik kararı verilmemiştir.

.....

Emel OKKALI

ÖNSÖZ VE TEŞEKKÜR

İnsansız Hava Araçları (İHA) olarak bilinen drone'lar, teknolojideki hızlı ilerlemelerle birlikte son yıllarda önemli bir dönüşüm geçirmiştir. Askeri alandaki kullanımları ile başlayan süreç; ticari, tarımsal, insani yardım ve araştırma alanlarına kadar geniş bir yelpazeye yayılmıştır.
Bu teknolojik ilerlemeler, drone'ların sahip olduğu yeteneklerin artmasına ve operasyonel açıdan daha etkin bir şekilde kullanılabilmesine olanak tanımaktadır.

Makine öğrenmesi teknolojileri, günümüzde birçok alanda etkin bir şekilde kullanılmaktadır. Bu teknolojiler, özellikle güvenlik ve izleme sistemleri gibi kritik uygulamalarda geleneksel yöntemlere kıyasla daha etkili ve yenilikçi çözümler sunma potansiyeline sahiptir. İnsansız hava araçlarının gelişiminde de makine öğrenmesi önemli bir rol oynamaktadır. Drone'lar, tarımdan güvenliğe, araştırmadan arama kurtarma operasyonlarına kadar geniş bir yelpazede fayda sağlamaktadır. Ancak, drone teknolojisinin sunduğu avantajların yanı sıra gizlilik, güvenlik ve emniyet konularında ortaya çıkan endişeler, bu teknolojilerin kullanımını karmaşık hale getirmektedir.

Bu çalışma, insansız hava araçlarının geniş kullanım alanlarına ek olarak, güvenlik ve gizlilik ile ilgili endişeleri ele almakta ve bu endişeleri giderecek modern makine öğrenimi teknolojilerini incelemektedir. Drone'ların RF sinyalleri üzerinden tespit edilmesi ve tanımlanması amacıyla yapılan bu araştırma, bu teknolojilerin daha etkin bir şekilde nasıl kullanılabileceğini göstermektedir.

Bu süreçte varlığı ile bana güç veren en büyük destekçim biricik kızım Fatma Vera OKKALI'ya teşekkür ederim. Özellikle Tez danışmanım Prof. Dr. Kerem KÜÇÜK'e rehberliği, sabrı ve desteği için çok minnettarım.

Eylül – 2024 Emel OKKALI

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI ii
ÖNSÖZ VE TEŞEKKÜR iii
İÇİNDEKİLER iv
ŞEKİLLER DİZİNİ vi
TABLOLAR DİZİNİ vii
SİMGELER VE KISALTMALAR DİZİNİ viii
ÖZET ix
ABSTRACT x
1. GİRİŞ 1
2. LİTERATÜR ÖZETİ 4
3. KULLANILAN MATERYALLER 8
3.1. İnsansız Hava Araçları 8
3.1.1. İnsansız Hava Araçlarının Tanımı ve Yapısı 8
3.1.2. İnsansız Hava Araçlarının Çeşitleri 10
3.1.3. İnsansız Hava Araçlarının Kullanım Alanları 10
3.1.4. İnsansız Hava Araçlarının Kullanım Riskleri 12
3.2. Makine Öğrenmesi 13
3.2.1. Makine Öğrenmesinin Tanımı ve Önemi 13
3.2.2. Makine Öğrenmesinin Tarihçesi ve Gelişimi 14
3.2.3. Makine Öğrenmesinin Temel Kavramları 15
3.2.3.1. Veri ve Veri Seti 15
3.2.3.2. Etiketsiz ve Etiketli Veri 16
3.2.3.3. Özellik Mühendisliği 16
3.2.3.4. Model ve Algoritma 16
3.2.4. Makine Öğrenmesi Türleri 17
3.2.4.1. Gözetimli Öğrenme (Supervised Learning) 17
3.2.4.2. Gözetimsiz Öğrenme (Supervised Learning) 18
3.2.4.3. Pekiştirmeli Öğrenme (Reinforcement Learning) 19
3.2.5. Makine Öğrenmesinin Uygulama Alanları 19
3.2.6. Makine Öğrenmesinin İnsansız Araçlarında Kullanımı 21
3.3. Radyo Frekans Sinyalleri 22
4. KULLANILAN VERİ SETİ ALGORİTMALAR VE YÖNTEMLER 25
4.1. Veri Seti 25
4.2. Makine Öğrenmesi Algoritmaları 28
4.2.1. K-En Yakın Komşu (K-Neighbors Classifier - KNN) 29
4.2.2. Rastgele Orman (Random Forest Classifier - RF) 31
4.2.3. Karar Ağacı (Decision Tree Classifier - CART) 33
4.2.4. Topluluk Öğrenmesi (Ensemble Model) 34
4.3. Kullanılan Yöntemler 36
5. TEST SONUÇLARI VE BULGULAR 40
5.1. Drone Algılama 42
5.2. Drone Tanımlama 46
5.3. Drone Modu Tanımlama 50
6. SONUÇ VE ÖNERİLER 57
KAYNAKLAR 60

KİŞİSEL YAYIN VE ESERLER.....64
ÖZGEÇMİŞ.....65

ŞEKİLLER DİZİNİ

Şekil 3.1. Makine öğrenmesi türleri 17
Şekil 3.2. Gözetimli öğrenme 18
Şekil 3.3. Gözetimsiz öğrenme 18
Şekil 3.4. Pekiştirmeli öğrenme 19
Şekil 4.1. K-En Yakın Komşu algoritmasının sınıflandırılması 30
Şekil 4.2. Rastgele orman algoritmasının sınıflandırılması 32
Şekil 4.3. Karar Ağacı algoritmasının sınıflandırılması 33
Şekil 4.4. Ensemble model çalışma yapısı 35
Şekil 4.5. Drone algılama tanımlama ve uçuş modu belirleme akış diyagramı 36
Şekil 5.1. Tüm algoritmaların drone algılama sonuçları 44
Şekil 5.2. Drone algılama RF, CART ve KNN ROC eğrisi 45
Şekil 5.3. Drone algılama Ensemble model ROC eğrisi 45
Şekil 5.4. Tüm algoritmaların drone tanımlama sonuçları 48
Şekil 5.5. Drone tanımlama RF, CART ve KNN ROC eğrisi 48
Şekil 5.6. Drone tanımlama ensemble model ROC eğrisi 49
Şekil 5.7. Tüm algoritmaların drone modu tanımlama sonuçları 54
Şekil 5.8. Drone modu tanımlama RF, CART ve KNN ROC eğrisi 55
Şekil 5.9. Drone modu tanımlama Ensemble model ROC eğrisi 56

TABLOLAR DİZİNİ

Tablo 4.1. Drone RF veri tabanının her drone tipi için ham örneklerinin ve segmentlerinin sayısı 26
Tablo 4.2. Drone RF veri tabanının her drone tipi için uçuş modu, örnek sayısı ve oran bilgileri 27
Tablo 4.3. Ön test sonuçları 28
Tablo 5.1. Tüm algoritmaların drone algılama metrik değerleri 41
Tablo 5.2. Tüm algoritmaların drone tanımlama metrik değerleri 41
Tablo 5.3. Tüm algoritmaların drone modu tanımlama metrik değerleri 41
Tablo 5.4. İki sınıflı KNN algoritması katışıklık matris tablosu 42
Tablo 5.5. İki sınıflı RF algoritması katışıklık matris tablosu 42
Tablo 5.6. İki sınıflı CART algoritması katışıklık matris tablosu 43
Tablo 5.7. İki sınıflı Ensemble model katışıklık matris tablosu 43
Tablo 5.8. Dört sınıflı KNN algoritması katışıklık matris tablosu 46
Tablo 5.9. Dört sınıflı RF algoritması katışıklık matris tablosu 46
Tablo 5.10. Dört sınıflı CART algoritması katışıklık matris tablosu 47
Tablo 5.11. Dört sınıflı Ensemble model katışıklık matris tablosu 47
Tablo 5.12. On sınıflı KNN algoritması katışıklık matris tablosu (%) 51
Tablo 5.13. On sınıflı RF algoritması katışıklık matris tablosu (%) 51
Tablo 5.14. On sınıflı CART algoritması katışıklık matris tablosu (%) 52
Tablo 5.15. On sınıflı Ensemble model katışıklık matris tablosu(%) 53
Tablo 6.1. Tüm modellerin karşılaştırılması 58

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

AI	:	Artificial Intelligence (Yapay Zekâ)
AM	:	Amplitude Modulation (Genlik Modülasyonu)
CNN	:	Convolutional Neural Network (Evrişimsel Sinir Ağı)
FM	:	Frequency Modulation (Frekans Modülasyonu)
IHA	:	İnsansız Hava Aracı
KNN	:	K-Nearest Neighbors (K- En Yakın Komşu)
RF	:	Radio Frequency (Radyo Frekansı)
SVM	:	Support Vector Machines (Destek Vektör Makineleri)
UAV	:	Unmanned Aerial Vehicle (İnsansız Hava Aracı)

RADYO FREKANSI SİNYALLERİ İLE İNSANSIZ HAVA ARAÇLARININ MAKİNE ÖĞRENMESİ TEMELLİ TESPİT EDİLMESİ

ÖZET

Makine öğrenmesi teknolojileri, günümüzde birçok alanda etkin bir şekilde kullanılmaktadır. Özellikle güvenlik ve izleme sistemleri gibi kritik uygulamalarda, geleneksel metotlara göre daha etkili ve yenilikçi çözümler sunma potansiyeline sahiptirler.

İnsansız hava araçlarının gelişiminde de makine öğrenmesi etkin bir şekilde kullanılabilmektedir. İHA'lar (drone'lar) tarımdan güvenliğe, araştırmadan arama kurtarma operasyonlarına kadar geniş bir alanda fayda sağlamaktadır. Ancak drone teknolojisinin sunduğu avantajların yanı sıra gizlilik, güvenlik ve emniyet konularında ortaya çıkan endişeler, bu teknolojilerin kullanımını karmaşıklaştırmaktadır.

Bu çalışma, insansız hava araçlarının geniş kullanım alanları yanında güvenlik ve gizlilik ile ilgili endişeleri ele almakta, bu endişeleri ortadan kaldıracak olan modern makine öğrenimi teknolojisini incelemektedir. Drone'ların RF sinyalleri üzerinden tespit edilmesi ve tanımlanması amacıyla geliştirilen araştırma, bu teknolojilerin nasıl daha etkin kullanılabileceğini göstermektedir.

Araştırma kapsamında, İnsansız hava aracı olan farklı modellerdeki drone'lardan toplanan RF sinyallerini içeren bir veri seti kullanılmıştır. Veri toplama süreci, çeşitli model ve markalardaki Drone'ların operasyonları boyunca gerçekleştirilmiş olup elde edilen veriler yeni tespit ve tanımlama yöntemlerinin geliştirilmesi amacıyla araştırmacılara sunulmuştur.

Radyo frekans sinyallerinin analizi için K- en yakın komşu, rastgele orman, karar ağacı ve Ensemble model gibi makine öğrenimi algoritmaları kullanılarak Drone tanımlama başarısı değerlendirilmiştir. Bu algoritmaların sonuçları, modelin performansını ve güvenilirliğini ölçmekte temel teşkil etmektedir.

Çalışma makine öğrenimi modellerinin, farklı drone tiplerini ve operasyonel modlarını etkili bir şekilde tespit edebileceğini göstermiştir. Özellikle Ensemble model, çeşitli algoritmaların güçlü yönlerini birleştirerek, karmaşık görevlerde güçlü bir performans sergilemiştir. Çalışma, makine öğrenmesi ve derin öğrenme yöntemlerinin güçlü ve zayıf yönlerini ortaya koyarak, drone tespiti ve tanımlaması için en uygun yöntemin seçilmesinde rehberlik sunmayı amaçlamaktadır. Drone teknolojilerinin hızla geliştiği ve geniş bir uygulama alanı bulduğu göz önüne alındığında bu tür çalışmaların güvenlik, izleme ve navigasyon gibi alanlarda önemli katkılar sağlayacağı öngörülmektedir.

Anahtar Kelimeler: Drone, Drone Tespiti, İnsansız Hava Araçları, Makine Öğrenmesi, Radyo Frekans Sinyalleri.

MACHINE LEARNING-BASED DETECTION OF UNMANNED AERIAL VEHICLES WITH RADIO FREQUENCY SIGNALS

ABSTRACT

Machine learning technologies are effectively utilized in many fields today. They have the potential to provide more effective and innovative solutions compared to traditional methods, especially in critical applications such as security and surveillance systems.

Machine learning can also be effectively employed in the development of unmanned aerial vehicles (UAVs). Drones offer benefits in a wide range of areas, from agriculture to security, research to search and rescue operations. However, alongside the advantages provided by drone technology, concerns regarding privacy, security, and safety complicate the use of these technologies.

This study addresses the wide range of applications of unmanned aerial vehicles while also examining the concerns related to security and privacy. It explores modern machine learning technology that aims to mitigate these concerns. The research demonstrates how these technologies can be used more effectively by developing a system for detecting and identifying drones through RF signals.

A dataset containing RF signals collected from different models of drones was used within the scope of this study. The data collection process was carried out during the operations of various drone models and brands, and the obtained data was made available to researchers for developing new detection and identification methods.

To analyze radio frequency signals, machine learning algorithms such as K-nearest neighbor, random forest, decision tree, and ensemble models were used to evaluate the success of drone identification. The results of these algorithms form the basis for measuring the model's performance and reliability.

The study demonstrated that machine learning models can effectively detect different drone types and their operational modes. The ensemble model, in particular, showed strong performance in complex tasks by combining the strengths of various algorithms. The study aims to guide the selection of the most suitable method for drone detection and identification by revealing the strengths and weaknesses of machine learning and deep learning methods. Considering the rapid development of drone technologies and their broad range of applications, it is anticipated that such studies will provide significant contributions in areas such as security, surveillance, and navigation.

Keywords: Drone, Drone Detection, Unmanned Aerial Vehicles, Machine Learning, Radio Frequency Signals.

1. GİRİŞ

Son yıllarda, insansız hava araçları, çeşitli uygulama alanları ve yüksek teknolojik kapasiteleriyle dikkat çekmektedir. Güvenlikten tarıma, araştırmadan kurtarma operasyonlarına kadar geniş bir yelpazede kullanılan İHA'lar, bu alanlarda önemli katkılar sunmaktadır (Kim ve diğ., 2019). Ancak, bu ilerlemeler aynı zamanda güvenlik, gizlilik ve emniyet gibi kritik konularda yeni zorlukları da beraberinde getirmektedir (Lin ve diğ., 2019). İHA'ların kullanımı arttıkça, bu sistemlerin izinsiz veya kötü niyetli kullanımlarının önlenmesi, verilerin korunması ve operasyonel güvenliğin sağlanması daha fazla önem kazanmaktadır (Gupta ve diğ., 2021). İHA'ları tespit etme yöntemleri arttırılabilirse kötü kullanımların önüne geçilebilir (Toorchi ve diğ., 2021).

Bu çalışma, İnsansız hava aracı olan drone'ların radyo frekans (RF) sinyalleri üzerinden tespit edilmesi ve tanımlanması üzerine odaklanmaktadır. RF sinyalleri, Drone'ların kontrol sistemleri ve iletişim ağları tarafından sürekli olarak yayılmakta olup, bu sinyallerin analizi, drone'un doğru bir şekilde tespit edilmesi ve kimliklerinin belirlenmesi için kritik öneme sahiptir (Nguyen ve diğ., 2016).

Drone algılama ve tanımlama, gerçek zamanlı olarak hızlı ve doğru sonuçlar üretmeyi gerektiren bir problem haline gelmiştir. Bu problemin çözümünde sınıflandırma yaklaşımı yaygın olarak kullanılmaktadır. Literatürde; Karar Ağaçları (Decison Tree), K-En Yakın Komşu (K-Nearest Neighbors), Destekçi Vektör Makineleri (Support Vector Machine - SVM) (Ezuma ve diğ., 2019), Naive Bayes (NB) Sınıflandırıcı (El Alami ve diğ., 2023), Lojistik Regresyon (Logistic Regression-LR), Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) (Seo ve diğ., 2018) ve Derin Sinir Ağı (Deep Neural Network - DNN) (Tejera-Berengue ve diğ., 2024) algoritmalarının ve modellerinin kullanıldığı çalışmalar yer almaktadır.

Bu tez, farklı makine öğrenimi yaklaşımlarını kullanarak drone'ların tespit ve tanımlanmasında etkinliği artırmayı hedeflemektedir. Çalışmada kullanılan algoritmaların performansları hem genel doğruluk oranları hem de karmaşık görevlerdeki etkinlikleri açısından değerlendirilmiştir. Bu kapsamda, KNN, RF, CART gibi yaygın olarak kullanılan algoritmaların yanı sıra, Ensemble modelde kullanılmıştır.

Çalışma kapsamında elde edilen bulgular, derin öğrenme yöntemleriyle yapılan çalışmalarla karşılaştırılmış ve makine öğrenmesi yaklaşımlarının derin öğrenme yaklaşımlarına çok yakın sonuçlar elde ettiği, hatta bazı durumlarda daha iyi performans gösterdiği görülmüştür. Bu nedenle, makine öğrenmesi yaklaşımları, derin öğrenme modellerine göre daha düşük maliyetle ve daha hızlı sonuçlar üretebildiği için drone algılama ve tanımlama süreçlerinde tercih edilebileceği belirlenmiştir.

Sonuç olarak, bu çalışma, drone tespiti ve tanımlaması için en uygun algoritmaların belirlenmesi hususunda değerli bir yol gösterici niteliği taşımaktadır.

Tezin çalışmasının organizasyonu şu şekildedir: Literatür Özeti kısmında, mevcut drone tespiti ve tanımlama yöntemleri üzerine yapılan çalışmalar ele alınmıştır.

Kullanılan Materyaller bölümü, insansız hava araçları, makine öğrenmesi ve Radyo Frekans sinyalleri gibi temel bileşenlerin detaylı bir incelemesini içermektedir. Bu bölümde, insansız hava araçlarının tanımı, yapısı, çeşitleri, kullanım alanları ve bu araçların kullanımıyla ilgili riskler ele alınmaktadır. Ayrıca, makine öğrenmesinin tanımı, tarihçesi, temel kavramları ve türleri gibi önemli konular ayrıntılı bir şekilde açıklanmıştır. Makine öğrenmesi bölümünde, özellikle gözetimli, gözetimsiz ve pekiştirmeli öğrenme türlerine vurgu yapılmış, bu tekniklerin insansız hava araçlarına nasıl entegre edildiği tartışılmıştır. Son olarak, Radyo Frekans Sinyalleri başlığı altında, bu sinyallerin drone tespit ve tanımlama süreçlerinde nasıl kullanıldığına dair bilgi verilmiştir. Bu materyaller, tezin temelini oluşturan deneysel çalışmaların dayandığı ana bileşenler olarak sunulmuştur.

Kullanılan Veri Seti, Algoritmalar ve Yöntemler bölümü, tezin deneysel çalışmalarında kullanılan veri setinin tanımı, makine öğrenmesi algoritmaları ve bu algoritmaların uygulama yöntemlerini kapsamaktadır. Bu bölümde ilk olarak, veri setinin içeriği ve bu verilerin nasıl toplandığı açıklanmaktadır. Ardından, K-En Yakın Komşu (KNN), Rastgele Orman (RF), Karar Ağacı (CART) ve Ensemble Model gibi makine öğrenmesi algoritmaları ayrıntılı bir şekilde ele alınmaktadır. Her bir algoritmanın temel özellikleri, bu çalışmadaki rolü ve performans değerlendirmesi sunulmaktadır. Son olarak, kullanılan yöntemler başlığı altında, bu algoritmaların veri seti üzerinde nasıl uygulandığı ve elde edilen sonuçların nasıl analiz edildiği açıklanmaktadır. Bu bölüm,

çalışmanın deneysel metodolojisini ve kullanılan tekniklerin detaylarını sunarak, elde edilen bulguların sağlam bir temele dayandığını göstermektedir.

Test Sonuçları ve Bulgular bölümü, tezin deneysel çalışmalarında elde edilen sonuçları ve bu sonuçların analiziyle ilgili bulguları içermektedir. Bu bölüm, drone algılama, drone tanımlama ve drone modu tanımlama gibi üç ana başlık altında incelenmiştir. İlk olarak, drone algılama başlığı altında, farklı makine öğrenimi algoritmalarının drone tespitinde gösterdiği performans değerlendirilmiştir. İkinci olarak, drone tanımlama başlığında, tanımlanan drone'ların markalarına veya modellerine göre nasıl sınıflandırıldıkları ve bu sınıflandırmada kullanılan yöntemlerin etkinliği ele alınmıştır. Son olarak, drone modu tanımlama kısmında ise drone'ların uçuş modlarının doğru bir şekilde tanımlanabilmesi için kullanılan algoritmaların performansı değerlendirilmiştir. Bu bölüm, her bir algoritmanın güçlü ve zayıf yönlerini ortaya koyarak, drone teknolojilerinin etkin bir şekilde kullanımı için hangi yöntemlerin daha uygun olabileceği konusunda rehberlik sağlamaktadır.

Son olarak Sonuç ve Öneriler bölümünde, tezin bulgularının genel bir değerlendirmesini sunulmakta ve gelecekteki çalışmalar için önerilerde bulunmaktadır. Bu bölümde, gerçekleştirilen çalışmalar sonucunda elde edilen verilerin analizi yapılmış ve kullanılan yöntemlerin etkinliği tartışılmıştır.

2. LİTERATÜR ÖZETİ

İnsansız hava araçlarında makine öğrenimi kullanılarak yapılan çalışmalar, bu teknolojilerin potansiyelini ve uygulama alanlarını genişletmiştir.

Literatüre bakıldığında, Yang ve diğ. (2020), tarafından yapılan çalışmada, sel tespiti ve izleme amacıyla bir insansız hava aracı olan döner kanatlı (helikopter tipi) drone kullanılmıştır. Bu çalışmada, Convolutional Neural Networks (CNN) gibi derin öğrenme modelleri optimize edilerek sel alanlarının tespiti gerçekleştirilmiştir. Araştırmacılar, İHA'ların afet bölgelerinin hızlı bir şekilde taranması ve verilerin analiz edilmesi için nasıl kullanılabileceğini göstermiştir. Bu çalışma, özellikle gerçek zamanlı afet izleme ve yönetimi için önemli bir katkı sağlamaktadır.

Pham ve diğ. (2018), tarafından yapılan çalışmada, İHA'ların otonom navigasyonu için pekiştirmeli öğrenme (Reinforcement Learning) algoritmaları kullanılmıştır. Araştırmacılar, Q-Learning ve Deep Q-Network (DQN) algoritmalarını kullanarak İHA'ların çevresel engelleri algılayarak ve öğrenerek otonom bir şekilde hedeflerine ulaşmasını sağlamışlardır. Bu çalışma, İHA'ların dinamik ortamlarda daha güvenli ve verimli bir şekilde hareket etmelerine olanak tanımaktadır ve otonom sistemler alanında önemli bir gelişme olarak kabul edilmektedir.

Hasan ve Cansever (2023), drone'ların hedef tespiti ve izleme görevlerinde makine öğrenmesi algoritmalarının kullanımını araştırmışlardır. Çalışmada, YOLO (You Only Look Once) ve CNN algoritmaları kullanılarak hareketli hedeflerin tespiti ve izlenmesi sağlanmıştır. Bu çalışma, özellikle güvenlik ve askeri uygulamalarda önemli bir katkı sunmaktadır.

Shalu ve Singh (2023), drone'ların çevresel izleme ve veri toplama görevlerinde makine öğrenmesi algoritmalarını kullanmıştır. Çalışmada, destek vektör makineleri (SVM) ve karar ağaçları (Decision Trees) algoritmaları kullanılarak hava kalitesi ve su kirliliği verileri analiz edilmiştir. Bu yöntem, çevresel koruma ve sürdürülebilirlik çalışmaları için büyük bir katkı sunmaktadır.

Zualkernan ve diğ. (2023), drone'lar ile toplanan görüntü verileri, hassas tarımda makine öğrenme teknikleriyle birlikte kullanılmıştır. Mahsul/yabani ot

sınıflandırmasında Rastgele Ormanlar, Destek Vektör Makineleri (SVM) ve K-En Yakın Komşu Algoritması'ndan (KNN) daha iyi performans göstermiştir. Ayrıca, U-Net tabanlı modeller, geleneksel CNN modellerine kıyasla sınıflandırma ve segmentasyon görevlerinde üstün başarı sağlamıştır.

Guo ve Sahagun (2024), çalışmada makine öğrenmesi ve drone teknolojisini birleştirerek gerçek zamanlı ve yüksek hassasiyetli bir hava kalitesi izleme ve analiz sistemi geliştirme hedeflenmiştir. Bu sistem, drone'ların hava kalitesi sensörleriyle donatılması ve verilerin makine öğrenmesi algoritmalarıyla analiz edilmesi yoluyla yüksek çözünürlüklü hava kalitesi haritaları oluşturmayı sağlar. Sistem, belirli bölgelerdeki hava kalitesini izleyerek, kirleticilerin kaynaklarını tespit etmek ve çevresel riskleri değerlendirmek için kullanılabilir. AirWatch sistemi, şehir içi hava kirliliğinin izlenmesi, sanayi bölgelerindeki emisyonların denetlenmesi ve çevresel düzenlemelere uyum sağlanması gibi çeşitli uygulama alanlarına sahiptir ve çevresel izleme süreçlerinde yenilikçi bir çözüm sunar.

Rahman ve diğ. (2024), İHA'ların tespiti ve sınıflandırılmasında makine öğrenmesi ve derin öğrenme algoritmalarının kullanımını kapsamlı bir şekilde incelemektedir. Çalışmada, radyo frekansı tabanlı, görsel veri tabanlı, akustik tabanlı ve radar tabanlı İHA tespit yöntemleri ele alınmış ve bu yöntemlerin çeşitli güvenlik ve izleme uygulamalarında nasıl etkili bir şekilde kullanılabileceği üzerinde durulmuştur.

Raouhi ve diğ. (2023), İHA'ların akıllı tarımda kullanımını sistematik bir şekilde incelemektedir. Bu makalede, tarımda yaygın olarak kullanılan çok rotorlu drone’lar, sabit kanatlı İHA'lar ve hibrit İHA'lar ele alınmış, bu türlerin manevra kabiliyeti ve hassas kontrol yetenekleri nedeniyle tarımsal izleme ve veri toplama işlemlerinde tercih edildiği vurgulanmıştır. Ayrıca, çalışma, İHA'ların bitki sağlığı izleme, sulama yönetimi, zararlı kontrolü, toprak analizi ve verim tahmini gibi akıllı tarım uygulamalarında nasıl kullanıldığını kapsamlı bir şekilde değerlendirmekte ve bu süreçte kullanılan multi-spektral kameralar, termal kameralar ve NDVI sensörleri gibi çeşitli sensörlerin tarımsal verimliliği artırmadaki rolünü açıklamaktadır. Makine öğrenmesi algoritmalarının, İHA'lar tarafından toplanan büyük veri setlerinin işlenmesi ve analiz edilmesinde kritik bir rol oynadığı ve bu analizlerin tarımsal süreçlerin

optimize edilmesine ve daha verimli bir üretim sürecinin oluşturulmasına katkı sağladığı da belirtilmiştir.

Chen ve diğ. (2017), tarafından yapılan çalışma, otonom iniş yapan insansız hava araçlarının iniş işaretlerini tanımlamak amacıyla Faster Regions with Convolutional Neural Network (Faster R-CNN) modelini kullanmıştır. Bu derin öğrenme algoritması, İHA'ların iniş bölgesini yüksek doğrulukla tespit etmesini sağlayarak, İHA'ların belirli bir alana otonom olarak iniş yapabilmesi için gereken görsel verilerin tanınmasını ve işlenmesini mümkün kılmaktadır. Çalışma, özellikle askeri uygulamalar, acil durum operasyonları ve diğer otonom iniş gerektiren senaryolarda bu algoritmanın önemini vurgulamaktadır, zira İHA'ların güvenli ve kesin bir şekilde belirli bir alana iniş yapabilmesi kritik öneme sahiptir.

Elumalai ve diğ. (2024), tarafından yapılan çalışma, akıllı tarım uygulamalarında IoT (Nesnelerin İnterneti) ve drone verilerinin makine öğrenmesi algoritmalarıyla nasıl işlenebileceğini incelemektedir. Çalışmada, drone'lar tarafından toplanan tarımsal verilerin, IoT cihazları ile kullanılarak, tarımsal süreçlerin optimize edilmesi ve verimliliğin artırılması amaçlanmıştır. Makine öğrenmesi algoritmaları, bu büyük veri setlerini analiz etmek ve tarımsal karar süreçlerini iyileştirmek için kullanılır. Bu çalışma, tarımda veri odaklı karar verme süreçlerine katkıda bulunarak, sürdürülebilir ve verimli tarım uygulamalarını desteklemektedir.

Al-Adwan ve Al-Habahbeh (2022), tarafından yapılan "Unmanned Aerial Vehicles Sensor-Based Detection Systems Using Machine Learning Algorithms" başlıklı çalışma, insansız hava araçlarında (İHA'lar) kullanılan sensör tabanlı tespit sistemlerinde makine öğrenmesi algoritmalarının önemini ele almaktadır. Bu çalışmada, İHA'ların çevresel ve güvenlik tehditlerini tespit edebilmesi için sensörlerden toplanan verilerin makine öğrenmesi algoritmaları ile nasıl analiz edilebileceği incelenmiştir. Çalışmada kullanılan sensörler (görüntü, sıcaklık, basınç gibi) ile elde edilen veriler, makine öğrenmesi algoritmalarıyla işlenerek, tehlikelerin ve anormalliklerin yüksek doğrulukla tespit edilmesi sağlanmıştır. Bu yöntem, İHA'ların askeri gözetim, sınır güvenliği, çevre izleme ve afet yönetimi gibi çeşitli uygulamalarda daha etkin kullanılmasına olanak tanımaktadır, bu da yüksek doğruluk ve düşük gecikme süresi ile karakterize edilen tespit sistemleriyle mümkündür.

Al-Syouf ve diğ. (2024), Bu çalışmada insansız hava araçlarında güvenlik tehditlerini tespit etmek için makine öğrenmesi yaklaşımlarını incelemektedir. Çalışma, çeşitli makine öğrenmesi tekniklerini kullanarak, İHA'ların çeşitli güvenlik açıklarını ve potansiyel saldırıları tespit etme yeteneklerini geliştirmeyi amaçlamaktadır. Özellikle, bu yaklaşımlar İHA'ların güvenlik ve operasyonel etkinliğini artırmak için kritik öneme sahiptir.

Bu tez çalışmasında, literatürdeki çalışmalardan farklı olarak, drone algılama, tanımlama ve uçuş modu belirleme işlemleri, makine öğrenmesi sınıflandırma yöntemleriyle gerçekleştirilmiş; bu sayede düşük maliyetle, kısa sürede sonuçlar elde edilmiştir.

3. KULLANILAN MATERYALLER

3.1. İnsansız Hava Araçları

3.1.1. İnsansız Hava Araçlarının Tanımı ve Yapısı

İHA'lar, belirli görevleri yerine getirmek amacıyla uzaktan kumanda edilen veya otonom olarak çalışan hava araçlarıdır (Austin, 2010). İnsansız hava araçları pilot veya mürettebat olmadan uzaktan kumanda ya da otonom kontrol sistemleri ile birçok görevi yerine getirebilir. İlk olarak askeri amaçlı kullanılan insansız hava araçları, günümüzde teknolojinin ilerlemesi ile tarımdan arkeolojiye kadar birçok alanda önemli görevler üstlenmektedir. İHA'lar, aynı zamanda daha yaygın olarak "drone" olarak da bilinirler ve bu terim, özellikle sivil ve ticari kullanımlarda sıklıkla tercih edilir. Drone'lar, farklı boyutlarda ve özelliklerde olabilen bu hava araçlarının bir alt kategorisi olarak geniş bir kullanım yelpazesine sahiptir.

Bir İnsansız hava aracı veya drone gövde, itki sistemi, uçuş kontrol sistemi, sensörler ve iletişim sistemlerinden oluşmaktadır. Bunlar;

- Gövde: Drone'ların ana bileşeni olup diğer bileşenlerin monte edildiği kısımdır. Gövde, Daha uzun süre uçuş ve zorlu hava koşullarına dayanıklı olması için hafif malzemeden yapılır. Bu gövdeler sensörler ve diğer parçaların montajının kolay yapılabilmesi için modüler bir yapıda tasarlanmıştır. Aynı zamanda gövde, hava direncini azaltacak şekilde aerodinamik bir yapıdadır. Karbon fiber, fiberglas ve alüminyum gibi kompozit malzemelerden yapılırlar.
- İtki Sistemi: Bu sistem, drone'un hareket etmesini ve hava da manevra yapmasını sağlayan önemli bir yapısal bileşendir. Genellikle elektrikli, içten yanmalı veya jet motorlar ile pervanelerden oluşur. İnsansız hava araçlarının türüne, boyutuna ve kullanım amaçlarına göre kullanılan motorlar ve pervaneler farklılık göstermektedir. Drone'un görev süresi ve manevra kabiliyetinin en iyi düzeyde olması için itki sisteminin iyi bir şekilde tasarlanması büyük önem taşır.
- Uçuş Kontrol Sistemi: İnsansız hava aracının kontrollü ve stabil uçmasını sağlayan elektronik ve yazılımsal bileşenlerdir. Bu sistem, çeşitli sensörler ve kontrol algoritmaları kullanılarak uçuşun güvenli ve verimli olmasını sağlar.

- Sensörler: Hava aracının uçuş kontrol sisteminde kullanılan sensörler, aracın çevresi ve hareketi ile ilgili verileri toplayarak uçuş kontrol kartına iletir. Uçuş kontrol kartı da sensörlerden aldığı verileri kullanarak aracın stabilitesini, yönünü, hızını ve irtifasını belir.
- İletişim Sistemleri: Drone'ların yer kontrol istasyonu ile güvenilir ve kesintisiz bir şekilde veri alışverişi yapmasını sağlayan bileşenlerdir. Bu sistemler, aracın uzaktan kontrol edilmesini, izlenmesini ve gerektiğinde müdahale edilmesini sağlar. İletişim sistemleri, radyo frekansları, uydu bağlantıları ve kablosuz ağlar üzerinden çalışabilir.
- Radyo Frekanslar: Drone ile yer kontrol istasyonları arasında kısa ve orta mesafeli iletişim sağlamak için kullanılır ve şu bileşenlerden oluşur: Verici, drone üzerinde bulunur ve yer kontrol istasyonuna veri gönderir; alıcı, yer kontrol istasyonunda bulunur ve Drone'dan gelen verileri alır; antenler ise hem drone hem de yer kontrol istasyonunda bulunur ve radyo dalgalarını iletir ve alır. Radyo frekansları, düşük gecikme süreleri ve yüksek veri iletim hızları ile gerçek zamanlı kontrol ve izleme sağlar.
- Uydu Bağlantıları: hava aracının uzun mesafeli iletişim ihtiyaçlarını karşılamak için kullanılır ve özellikle geniş alanların gözetimi, keşif ve askeri operasyonlar gibi görevlerde tercih edilir. Bu sistemler, yer istasyonu, uydu ve uydu modülü olmak üzere üç temel bileşenden oluşur: Yer istasyonu, drone ile uydu arasında veri alışverişini sağlar; uydu, verileri yer istasyonundan drone'a ve drone'dan yer istasyonuna aktarır; uydu modülü ise drone üzerinde bulunur ve uydu ile doğrudan iletişim kurar.
- Kablosuz Ağlar: insansız hava araçlarının kısa mesafeli ve yerel iletişim ihtiyaçlarını karşılamak için kullanılır ve genellikle Wi-Fi, LTE veya 5G teknolojileri üzerine kuruludur. Bu sistemler, erişim noktaları ve veri ağları olmak üzere iki ana bileşenden oluşur: Erişim noktaları, hava aracının bağlanabileceği kablosuz ağ cihazlarıdır; veri ağları ise hava aracının yerel veri ağlarına bağlanarak veri alışverişi yapmasını sağlar. Kablosuz ağlar, yüksek veri iletim hızları ve düşük gecikme süreleri sunarak gerçek zamanlı veri akışı sağlar.

3.1.2. İnsansız Hava Araçlarının Çeşitleri

İnsansız hava araçları çeşitli amaçlar ve görevler için farklı tiplerde tasarlanmış ve üretilmiştir. Bunlar:

- Sabit Kanatlı Modeller: Geleneksel uçaklar gibi sabit kanatlara sahip olan bu araçlar, genellikle uzun mesafeli keşif ve gözetim görevlerinde kullanılır. Yüksek hız ve uzun uçuş süreleri sunan bu modeller, genellikle askeri operasyonlarda tercih edilir.
- Döner Kanatlı Modeller: Helikopter benzeri rotor sistemleri ile donatılmış bu araçlar, daha fazla manevra kabiliyeti ve dikey kalkış-iniş yetenekleri sunar. Kısa mesafeli görevlerde sıkça kullanılır ve genellikle sivil uygulamalar ile hobi amaçlı kullanımlarda tercih edilir. Bu tür araçlar, kamera ve sensörlerle donatılmıştır.
- Hibrit Modeller: Sabit kanatlı ve döner kanatlı sistemlerin özelliklerini birleştirir ve hem uzun uçuş süresi hem de yüksek manevra kabiliyeti sağlar. Dik kalkış-iniş yapabilen ve uzun mesafeler kat edebilen bu araçlar, özellikle paket teslimatında kullanılır.
- Mikro ve Nano Modeller: Küçük boyutları sayesinde dar alanlarda operasyon yapabilme yeteneğine sahip bu araçlar, genellikle iç mekanlarda veya kalabalık ortamlarda kullanılır. Ayrıca, eğitim ve eğlence amaçlı olarak da tercih edilirler.
- Yüksek İrtifa Uzun Dayanıklılık (HALE) Modeller: Yüksek irtifalarda uzun süre boyunca uçabilen bu araçlar, stratejik gözetim ve keşif görevlerinde önemli bir rol oynar.

3.1.3. İnsansız Hava Araçlarının Kullanım Alanları

İnsansız hava araçları, yani drone'lar, geniş bir kullanım yelpazesi sunarak çeşitli ihtiyaçlara yönelik özelleştirilmiş çözümler sağlar. En yaygın kullanım alanları şunlardır:

- Askeri Uygulamalar: Bu araçlar, başlangıçta askeri amaçlarla geliştirilmiş olup, halen bu alanda en yoğun şekilde kullanılmaktadır. Askeri operasyonlarda keşif, gözetim, istihbarat toplama, hedef tespiti ve saldırı görevlerinde etkin bir şekilde rol alırlar. Örneğin, Predator ve Reaper gibi modeller, yüksek irtifalarda uzun süreli

uçuşlar yaparak düşman bölgelerini izleyebilir ve gerektiğinde silahlı müdahalelerde bulunabilir. Bu tür araçlar, insan pilotların risk altında olmasını engellerken, operasyonel esneklik sağlar.

- Tarım: Tarım sektöründe drone'lar, bitki sağlığı izleme, sulama yönetimi, ilaçlama ve ekim gibi çeşitli görevlerde kullanılır. Multispektral ve termal kameralarla donatıldığında, tarlaların ayrıntılı haritalarını çıkararak bitki sağlığını izleyebilirler. Böylece, çiftçiler zararlıları ve hastalıkları erken tespit ederek hızlıca müdahale edebilir. Ayrıca, hassas tarım uygulamaları ile sulama ve gübreleme işlemlerini optimize ederek verimliliği artırırlar.
- Arama ve Kurtarma: Doğal afetler veya kaybolma vakalarında, drone'lar hızlı bir şekilde geniş alanları tarayarak kaybolan kişilerin yerini tespit edebilir. Termal kameralar ve diğer sensörlerle donatılmış bu araçlar, gece veya zor hava koşullarında bile etkili arama yapabilir. Bu sayede, tehlikeli bölgelerde insan kurtarma ekiplerinin yerine kullanılarak hem hız kazandırılır hem de güvenlik artırılır.
- Çevresel İzleme: Drone'lar, çevresel izleme ve koruma çalışmalarında da sıkça kullanılır. Orman yangınlarının tespiti ve izlenmesi, su kaynaklarının takibi, yaban hayatı sayımı ve kirlilik kontrolü gibi görevlerde etkili olurlar. Örneğin, orman yangınlarının erken tespiti ve yangının yayılma yönünün izlenmesi, yangınla mücadele ekiplerinin stratejik kararlar almasını kolaylaştırır.
- İnşaat ve Altyapı Denetimi: Bu araçlar, inşaat projelerinde ve altyapı denetimlerinde önemli bir rol oynar. İnşaat sahalarının havadan izlenmesi, proje ilerlemesinin kontrol edilmesi ve yapıların 3D haritalarının oluşturulması gibi görevlerde kullanılırlar. Ayrıca, köprüler, enerji hatları ve rüzgar türbinleri gibi büyük altyapı projelerinin düzenli denetimleri daha hızlı ve güvenli bir şekilde gerçekleştirilebilir.
- Medya ve Eğlence: Film ve televizyon prodüksiyonlarında, haber yapımında ve spor etkinliklerinde drone'lar, havadan çekim yaparak eşsiz görüntüler sunar. Düğün videoları, reklam çekimleri ve canlı yayınlar için de yüksek kaliteli ve etkileyici görüntüler sağlarlar. Bu kullanım alanı hem estetik hem de ekonomik avantajlar sunar.
- Lojistik ve Teslimat: Amazon Prime Air gibi şirketler, paket teslimatlarında drone'ları kullanarak hızlı ve etkin hizmet sunmayı hedeflemektedir. Bu araçlar,

trafik sıkışıklığı gibi kara taşıma problemlerini aşarak, özellikle acil durumlarda veya ulaşılması zor bölgelere teslimat yapmada büyük kolaylık sağlar.

- Araştırma ve Bilim: Bilimsel araştırmalarda drone'lar, veri toplama ve gözlem yapma süreçlerinde kullanılır. Özellikle coğrafi bilgi sistemleri (GIS), meteoroloji ve jeoloji alanlarında, hassas veriler toplayarak araştırmacılara detaylı analiz imkânı sunarlar. Antarktika'daki buzulların izlenmesi veya volkanik aktivitelerin gözlemlenmesi gibi zorlu araştırma alanlarında önemli katkılar sağlarlar.

Drone'ların bu çeşitli kullanım alanları, teknolojinin ilerlemesiyle birlikte daha da genişlemekte ve derinleşmektedir.

3.1.4. İnsansız Hava Araçlarının Kullanım Riskleri

İnsansız hava araçları, sundukları avantajlarla birçok alanda büyük kolaylıklar sağlarken, aynı zamanda bazı riskleri ve zorlukları da beraberinde getirmektedir. Bu araçların kullanımının yaygınlaşmasıyla birlikte, güvenlik, gizlilik ve düzenleme konularında ortaya çıkan riskler daha belirgin hale gelmiştir. Aşağıda, bu araçların kullanımına dair başlıca riskler sıralanmıştır:

- Güvenlik Riskleri: Bu araçlar, hava sahasında diğer uçaklar ve helikopterlerle çarpışma riski taşır. Özellikle yoğun hava trafiği olan bölgelerde veya kontrolsüz hava sahalarında bu risk daha yüksektir. Ayrıca, teknik arızalar veya operatör hataları nedeniyle düşmeleri, insanlar veya mülkler üzerinde ciddi zararlara yol açabilir. Bu tür olaylar hem maddi kayıplara hem de yaralanmalara neden olabilir.
- Gizlilik ve Veri Güvenliği Riskleri: Gözetim ve veri toplama yetenekleri nedeniyle, drone'lar bireylerin ve kurumların mahremiyetine yönelik tehditler oluşturabilir. Yasadışı olarak kullanılan bu araçlar, özel mülkiyetlerin, hassas alanların ve kişisel verilerin izinsiz olarak görüntülenmesine veya kaydedilmesine yol açabilir. Bu durum, bireysel gizlilik ihlallerine ve kurumsal bilgilerin çalınmasına neden olabilir.
- Sibernetik Tehditler: İnsansız hava araçları, bilgisayar sistemleri ve yazılımlar ile kontrol edildiği için siber saldırılara karşı savunmasızdır. Hackerlar, bu araçların kontrolünü ele geçirerek zararlı faaliyetlerde bulunabilirler. Bu tür saldırılar, görevlerin yerine getirilememesi, cihazın düşmesi veya kötü amaçlı kullanımına yol açabilir.

- Düzenleyici ve Hukuki Riskler: Drone kullanımına ilişkin yasal düzenlemeler, hızlı teknolojik gelişmeler karşısında yetersiz kalabilir. Düzenlemelerin eksik veya belirsiz olması hem kullanıcılar hem de düzenleyici otoriteler için karmaşıklık yaratır. Ayrıca, farklı ülkelerin kullanım ile ilgili farklı düzenlemelere sahip olması, uluslararası operasyonlarda hukuki zorluklar doğurabilir.
- Sosyal ve Etik Riskler: Bu araçların yaygın kullanımı, toplumda etik ve sosyal kaygılar da yaratabilir. Özellikle askeri ve güvenlik amaçlı kullanımları, sivillerin yaşamlarını olumsuz etkileyebilir ve kamuoyunda tartışmalara yol açabilir. Ayrıca, ticari ve kişisel kullanımlarında adil ve etik olmayan uygulamaların ortaya çıkma riski vardır.

Drone'ların sağladığı faydaların yanı sıra, bu araçların kullanımına dair risklerin doğru bir şekilde yönetilmesi büyük önem taşımaktadır. Bu risklerin minimize edilmesi, drone'ların güvenli, verimli ve sorumlu bir şekilde kullanılmasına olanak tanıyacaktır. Teknolojik ve yasal düzenlemelerin yanı sıra, toplumsal bilinçlendirme ve eğitim çalışmaları da bu sürecin önemli bir parçasını oluşturmaktadır.

3.2. Makine Öğrenmesi

3.2.1. Makine Öğrenmesinin Tanımı ve Önemi

Makine öğrenmesi, bilgisayarların insan müdahalesi olmadan deneyimlerden öğrenme ve bu bilgileri kullanarak yeni ve bilinmeyen veriler üzerinde tahminler yapma yeteneği kazanmalarını sağlayan bir yapay zekâ alt dalıdır. Jordan ve Mitchell (2015), makine öğrenmesini şu şekilde tanımlamaktadır: "Makine öğrenmesi, bilgisayarların deneyim yoluyla gelişmesini sağlayan bir bilim dalıdır" (Jordan & Mitchell, 2015).

Makine öğrenmesi, büyük veri setleri üzerinde çalışarak karmaşık desenleri ve ilişkileri ortaya çıkarır. Bu, işletmelerin ve araştırmacıların daha doğru tahminler yapmasına ve stratejik kararlar almasına olanak tanır. Örneğin, finans sektöründe kredi riski değerlendirmeleri ve pazar eğilimlerinin tahmin edilmesi gibi uygulamalarda makine öğrenmesi büyük fayda sağlar. Ayrıca, otomasyon ve verimlilik açısından makine öğrenmesi algoritmaları, rutin ve tekrarlayan görevleri otomatikleştirir, böylece insan müdahalesine olan ihtiyacı azaltır ve verimliliği artırır.

Makine öğrenmesi, kullanıcı davranışlarını analiz ederek kişiselleştirilmiş deneyimler sunar. Bu, e-ticaret sitelerinde ürün önerileri, dijital pazarlama stratejilerinde hedefleme ve sosyal medya platformlarında içerik önerileri gibi uygulamalarda kullanılır. Bu sayede kullanıcı memnuniyeti artar ve işletmelerin müşteri bağlılığı güçlenir. Sağlık hizmetlerinde inovasyon açısından da makine öğrenmesi algoritmaları hastalık teşhisi, tedavi planlaması ve hasta izleme gibi alanlarda yenilikçi çözümler sunar. Örneğin, tıbbi görüntüleme verilerinin analizi ile kanser teşhisi veya genetik verilerin analizi ile kişiselleştirilmiş tedavi yöntemleri geliştirilmesi gibi uygulamalar, sağlık hizmetlerinin kalitesini ve etkinliğini artırır.

Makine öğrenmesi, güvenlik ve gözetim sistemlerinde de önemli bir rol oynar. Örneğin, yüz tanıma sistemleri, anormal davranış tespiti ve siber güvenlik tehditlerinin önceden belirlenmesi gibi uygulamalar, toplum güvenliğini artırır ve suçları önlemeye yardımcı olur. Makine öğrenmesinin sunduğu bu avantajlar, onun neden günümüz dünyasında bu kadar önemli ve yaygın bir teknoloji olduğunu göstermektedir. İleriye dönük olarak, makine öğrenmesi teknolojilerinin daha da gelişmesi ve yaygınlaşması beklenmektedir.

3.2.2. Makine Öğrenmesinin Tarihçesi ve Gelişimi

Makine öğrenmesinin kökleri, 1950'lerde yapay zekanın (AI) doğuşuyla birlikte atıldı. Alan Turing'in 1950 yılında yayınladığı "Computing Machinery and Intelligence" makalesi, makinelerin zekâ sahibi olup olamayacağı sorusunu ortaya attı ve Turing Testi'ni önerdi. 1952 yılında Arthur Samuel, IBM'de çalışırken bilgisayarların satranç gibi oyunları öğrenebilmesi üzerine çalışmalar yaptı ve "makine öğrenmesi" terimini ilk kez kullandı. Bu çalışmalar, bilgisayarların belirli görevleri yerine getirirken deneyimlerden nasıl öğrenebileceğini göstermeye başladı.

1960'larda, Türk matematikçi Cahit Arf, "Makineler Düşünebilir mi?" makalesiyle yapay zekâ ve makine öğrenmesi konularına önemli katkılarda bulundu. Arf, makalesinde makinelerin düşünme yetenekleri üzerine tartışmalar yaparak, bu alandaki teorik temellerin oluşmasına yardımcı oldu (Arf, 1960).

Makine öğrenmesinin gelişiminde birkaç önemli aşama vardır. 1960'larda, Frank Rosenblatt'ın geliştirdiği perceptron algoritması, yapay sinir ağlarının temellerini attı.

Ancak, Marvin Minsky ve Seymour Papert'in 1969'da yayınladıkları "Perceptrons" kitabı, bu erken dönem çalışmalarının sınırlamalarını gösterdi ve araştırmalar bir süre durakladı.

1980'ler ve 1990'lar, makine öğrenmesi alanında önemli ilerlemelerin kaydedildiği yıllar oldu. Bu dönemde, veri madenciliği ve bilgi keşfi alanlarındaki çalışmalar yoğunlaştı. Ayrıca, Geoffrey Hinton ve Yann LeCun gibi araştırmacıların katkılarıyla derin öğrenme (deep learning) alanında önemli adımlar atıldı. Özellikle, Hinton'ın 1986'da geliştirdiği geri yayılım (backpropagation) algoritması, yapay sinir ağlarının eğitiminde devrim yarattı.

2000'li yıllar ve sonrasında, internetin ve büyük veri (big data) teknolojilerinin gelişimi, makine öğrenmesinin hızla yayılmasına ve daha geniş bir uygulama yelpazesinde kullanılmasına olanak tanıdı. Günümüzde, makine öğrenmesi; sağlık, finans, perakende, otomotiv ve daha birçok sektörde önemli çözümler sunmaktadır.

3.2.3. Makine Öğrenmesinin Temel Kavramları

Makine öğrenmesi, karmaşık problemlerin çözümünde kullanılan birçok temel kavrama sahiptir. Bu kavramlar, makine öğrenmesi modellerinin oluşturulmasında ve uygulanmasında kritik rol oynar.

3.2.3.1. Veri ve Veri Seti

Veri, makine öğrenmesi modellerinin eğitilmesi ve test edilmesi için kullanılan bilgidir. Veriler, çeşitli kaynaklardan elde edilebilir ve farklı formatlarda olabilir. Örneğin, metin, görüntü, ses veya sayısal ölçümler şeklinde veri toplanabilir.

Veri seti, belirli bir problem veya görev için toplanmış ve organize edilmiş veri koleksiyonudur. Makine öğrenmesi modelleri, bu veri setleri üzerinde eğitilir ve değerlendirilir. Bir veri seti, genellikle giriş (input) ve çıkış (output) verilerinden oluşur. Örneğin, Drone'larla ilgili bir veri seti, drone'ların uçuş sırasında topladığı sensör verilerini içerebilir.

3.2.3.2. Etiketsiz ve Etiketli Veri

Etiketli veri, her veri noktasının bir hedef veya sonuç değeri ile geldiği veri türüdür. Bu tür veriler, genellikle gözetimli öğrenme algoritmaları için kullanılır. Etiketli veriler, modelin doğru tahminlerde bulunabilmesi için gerekli referans bilgilerini sağlar.

Etiketsiz veri, veri noktalarının hedef veya sonuç değeri içermediği veri türüdür. Bu tür veriler, genellikle gözetimsiz öğrenme algoritmaları için kullanılır. Model, etiketsiz verilerdeki gizli desenleri ve yapıları kendi başına keşfeder.

Drone'ların uçuş sırasında topladığı görüntüler, etiketsiz veri olarak değerlendirilebilir. Bu görüntüler, gözetimsiz öğrenme algoritmaları kullanılarak analiz edilebilir ve drone'ların uçuş rotasında belirli nesnelerin (örneğin, ağaçlar, binalar) tanımlanması sağlanabilir. Etiketli veri örneği ise, drone'un çektiği görüntülerde belirli nesnelerin (örneğin, araçlar, insanlar) manuel olarak işaretlendiği durumları içerir. Bu etiketli veriler, nesne tespiti ve sınıflandırma modellerinin eğitimi için kullanılabilir.

3.2.3.3. Özellik Mühendisliği

Özellik mühendisliği, ham verilerden anlamlı ve faydalı özellikler (features) çıkarma sürecidir. Bu özellikler, makine öğrenmesi modellerinin performansını önemli ölçüde artırabilir. Özellik mühendisliği, verilerin doğru şekilde temsil edilmesini ve modelin bu verilerden daha iyi öğrenme yapmasını sağlar.

Drone'ların uçuş verilerinden hız, irtifa değişimi ve yönelme gibi özellikler çıkarılabilir. Bu özellikler, drone'un uçuş dinamiklerinin analiz edilmesi ve uçuş performansının optimize edilmesi için kullanılabilir.

3.2.3.4. Model ve Algoritma

Makine öğrenmesi modeli, veriler üzerinde eğitim sürecinden geçirilen ve belirli bir görevi (örneğin, sınıflandırma, regresyon) gerçekleştiren matematiksel bir yapıdır. Model, verilerden öğrenerek yeni ve bilinmeyen veriler üzerinde tahminler yapma yeteneği kazanır.

Algoritma, makine öğrenmesi modellerini eğitmek için kullanılan yöntem veya prosedürdür. Algoritmalar, verilerden öğrenme sürecini yönetir ve modelin parametrelerini optimize eder.

Drone'ların uçuş verileri kullanılarak geliştirilen bir makine öğrenmesi modeli, drone'un belirli hava koşullarında nasıl performans göstereceğini tahmin edebilir. Örneğin, bir karar ağacı (Decision Tree) algoritması, drone'un belirli irtifa ve hız değerlerinde enerji tüketimini tahmin etmek için kullanılabilir. Algoritma, eğitim sürecinde verilerden öğrenir ve modelin parametrelerini optimize ederek en doğru tahminleri yapmasını sağlar.

3.2.4. Makine Öğrenmesi Türleri

Makine öğrenmesi, farklı öğrenme türlerine dayanarak çeşitli problemlere çözüm getirebilir. Başlıca makine öğrenmesi türleri Şekil 3.1'de görüldüğü gibi gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme olarak sınıflandırılır. Her bir öğrenme türü, belirli veri türleri ve problemler için uygundur.

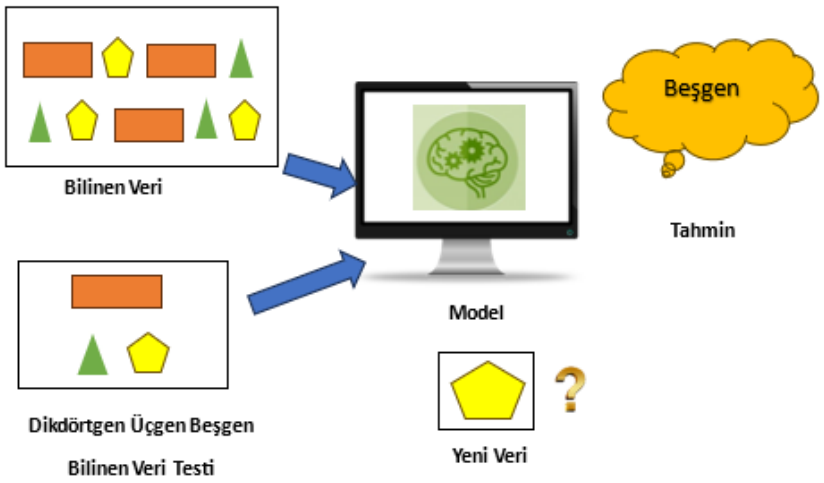


Şekil 3.1. Makine öğrenmesi türleri

3.2.4.1. Gözetimli Öğrenme (Supervised Learning)

Gözetimli öğrenme, etiketli veri kullanılarak modelin eğitildiği bir makine öğrenmesi türüdür. Etiketli veri setinde her veri noktası bir giriş(input) ve bir çıkış(output) değeri

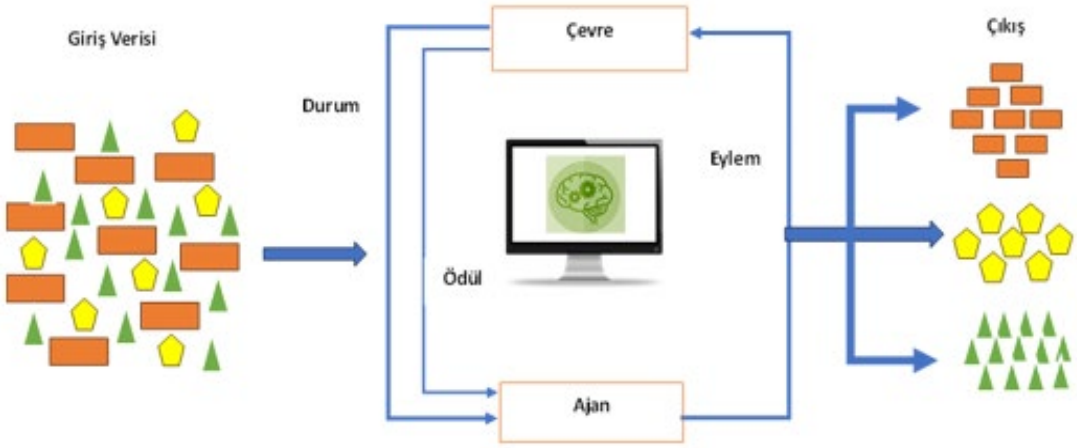
içerir. Şekil 3.2'de görüldüğü gibi model, giriş ve hedef değerler arasındaki ilişkiyi öğrenerek yeni verilere tahminler yapabilir.



Şekil 3.2. Gözetimli öğrenme

3.2.4.2. Gözetimsiz Öğrenme (Supervised Learning)

Gözetimsiz öğrenme, etiketlenmemiş veri kullanılarak modelin eğitildiği bir makine öğrenmesi türüdür. "Gözetimsiz öğrenme, verilerdeki gizli yapıları ve desenleri keşfetmek amacıyla etiketlenmemiş veriler üzerinde çalışır" (Hastie, Tibshirani, & Friedman, 2009). Bu yöntem, özellikle veri etiketlemenin zor veya maliyetli olduğu durumlarda kullanışlıdır. Yöntemin çalışma yapısı Şekil 3.3'te olduğu gibidir.

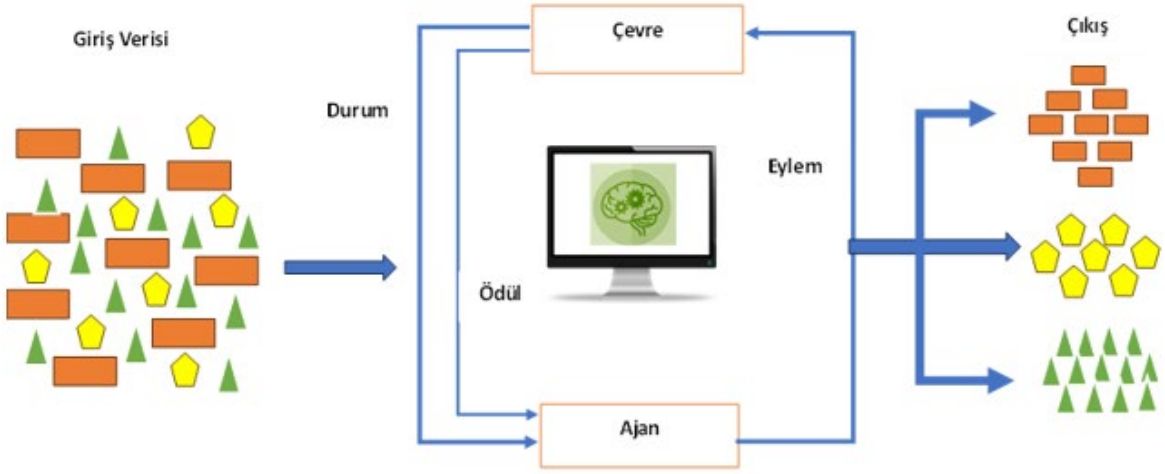


Şekil 3.3. Gözetimsiz öğrenme

Bir drone'un görüntü verileri kullanılarak nesne tespiti yapması gözetimli öğrenmeye örnektir. Eğitim veri seti, her görüntüdeki nesnelerin etiketlendiği verilerdir. Model, bu verilerden öğrenerek yeni görüntülerdeki nesneleri tanımlayabilir.

3.2.4.3. Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, bir ajanın çevresiyle etkileşimde bulunarak hangi eylemlerin daha yüksek ödül getirdiğini öğrenmeye çalıştığı bir öğrenme türüdür. Ajan, deneme yanılma yoluyla en iyi stratejiyi veya politikayı geliştirmeye çalışır. Yöntemin çalışma yapısı Şekil 3.4'te olduğu gibidir.



Şekil 3.4. Pekiştirmeli öğrenme

Bir İHA'nın otonom navigasyonu pekiştirmeli öğrenmeye örnektir. İHA, çevresindeki engellerden kaçınarak ve hedef noktalarına ulaşarak ödüller kazanmaya çalışır. Ajan, en uygun rotayı belirlemek için sürekli olarak çevresiyle etkileşime girer ve deneyimlerinden öğrenir.

3.2.5. Makine Öğrenmesinin Uygulama Alanları

Makine öğrenmesi, günümüzde birçok sektörde ve alanda kullanılan güçlü bir teknolojidir. Verilerin işlenmesi ve analiz edilmesiyle makine öğrenmesi, çeşitli problemlere yenilikçi çözümler sunar. Makine öğrenmesinin kullanıldığı alanlar şunlardır:

- Sağlık Hizmetleri: Makine öğrenmesi, sağlık sektöründe teşhis ve tedavi süreçlerini önemli ölçüde iyileştirmektedir. Hastalık teşhisi, tedavi planlaması, ilaç keşfi ve hasta izleme gibi alanlarda makine öğrenmesi algoritmaları kullanılarak daha doğru ve hızlı sonuçlar elde edilebilir. Sağlık sektöründe Röntgen, MR ve CT taramaları gibi tıbbi görüntülerin analizi için makine öğrenmesi algoritmaları kullanılır. Bu algoritmalar, görüntülerdeki anormallikleri tespit ederek doktorlara yardımcı olur. Hastalıkların erken teşhisinde makine öğrenmesi algoritmaları kullanılabilir
- Finans ve Bankacılık: Makine öğrenmesi, finans sektöründe risk yönetimi, dolandırıcılık tespiti, müşteri hizmetleri ve yatırım stratejileri gibi birçok alanda kullanılmaktadır. Bankalar, müşterilerin kredi başvurularını değerlendirirken makine öğrenmesi modelleri kullanarak kredi riskini tahmin eder. Bu sayede, kredi verilecek kişilerin ödeme kapasiteleri daha doğru bir şekilde belirlenir. Makine öğrenmesi algoritmaları, finansal işlemleri analiz ederek anormal ve şüpheli aktiviteleri tespit eder.
- Perakende ve E-Ticaret: Makine öğrenmesi, perakende ve e-ticaret sektörlerinde müşteri deneyimini geliştirmek, satışları artırmak ve operasyonel verimliliği sağlamak için kullanılır. E-ticaret siteleri, müşterilere ilgi alanlarına göre kişiselleştirilmiş ürün önerileri sunmak için makine öğrenmesi algoritmaları kullanır.
- Ulaşım ve Lojistik: Makine öğrenmesi, ulaşım ve lojistik sektöründe verimliliği artırmak, maliyetleri düşürmek ve hizmet kalitesini iyileştirmek için önemli rol oynar. Makine öğrenmesi, otonom araçların çevresini algılaması, kararlar alması ve güvenli bir şekilde hareket etmesi için kullanılır.
- Askeri Uygulamalar: Makine öğrenmesi, askeri alanda da kritik öneme sahiptir. Güvenlik ve savunma stratejilerinin geliştirilmesi, tehditlerin tespiti ve operasyonel verimlilik gibi birçok alanda kullanılır. Makine öğrenmesi algoritmaları, insansız hava araçları ve diğer gözetim sistemlerinde hedef tespiti ve izleme görevlerinde kullanılır. Bu, düşman hareketlerinin hızlı ve doğru bir şekilde belirlenmesini sağlar. Askeri eğitim ve simülasyonlarda kullanılarak askerlerin savaş stratejilerini ve operasyonel becerilerini geliştirmelerine yardımcı olur. Makine öğrenmesi, askeri siber güvenlik sistemlerinde tehdit tespiti ve saldırı önleme amaçlı kullanılır. Bu, askeri ağların ve verilerin korunmasını sağlar.

- Enerji ve Çevre: Makine öğrenmesi, enerji üretimi ve tüketimi ile çevresel koruma alanlarında da yaygın olarak kullanılmaktadır. Bu alanlarda verimliliği artırmak ve sürdürülebilirlik sağlamak için makine öğrenmesi önemli çözümler sunar. Enerji firmaları, tüketim verilerini analiz ederek gelecekteki enerji talebini tahmin eder. Bu, enerji üretim planlamasında ve arz-talep dengesinin sağlanmasında kullanılır. Rüzgâr türbinleri ve güneş panelleri gibi yenilenebilir enerji kaynaklarının verimliliği, makine öğrenmesi algoritmaları ile artırılabilir.
- Medya ve Eğlence: Makine öğrenmesi, medya ve eğlence sektörlerinde içerik önerisi, kişiselleştirilmiş deneyimler ve veri analizi gibi alanlarda kullanılarak kullanıcı memnuniyetini artırır. Video akış platformları ve müzik servisleri, kullanıcıların beğenilerine göre kişiselleştirilmiş içerik önerileri sunmak için makine öğrenmesi kullanır. Bu, kullanıcıların ilgisini çeker ve platforma bağlılıklarını artırır. Medya şirketleri, izleyici davranışlarını analiz ederek hangi içeriklerin popüler olduğunu belirler.

3.2.6. Makine Öğrenmesinin İnsansız Araçlarında Kullanımı

Makine öğrenmesi (ML), insansız hava araçları alanında çeşitli uygulamalarla büyük bir dönüşüm sağlamaktadır. Özellikle gözetim, keşif, tarım, arama-kurtarma ve askeri operasyonlar gibi alanlarda yaygın olarak kullanılmaktadır. Makine öğrenmesi, bu araçların daha akıllı, verimli ve otonom hale gelmesini sağlar. Makine öğrenmesinin insansız hava araçlarında kullanıldığı yerler şunlardır:

- Nesne ve Hedef Tespiti: Makine öğrenmesi, Drone'ların görüntü işleme yeteneklerini artırarak nesne ve hedef tespitinde kullanılabilir. Özellikle derin öğrenme algoritmaları, görüntülerdeki nesneleri hızlı ve doğru bir şekilde tanımlama kapasitesine sahiptir. Bir İHA, tarım alanlarında bitki sağlığını izlemek için uçarken, makine öğrenmesi algoritmaları kullanarak bitkilerdeki hastalık belirtilerini tespit edebilir. Aynı şekilde, askeri operasyonlarda düşman hedeflerinin tespiti için de Drone'lar, makine öğrenmesi tabanlı görüntü işleme teknikleri kullanabilir.
- Otonom Navigasyon ve Rota Planlama: Makine öğrenmesi, drone'ların otonom olarak hareket etmelerini ve en uygun rotayı belirlemelerini sağlar. Bu, drone'ların

çevresel koşullara uyum sağlayarak engellerden kaçınmasına ve belirlenen hedeflere güvenli bir şekilde ulaşmasına olanak tanır.

- Tahmine Dayalı Bakım ve Arıza Tespiti: Makine öğrenmesi, drone'ların bakımı ve arıza tespiti süreçlerinde de önemli rol oynar. Sensör verileri analiz edilerek, olası arızalar önceden tahmin edilebilir ve gerekli bakım işlemleri zamanında yapılabilir.
- Veri Toplama ve Analiz: İnsansız hava araçları, büyük miktarda veri toplayabilir ve bu veriler makine öğrenmesi algoritmaları ile analiz edilerek anlamlı bilgilere dönüştürülebilir.
- Güvenlik ve Gözetim: İnsansız hava araçları, güvenlik ve gözetim amaçlı olarak da makine öğrenmesi kullanılarak optimize edilebilir. Bu, özellikle sınır güvenliği, kamu güvenliği ve kritik altyapıların korunması gibi alanlarda etkilidir.
- Çevresel İzleme ve Koruma: Makine öğrenmesi, drone'ların çevresel izleme ve koruma görevlerinde de etkili bir şekilde kullanılmasını sağlar. Bu, hava kalitesi ölçümleri, su kaynaklarının izlenmesi ve yaban hayatı gözetimi gibi alanları kapsar.

3.3. Radyo Frekans Sinyalleri

Radyo frekansı (RF), elektromanyetik spektrumun 3 kHz ile 300 GHz arasındaki frekans aralığını kapsar. Bu frekans aralığı, radyo dalgalarının iletişim, radar, televizyon, cep telefonları, Wi-Fi ve diğer kablosuz iletişim teknolojilerinde kullanılmasını sağlar (Haykin, 2001). RF sinyalleri, bilgi taşıma kapasitesine sahip elektromanyetik dalgalardır ve bu dalgalar, elektromanyetik spektrumda belirli frekanslarda salınır.

RF sinyalleri, bir verici (transmitter) tarafından üretilir ve bir anten aracılığıyla iletilir. Bu sinyaller, serbest uzayda yayılarak belirli bir mesafeye ulaşır. Alıcı (receiver) ise bu sinyalleri toplar ve çözümleyerek orijinal bilgiyi geri elde eder. RF sinyallerinin çalışma prensibi birkaç temel adımdan oluşur:

- Verici: RF sinyalleri, verici cihaz tarafından üretilir. Bu cihaz, elektrik sinyallerini elektromanyetik dalgalara dönüştürür. Verici anten, bu elektromanyetik dalgaları havaya yayar.
- Modülasyon: Verici tarafından üretilen RF sinyalleri, taşıdıkları bilgiyi kodlamak için modüle edilir. Modülasyon, bilgi sinyalinin (örneğin, ses veya veri) RF taşıyıcı

dalga üzerine bindirilmesini sağlar. Modülasyon yöntemleri arasında frekans modülasyonu (FM), genlik modülasyonu (AM) ve faz modülasyonu (PM) bulunur.

- Frekans Modülasyonu (FM): Frekans modülasyonu, bir taşıyıcı dalganın frekansının bilgi sinyaline göre değiştirilmesi işlemidir. Bu modülasyon türünde, bilgi sinyalinin genliğine bağlı olarak taşıyıcı dalganın frekansı sürekli olarak değişir. Taşıyıcı dalganın genliği sabit kalırken, frekansındaki değişiklikler bilgi sinyalini taşır. Frekans modülasyonunda, bilgi sinyali taşıyıcı dalganın frekansını artırıp azaltarak iletilir.
- Genlik Modülasyonu (GM): Genlik modülasyonu, bir taşıyıcı dalganın genliğinin bilgi sinyaline göre değiştirilmesi işlemidir. Bu modülasyon türünde, taşıyıcı dalganın genliği, bilgi sinyalinin anlık genliğine bağlı olarak değişir. Taşıyıcı dalganın frekansı ve fazı sabit kalırken, genlikteki değişiklikler bilgi sinyalini taşır Genlik modülasyonunda, bilgi sinyali (örneğin, ses veya veri sinyali) taşıyıcı dalganın genliğini değiştirir. Bu, bilgi sinyalinin taşıyıcı dalganın tepe değerine eklenmesiyle gerçekleşir.
- Faz Modülasyonu (PM): Faz modülasyonu, bilgi sinyalinin genliğine bağlı olarak taşıyıcı dalganın fazının değiştirilmesi işlemidir. Bu modülasyon türünde, taşıyıcı dalganın genliği ve frekansı sabit kalırken, fazı bilgi sinyaline göre değişir. Faz modülasyonu, dijital iletişim sistemlerinde sıkça kullanılır ve faz kaydırmalı anahtarlama (PSK) gibi tekniklerin temelini oluşturur. Faz modülasyonunda, bilgi sinyali taşıyıcı dalganın fazını sürekli olarak değiştirir. Bilgi sinyalinin genliği arttıkça taşıyıcı dalganın fazı kayar ve azaldıkça faz geri döner. Bu, bilgi sinyalinin taşıyıcı dalga üzerinde kodlanmasını sağlar.
- Yayılma: Elektromanyetik dalgalar, elektrik ve manyetik alanların birbirine dik ve dalgalar halinde yayılmasıyla oluşur. Bu dalgalar, boşlukta veya farklı ortamlarda (hava, su, vakum, vb.) yayılabilir. RF (Radyo Frekans) sinyalleri de elektromanyetik dalgalardır ve farklı yollarla iletilebilir. RF sinyallerinin yayılması birkaç farklı yolla gerçekleşebilir:
- Doğrudan Yayılma (Line-of-Sight Propagation): RF sinyalleri, verici ve alıcı arasında doğrudan bir yol izler. Bu tür yayılma genellikle kısa mesafelerde ve engel bulunmayan ortamlarda kullanılır. TV ve radyo vericileri, cep telefonu baz istasyonları buna örnek verilebilir.

- Yer Dalga Yayılması (Ground Wave Propagation): Sinyaller, Dünya yüzeyi boyunca yayılır. Bu yayılma türü, özellikle uzun dalga boylarında (LF ve MF frekansları) etkilidir. AM radyo yayınları bu tür yayılmaya örnektir.
- İyonosferik Yayılma (Sky Wave Propagation): RF sinyalleri, iyonosfer tabakasına çarparak yeryüzüne geri yansır. Bu tür yayılma, özellikle HF (High Frequency) bandında kullanılır ve uzun mesafeli iletişim sağlar.
- Uzay Dalgası Yayılması (Space Wave Propagation): Sinyaller, atmosferin üst katmanları veya boşlukta yayılır. Bu yöntem, uydu iletişiminde yaygındır. GPS, uydu televizyonu bu yöntemle gerçekleşir.

RF sinyallerinin yayılması, verici ile alıcı arasındaki mesafe, ortam koşulları ve kullanılan frekans bandına bağlı olarak değişir.

- Alıcı: Bir alıcı, elektromanyetik dalgaları yakalayan ve bu dalgaları yeniden elektrik sinyallerine dönüştüren bir cihazdır. RF (Radyo Frekans) alıcıları, radyo, televizyon, cep telefonları, Wi-Fi cihazları ve diğer iletişim sistemlerinde kullanılır. Alıcılar, yayılan elektromanyetik dalgaları toplar, sinyali işler ve orijinal bilgi sinyalini elde eder.

Bir RF alıcısının temel çalışma prensibi, yayılan elektromanyetik dalgaları alıp elektrik sinyallerine dönüştürmek, ardından bu sinyalleri demodüle ederek orijinal bilgi sinyalini elde etmektir.

- Demodülasyon: Demodülasyon, bir alıcının aldığı modüle edilmiş sinyalden bilgi sinyalini ayırma işlemidir. Modülasyonun tersi olan bu işlem, taşıyıcı dalga ile taşınan bilginin geri kazanılmasını sağlar. Demodülasyon, iletişim sistemlerinde kritik bir işlemdir çünkü gönderilen bilgi sinyalinin alıcı tarafından doğru bir şekilde yeniden oluşturulmasını sağlar.

Drone’lar, uzaktan kumanda edilmek veya veri iletmek için RF sinyallerini kullanır. Bu sinyaller, Drone’un operatör tarafından kontrol edilmesini ve gerekli bilgilerin yer kontrol istasyonuna iletilmesini sağlar. Ayrıca, drone'ların GPS sistemleri, telemetri verileri ve diğer sensör bilgileri de RF sinyalleri ile iletilir. Drone'ların RF sinyallerini kullanarak tespit ve tanımlama yapması, özellikle güvenlik, gözetim ve hava sahası yönetimi açısından büyük önem taşır.

4. KULLANILAN VERİ SETİ ALGORİTMALAR VE YÖNTEMLER

4.1. Veri Seti

Bu tez çalışmasında, drone tespit ve tanımlama uygulamaları için özel olarak tasarlanmış bir laboratuvar ortamında üretilmiş açık kaynaklı bir veri seti kullanılmaktadır (Allahham et al., 2019). Veri setinin oluşturulması sürecinde, pazarın en yaygın ve popüler drone modellerinden olan Bebop, AR ve Phantom markalı drone'lar tercih edilmiştir. Bu drone'ların, belirli operasyonel özelliklere ve RF sinyal yayılım kapasitelerine sahip olması, bu araştırmada tercih edilmelerini sağlamıştır. Seçilen drone'lar, farklı uçuş modlarında (örneğin, kalkış, iniş, havada sabit kalma ve video kaydı yapma gibi) çeşitli görevleri yerine getirebilme yeteneklerine ve RF sinyallerini farklı koşullar altında yayabilme kapasitesine sahiptir. Bu özellikler, drone'ların tespiti ve tanımlanması için geliştirilen sistemlerin test edilmesi ve doğrulanması açısından son derece değerli veri sağlamaktadır.

Veri toplama sürecinde, drone'ların operasyonel çevresinde özel olarak kurulan RF alıcıları kullanılmıştır. Kullanılan RF alıcıları, National Instruments USRP-2943R yazılım tanımlı radyo cihazlarıdır ve bu cihazlar, 1,2 GHz ile 6 GHz arasında frekans aralığında çalışabilmektedir. Her alıcı, 40 MHz anlık bant genişliğine sahip olup, maksimum 200 MS/s I/Q örnekleme oranı ve 14 bit ADC çözünürlüğü sunmaktadır. Veri toplama sürecinde, iki RF alıcısı, PCIe kabloları aracılığıyla iki dizüstü bilgisayara bağlanmıştır. Bu dizüstü bilgisayarlar, Intel Core i5-520M 2,4 GHz işlemciye ve 4 GB RAM'e sahip olup, Windows 7 64-bit işletim sistemi üzerinde çalışmaktadır.

Drone'ların uçuş modlarını değiştirmek ve RF komutlarını göndermek için uçuş kontrol cihazları ve cep telefonları kullanılmıştır. Drone'ları cep telefonu ile kontrol etmek için, her bir drone markası için özel olarak geliştirilmiş mobil uygulamalar (sırasıyla FreeFlight Pro, AR.FreeFlight ve DJI Go) kullanılmıştır. Bu uygulamalar, ilgili drone'ların kontrolünü sağlamak amacıyla tasarlanmış olup, toplanan RF verileri daha sonra işlenmek ve depolanmak üzere LabVIEW Communications System Design Suite yazılımı ile işlenmiştir.

Tablo 4.1’de görüldüğü üzere toplamda 227 adet RF sinyal segmenti oluşmuştur. Bu segmentler, drone'ların çeşitli operasyonel durumlarında alınmıştır ve her segment, drone'un o anki durumunu yansıtan zengin bilgi setleri içermektedir.

Tablo 4.1. Drone RF veri tabanının her drone tipi için ham örneklerinin ve segmentlerinin sayısı

Drone Tipi	Segment	Örnek sayısı	Oran
Bepop	84	$1{,}680 \times 10^6$	37,00%
AR	81	$1{,}620 \times 10^6$	35,68%
Phantom	21	420×10^6	9,25%
Drone Yok	41	820×10^6	18,06%

Toplanan verilerdeki Radyo Frekans sinyalleri Drone'ların farklı uçuş modlarının bilgilerini içermektedir. Bu uçuş modları:

- Kapalı (Off): Drone’un tamamen kapalı olduğu, hiçbir elektronik aktivitenin olmadığı durumu ifade eder. Bu modda, drone operasyonel değildir.
- Açık (On): Drone’un açık olduğu ancak henüz uçuş moduna geçmemiş olduğu durumu belirtir. Bu durumda, drone enerjilendirilmiştir ve muhtemelen bazı temel fonksiyonları çalıştırabilir ancak hareket hâlinde değildir.
- Bağlı (Connected): Drone’un kontrol cihazı veya uçuş kontrol sistemi ile aktif bir bağlantısının olduğu durumu ifade eder. Bu mod, drone’un komut almak üzere hazır olduğunu ve pilot ile iletişim hâlinde olduğunu gösterir.
- Süzülme (Hovering): Drone’un havada sabit bir yükseklikte durduğu, ileri veya geri bir hareket yapmadan belirli bir noktada asılı kaldığı uçuş modudur
- Uçuş (Flying): Drone’un aktif bir şekilde uçtuğu, hareket ettiği durumu belirtir. Bu mod, drone’un belirlenen bir rota üzerinde veya serbestçe manevra yaparak uçtuğu anlamına gelir.
- Video Kaydı: Drone’un video kaydı yaptığı moddur. Bu durum, drone’un üzerindeki kameraların aktif olduğu ve çevresini kaydettiği anlamına gelir.

Tablo 4.2, drone'ların kapalı (off), açık (on), bağlı (connected), süzülme (hovering), uçuş (flying) ve video kaydı gibi farklı uçuş modlarının örnek sayısı ve oranlarını içermektedir.

Tablo 4.2. Drone RF veri tabanının her drone tipi için uçuş modu, örnek sayısı ve oran bilgileri

Sınıf	Örnek Sayısı (adet)	Oran (%)
Phantom mod 1, bağlı ve açık	420 x 106	9,25
AR mod 4, uçuş ve video kaydı	360 x 106	9,25
AR mod 3, uçuş	420 x 106	9,25
AR mod 2, havada durma	420 x 106	9,25
AR mod 1, bağlı ve açık	420 x 106	9,25
Bebop mod 1, bağlı ve açık	420 x 106	9,25
Bebop mod 2, havada durma	420 x 106	9,25
Bebop mod 3, uçuş	420 x 106	9,25
Bebop mod 4, uçuş ve video kaydı	420 x 106	9,25
Drone yok	820 x 106	18,06

Toplamda 454 RF sinyal kaydı bulunan veri seti, her bir kaydında 1 milyon örnek barındırmaktadır. Ek olarak, veri seti, drone'ların olmadığı durumlarda toplanan arka plan aktivitelerini de içerir; bu durum, gürültünün azaltılmasına ve sınıflandırma ile tespit sonuçlarının doğruluğunun artırılmasına katkı sağlar.

Veri setinin dağılımı göz önüne alındığında, drone kayıtları toplam veri setinin yaklaşık %82'sini oluştururken, kalan %18,06'lık kısım drone içermeyen örneklerden meydana gelmektedir. Bu "drone içermeyen" veriler, çevresel ve arka plan RF aktivitelerini kapsayarak, sistemin gürültüye karşı dayanıklılığını önemli ölçüde artırır. Veri seti, drone'ların tespit edilmesini sağlamakla kalmayıp, aynı zamanda kullanılan drone'ların marka ve tipinin sınıflandırılmasına olanak tanır. Bu özellik, RF sinyallerinin analiz edilmesiyle farklı drone tipleri ve modları arasındaki ayırt edici özelliklerin belirlenmesine imkân verir.

4.2. Makine Öğrenmesi Algoritmaları

Drone'lardan alınan radyo frekans (RF) sinyallerini kullanarak, drone'ların algılanması ve tanımlanması gibi belirli görevleri yerine getirmeyi amaçlayan bu çalışmada gözetimli öğrenme yöntemi kullanılmıştır. Bu yöntemin tercih edilmesinin nedenleri şunlardır:

- Etiketli Veri: RF sinyalleri gibi sensör verileri, belirli etiketlerle (örneğin drone modları veya türleri gibi) işaretlenmiştir, bu da modelin bu etiketlere göre sınıflandırma yapmasını sağlar.
- Yüksek Doğruluk: Gözetimli öğrenme modelleri, eğitim verilerine dayanarak yüksek doğrulukta tahminlerde bulunabilir, bu da güvenlik gibi hassas uygulamalar için önemlidir.
- Özellik Mühendisliği: Gözetimli öğrenme, özellik mühendisliği ve seçimi sayesinde daha karmaşık veri setlerinden önemli bilgiler çıkarmayı mümkün kılar.

Bu tez çalışmasında, veri seti üzerinde K-En Yakın Komşu (K-Neighbors Classifier - KNN), Rastgele Orman (Random Forest Classifier - RF), Destek Vektör Makineleri (Support Vector Machines - SVM), Lojistik Regresyon (Logistic Regression – LR ve Karar Ağacı (Decision Tree Classifier - CART) algoritmaları ile bir ön test gerçekleştirilmiştir. Tablo 4.3'de görüldüğü gibi KNN, RF, CART algoritmaları; ön testte diğerlerine göre daha yüksek doğruluk değeri vermesi, sürekli ve nümerik verilerde kullanıma uygun olması sebebiyle drone algılama, tanımlama ve uçuş modu belirleme işlemleri için tercih edilmiştir.

Tablo 4.3. Ön test sonuçları

Kullanılan Algoritmalar	Ön test Sonuçları (Doğruluk/ Accuracy)
KNN	0,874493
SVM	0,574229
RF	0,849031
CART	0,833304
LR	0,374009

4.2.1. K-En Yakın Komşu (K-Neighbors Classifier - KNN)

Gözetimli öğrenme kategorisinde yer alan ve sınıflandırma görevlerinde kullanılan temel bir yöntemdir. Bu model, bir veri noktasının hangi kategoriye ait olduğunu belirlemek amacıyla, en yakın 'K' komşusunu baz alır ve bu komşuların sınıflarına göre çoğunluk oylama yöntemiyle karar verir (Hastie, Tibshirani, & Friedman, 2009).

KNN algoritması, veri setindeki her bir noktayı temsil eden özellikler arasındaki uzaklıkları hesaplamak için genellikle Öklid mesafesi kullanır.

Euclidean mesafesi, iki nokta arasındaki en kısa düz çizgi mesafesini ölçen bir mesafe metriğidir. Genellikle iki veya daha fazla boyutlu uzaylarda noktalar arasındaki mesafeyi hesaplamak için kullanılır ve geometrik olarak bir hipotenüs uzunluğu olarak düşünülebilir.

İki nokta arasındaki Euclidean mesafesi, noktaların her bir koordinatının farklarının karesinin toplamının karekökü alınarak hesaplanır. Bu, Pisagor teoreminin bir genellemesidir.

İki boyutlu uzayda p = (p1, p2) ve q = (q1, q2) noktaları arasındaki Euclidean mesafesi aşağıdaki formül (4.1) ile hesaplanır:

$$d(p,q) = \sqrt{(q1 - p1)^2 + (q2 - p2)^2} \quad (4.1)$$

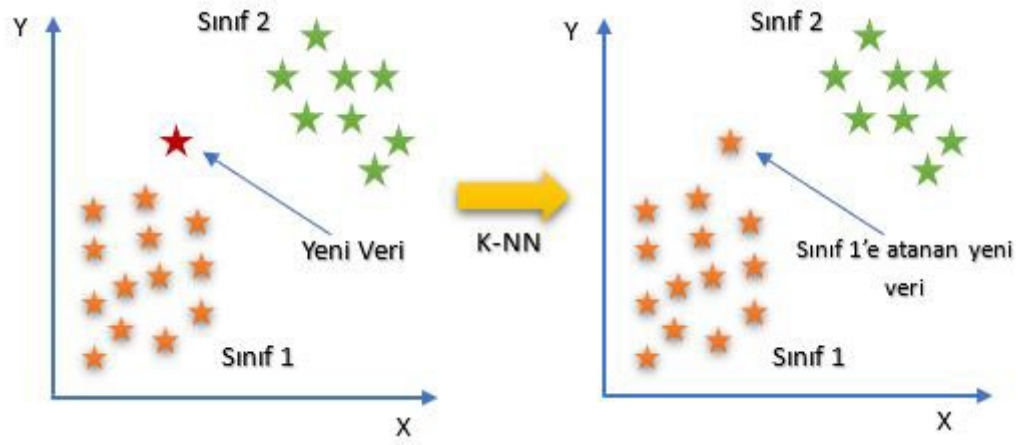
Üç boyutlu uzayda p = (p1, p2, p3) ve q = (q1, q2, q3) noktaları arasındaki Euclidean mesafesi aşağıdaki formül (4.2) ile hesaplanır:

$$d(p,q) = \sqrt{(q1 - p1)^2 + (q2 - p2)^2 + (q3 - p3)^2} \quad (4.2)$$

n boyutlu uzayda p = (p1, p2, ..., pn) ve q = (q1, q2, ..., qn) noktaları arasındaki Euclidean mesafesi (4.3) aşağıdaki şekilde hesaplanır:

$$d(p,q) = \sqrt{(\sum(qi - pi)^2)} \quad (4.3)$$

KNN Algoritması, Şekil 4.1'de olduğu gibi belirlenen bir 'K' sayısı için, sınıflandırılmak üzere olan noktaya en yakın 'K' komşuyu bulur. Bu komşuların hangi sınıflara ait olduğuna bakar ve en sık rastlanan sınıfı yeni noktanın sınıfı olarak atar. Bu yöntem, özellikle küçük ve orta ölçekli veri setleri için etkili ve anlaşılması kolay bir yöntemdir.



Şekil 4.1. K-En Yakın Komşu algoritmasının sınıflandırılması

Makine öğreniminde her algoritmanın avantajları ve dezavantajları vardır. K-En Yakın Komşu (KNN) algoritmasının avantajları şu şekilde sıralanabilir: KNN algoritması oldukça basittir ve anlaması kolaydır; karmaşık parametre ayarlarına veya model eğitimine ihtiyaç duymaz. Eğitim gerektirmeyen bir model olduğu için, tüm işlem tahmin aşamasında gerçekleşir ve bu da eğitim süresi gerektirmediği anlamına gelir. KNN, hem sınıflandırma hem de regresyon problemlerinde esnek bir şekilde kullanılabilir ve çeşitli mesafe ölçütleri (Euclidean, Manhattan, Minkowski) ile çalışabilir. Ayrıca, yeni verilerin modele kolayca eklenmesine olanak tanır; eğitim aşaması olmadığından, yeni veri eklendiğinde modeli yeniden eğitmeye gerek yoktur. KNN algoritması, çok boyutlu verilerle de iyi çalışabilir, özellikle veri seti belirli bir yapıya sahip değilse ve doğrudan örüntülerin tespiti gerekiyorsa etkili olabilir.

Öte yandan, KNN algoritmasının bazı dezavantajları da vardır. Bu algoritma, tüm eğitim verilerini bellekte tuttuğu ve tahmin sırasında tüm veri setini taradığı için büyük veri setlerinde yüksek hafıza tüketimine neden olabilir. Ayrıca, veri setinin büyüklüğü ile doğru orantılı olarak tahmin süresi de uzar, bu da büyük veri setlerinde zaman alıcı olabilir. KNN, özelliklerin ölçeklendirilmiş olmasını gerektirir; özellikler arasında

büyük ölçek farkları varsa, mesafe hesaplamaları yanlış sonuçlar verebilir. Algoritma, gürültülü verilere karşı hassastır ve bu durum komşuluk yapısını bozarak yanlış sınıflandırmalara yol açabilir. Ayrıca, en uygun komşu sayısı olan kkk değerinin belirlenmesi zordur; genellikle çapraz doğrulama ile belirlenir, ancak bu ek bir hesaplama yükü getirir. Son olarak, özellikle çok sayıda özellik veya yüksek boyutlu verilerde KNN'nin performansı düşebilir; bu durumda, boyut indirgeme teknikleri kullanılabilir, ancak bu da ek bir işlem gerektirir.

4.2.2. Rastgele Orman (Random Forest Classifier - RF)

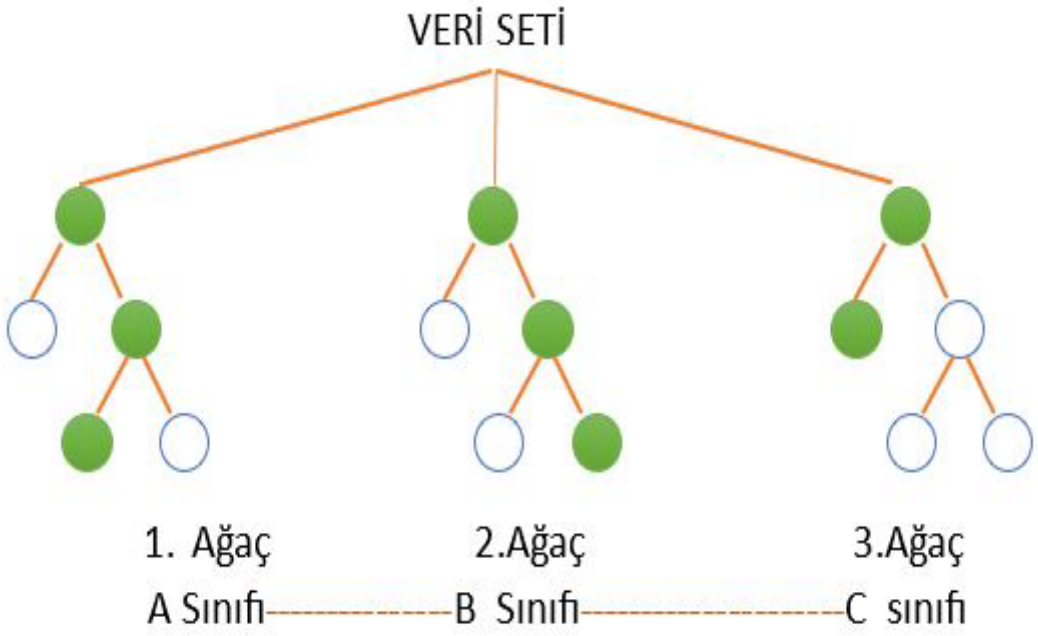
Random Forest Classifier (Rastgele Orman-RF), birçok karar ağacının birleşiminden oluşan bir topluluk öğrenme algoritmasıdır ve sınıflandırma ile regresyon görevlerinde yaygın olarak kullanılır. Bu yöntem, Leo Breiman ve Adele Cutler tarafından geliştirilmiştir ve modelin tahminlerinin doğruluğunu ve kararlılığını artırmak için tasarlanmıştır (Breiman, 2001).

Random Forest, geniş bir uygulama yelpazesine sahiptir. Finans sektöründe kredi riski değerlendirmeleri, biyoenformatikte gen ifade sınıflandırmaları, e-ticarette müşteri tercih analizleri ve tıpta hastalık teşhisi gibi çeşitli alanlarda etkili bir şekilde kullanılmaktadır

Random Forest, birden fazla karar ağacı oluşturarak çalışır ve her bir ağacın tahminini birleştirerek son kararı verir. Bu süreç şu adımları içerir:

- Bootstrap Aggregating (Bagging): Eğitim veri setinden rastgele, tekrarlı örneklem alma işlemi ile birçok alt kümeler oluşturulur. Her bir alt küme, bir karar ağacının eğitim seti olarak kullanılır.
- Karar Ağacı Eğitimi: Her bir alt küme için bir karar ağacı bağımsız olarak eğitilir. Ağaçların her bir düğümünde, rastgele seçilen özellikler alt kümesi üzerinden en iyi bölünme (split) bulunmaya çalışılır. Bu süreç, ağaçların birbirinden farklı olmasını ve overfitting'i azaltmayı sağlar.
- Tahminlerin Birleştirilmesi: Sınıflandırma için, oluşturulan tüm ağaçların tahminleri arasında çoğunluk oyuyla karar verilir; yani en çok tekrarlanan etiket nihai tahmin

olarak belirlenir. Regresyon durumunda ise çıktılar ortalaması alınır. Şekil 4.2'te bu algoritmanın çalışma yapısı görülmektedir.



Şekil 4.2. Rastgele orman algoritmasının sınıflandırılması

Rastgele Orman algoritmasının önemli avantajları arasında aşırı uyumun azaltılması, yüksek doğruluk, özellik öneminin belirlenmesi, gürültülü verilere karşı dayanıklılık ve esneklik bulunur. Karar ağaçlarının aşırı uyum eğilimini azaltarak genel modelin daha iyi genelleme yapmasını sağlayan Rastgele Orman, genellikle tek bir karar ağacından daha yüksek doğruluk sunar. Ayrıca, hangi özelliklerin hedef değişkeni tahmin etmek için daha önemli olduğunu belirlemeye yardımcı olabilir. Hem sınıflandırma hem de regresyon problemlerinde etkili bir şekilde kullanılabilen bu algoritma, gürültülü verilere karşı daha dayanıklıdır ve daha dengeli sonuçlar verir.

Bununla birlikte, Rastgele Orman algoritmasının dezavantajları da vardır. Birden fazla karar ağacının oluşturulması ve tahminlerin birleştirilmesi, özellikle büyük veri setlerinde yüksek hesaplama maliyeti ve bellek kullanımı gerektirebilir. Ayrıca, büyük ormanlarda tahmin yapma süresi yavaş olabilir ve modelin yorumlanabilirliği tek bir karar ağacına kıyasla daha zordur; birçok ağacın topluluğunda verilen kararları izlemek güç olabilir.

4.2.3. Karar Ağacı (Decision Tree Classifier - CART)

Karar Ağacı (CART), hem sınıflandırma hem de regresyon problemleri için kullanılan gözetimli bir öğrenme algoritmasıdır. Bu algoritma, verileri belirli kurallara göre bölerek bir ağaç yapısı oluşturur ve her dal, veriyi daha homojen alt gruplara ayırır. Karar ağacı, verilerin özelliklerine dayalı olarak kararlar alır ve bu kararları hiyerarşik bir yapıda organize eder (Quinlan, 1986).

CART algoritması, veri setini özellik değerlerine göre dallara ayırarak çalışır. Her bir iç düğüm, bir özellik üzerinde bir koşul içerir, her dal ise bu koşulun sonucunu temsil eder. Yaprak düğümler, nihai sınıfları veya değerleri içerir. Karar ağacının çalışma yapısı şu şekildedir:

- Kök Düğüm: Ağaçtaki en üst düğümdür ve veri setinin tamamını temsil eder. Kök düğüm, veri setindeki en iyi bölmeyi sağlayan özellik üzerine kurulur.
- İç Düğümler: Her iç düğüm, veriyi daha homojen alt gruplara ayıran bir bölme kriterine dayanır. Bu bölme, belirli bir özelliğin değeri üzerinden yapılır.
- Yaprak Düğümler: İç düğümlerin bölünemediği son noktalar olup, sınıf etiketlerini veya tahmin değerlerini içerir. Her yaprak düğüm, veri setinin belirli bir bölümünü temsil eder. Şekil 4.3'te bu algoritmanın çalışma yapısı görülmektedir.



Şekil 4.3. Karar Ağacı algoritmasının sınıflandırılması

CART algoritması, Gini indeksini veya bilgi kazancını (entropy) kullanarak veri setini bölmek için en iyi özelliği seçer. Gini indeksi, bir düğümdeki örneklerin saflaşma

derecesini ölçer ve düşük Gini indeksi, daha iyi bölmeyi gösterir. Bilgi kazancı ise, bir düğümdeki bilgi miktarını ölçer ve yüksek bilgi kazancı daha iyi bölmeyi temsil eder.

Karar ağaçları, kredi riski değerlendirme, müşteri segmentasyonu, tıbbi teşhis ve karar destek sistemleri gibi birçok alanda kullanılır. Bu algoritma, özellikle karmaşık karar süreçlerini basit ve anlaşılır kurallara dönüştürmek için idealdir.

Karar ağacı algoritmasının avantajları arasında kolay yorumlanabilirlik, az veri hazırlığı gereksinimi, kategorik ve sayısal verilerle uyumlu olması ve aykırı değerlere ile eksik verilere karşı dayanıklılık bulunur. Karar ağaçları, görsel olarak temsil edilebilir ve insanlar tarafından kolayca anlaşılabilir; hangi özelliklerin nasıl ve ne kadar önemli olduğu açıkça görülebilir. Veri hazırlığı açısından, karar ağaçları genellikle çok az ön işleme ihtiyaç duyar, bu nedenle özellik ölçeklendirmesi veya normalizasyonu gerektirmez. Hem kategorik hem de sayısal verilerle çalışabilen karar ağaçları, aykırı değerler ve eksik verilerden genellikle olumsuz etkilenmez, bu da onları esnek ve dayanıklı bir seçenek haline getirir.

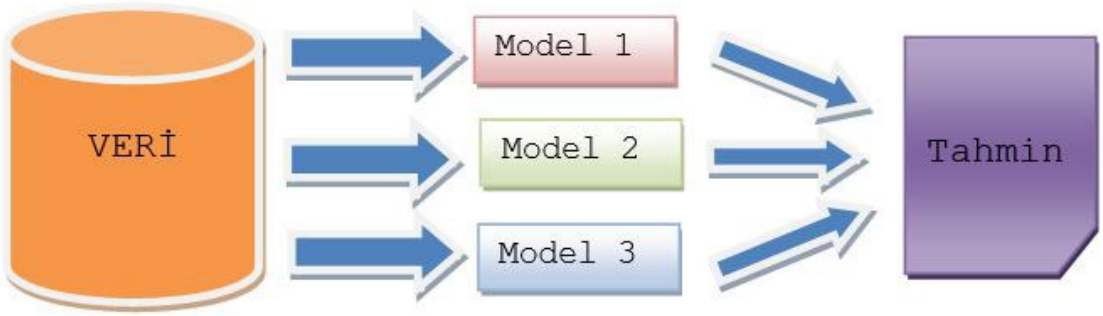
Bununla birlikte, karar ağacı algoritmasının bazı dezavantajları da vardır. En belirgin dezavantajlardan biri aşırı uyum eğilimidir; özellikle derin ağaçlar, eğitim verisine aşırı derecede uyum sağlarken, yeni verilerde düşük performans gösterebilir. Ayrıca, dengesiz veri setlerinde karar ağaçları genellikle düşük performans gösterir, çünkü bir sınıfın diğerlerine göre çok daha fazla sayıda olduğu durumlarda doğru sınıflandırma yapmakta zorlanabilirler. Büyük veri setleri ve çok sayıda özellik ile çalışırken, optimal bölmeleri bulmak için yapılan hesaplamalar maliyetli olabilir. Son olarak, karar ağaçları, veri setindeki küçük değişikliklere karşı hassastır; bu durum, ağacın yapısını önemli ölçüde değiştirebilir ve model kararlılığını olumsuz etkileyebilir. Bu nedenle, veri setindeki küçük değişiklikler büyük farklılıklara yol açabilir.

4.2.4. Topluluk Öğrenmesi (Ensemble Model)

Ensemble model, makine öğreniminde birden fazla modelin birleştirilerek tek bir güçlü model oluşturulmasıdır. Bu yöntem, genellikle farklı algoritmaların veya aynı algoritmanın farklı versiyonlarının çıktılarının bir araya getirilmesiyle elde edilir. Amaç, her bir modelin güçlü yönlerinden faydalanarak daha doğru ve kararlı tahminler veya

sınıflandırmalar yapmaktır. Ensemble yöntemleri, özellikle tek bir modelin performansının yetersiz olduğu durumlarda kullanılır (Dietterich, 2000).

Ensemble modelleri, birden fazla modelin çıktısını birleştirerek genellikle tek bir modelin sağlayabileceğinden daha iyi bir performans sunar. Şekil 4.4'te bu algoritmanın çalışma yapısı gösterilmektedir.



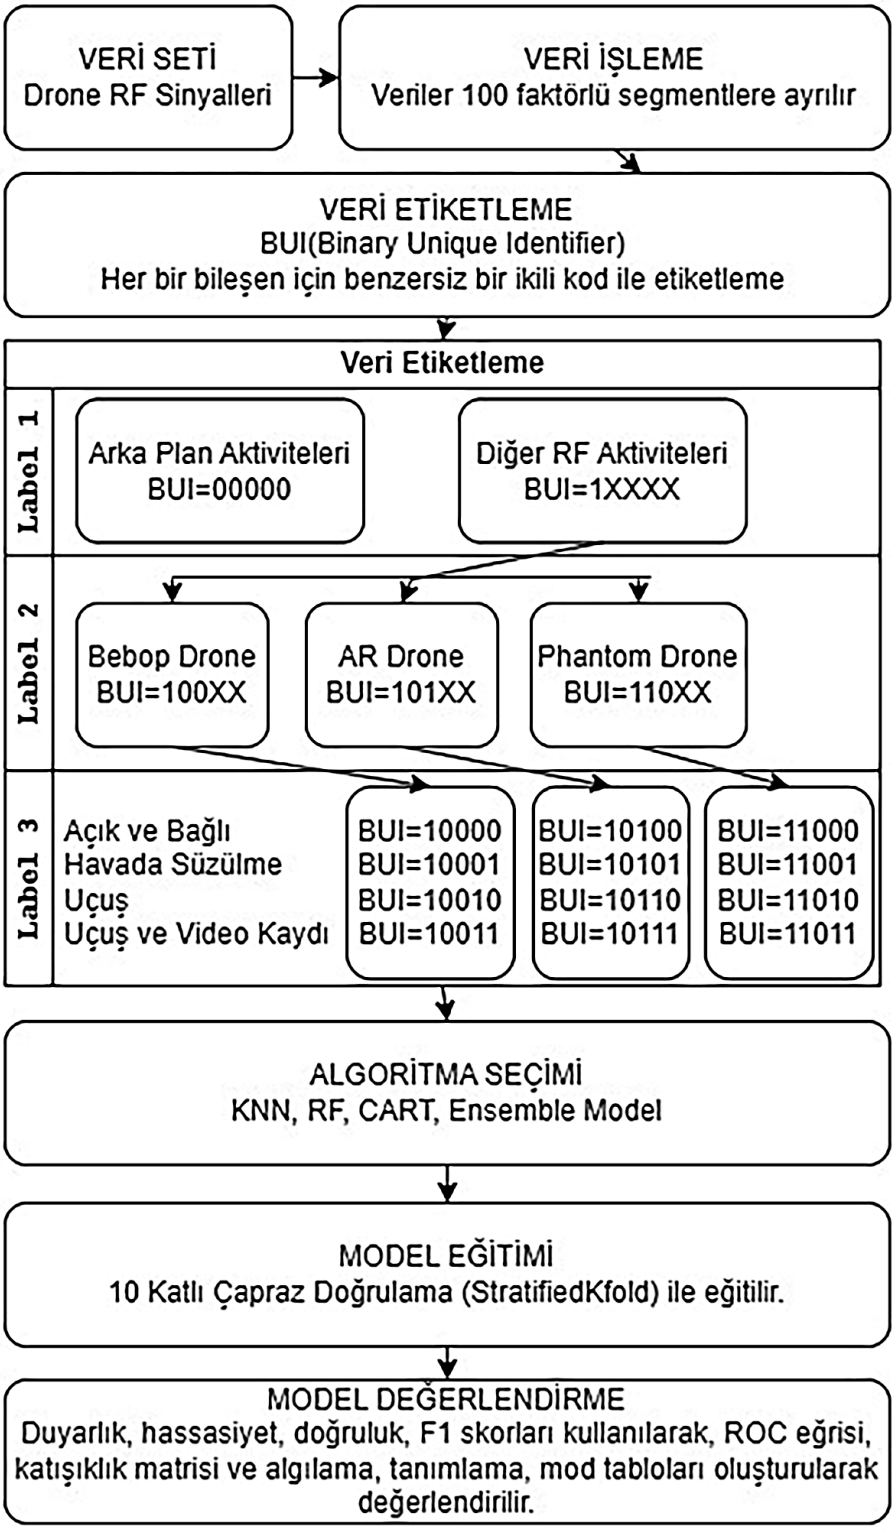
Şekil 4.4. Ensemble model çalışma yapısı

Bu yöntem, farklı modellerin hatalarını telafi edebilir ve bu sayede daha yüksek doğruluk oranları elde edilebilir. Ayrıca, Ensemble modelleri aşırı uyuma (overfitting) karşı daha dayanıklıdır. Tek bir model, özellikle eğitim verilerine çok iyi uyum sağlayarak aşırı uyum riski oluşturabilirken, Ensemble yöntemleri bu riski azaltarak daha iyi genelleme yapma yeteneği sunar. Farklı modellerin çıktılarının birleştirilmesiyle, veri setindeki küçük değişiklikler sonuçları fazla etkilemez, bu da modelin daha kararlı ve güvenilir tahminler yapmasını sağlar. Ek olarak, Ensemble modeller, farklı algoritmaların kombinasyonuyla çeşitli veri türleri ve problemler üzerinde esnek çözümler sunabilir.

Bununla birlikte, Ensemble modellerinin bazı dezavantajları da vardır. Öncelikle, bu modellerin eğitilmesi ve çalıştırılması genellikle daha yüksek hesaplama gücü ve zaman gerektirir, bu da büyük veri setleri ve karmaşık modellerle çalışırken önemli bir dezavantaj olabilir. Birden fazla modelin birleştirilmesi, modelin yapısını ve yorumlanmasını zorlaştırabilir. Tek bir karar ağacı gibi basit modeller genellikle daha anlaşılırken, Ensemble modelleri genellikle "kara kutu" olarak nitelendirilir ve sonuçların açıklanmasını zorlaştırabilir. Ayrıca, bazı Ensemble teknikleri, özellikle boost yöntemleri, yanlış örnekleri aşırı düzeltmeye çalışarak aşırı uyum riski taşıyabilir.

4.3. Kullanılan Yöntemler

Drone tespit, tanımla ve uçuş modu süreci Şekil 4.5'teki akış diyagramına göre gerçekleştirilmiştir.



Şekil 4.5. Drone algılama tanımlama ve uçuş modu belirleme akış diyagramı

Veri seti, 100 faktörlü 2048 örnekli segmentlere bölünerek her segment daha detaylı ve spesifik özelliklere sahip hale getirilmiştir. Böylelikle sınıflar arası dengesizlik azaltılmıştır. Ayrıca her segment farklı veri özelliklerine sahip olduğundan, modelin farklı durumlar ve varyasyonlar üzerinde eğitilmesi sağlanmış ve modelin gerçek dünya verilerine karşı daha dayanıklı olması sağlanmaya çalışılmıştır.

Daha sonra, modelin performansını artırmak ve farklı özelliklerin aynı ölçek üzerinde karşılaştırılabilir olmasını sağlamak amacıyla, veriler Min-Max Normalizasyonu uygulanarak 0 ile 1 aralığına dönüştürülmüştür. Bu işlem, her bir özelliğin değerlerini, minimum ve maksimum değerleri arasındaki farkı kullanarak ölçeklendirmeyi içerir. Böylece, veri setindeki özellikler, birbiriyle kıyaslanabilir hale getirilmiş ve modelin daha tutarlı öğrenme yapması için uygun bir veri yapısı oluşturulmuştur. Min-Max Scaler yöntemi, özellikle özelliklerin farklı ölçeklerde olduğu durumlarda modelin ağırlık güncelleme işlemlerinin dengeli olmasını sağlar ve öğrenme sürecini optimize eder.

Normalizasyon işleminden sonra, tüm drone türleri ve ilgili aktiviteler birleştirilmiş ve bu veriler üzerinde Benzersiz İkili Kod Tanımlayıcı (BUI - Binary Unique Identifier) ile Label (etiket) matrisi oluşturulmuştur. Bu işlem, veri setinde her bir satırı farklı bir etiketleme stratejisiyle temsil ederek, modelin çeşitli sınıflandırma görevlerini yerine getirmesini sağlar. Etiketleme stratejileri, veri setinin farklı kategorilerde ayrılmasını ve bu kategoriler üzerinde öğrenme sürecinin gerçekleştirilmesini kolaylaştırır.

Oluşturulan Label matrisi, her bir satırında belirli bir sınıflandırma görevine uygun olarak veri setinin farklı bölümlerini etiketler. Label 1, veri setinde RF arka plan aktivitelerini "0" olarak etiketlerken, diğer tüm drone aktivitelerini "1" olarak etiketler, bu da ikili sınıflandırma için uygun bir yapı sağlar. Label 2, Bebop, AR ve Phantom drone türlerini birbirinden ayırt eden bir etiketleme stratejisi ile çalışır ve bu drone türlerinin aktivitelerini ayrı ayrı etiketler. Label 3 ise daha detaylı bir etiketleme stratejisi benimseyerek, drone'ların uçuş modlarını ve bu modlardaki aktivitelerini etiketler. Bu katmanlı etiketleme yaklaşımı, modelin farklı sınıflandırma görevlerinde esnek bir şekilde kullanılmasına olanak tanır.

Daha sonra, seçilen makine öğrenimi algoritmalarının eğitimi için veri seti, StratifiedKFold yöntemi ile %10 test ve %90 eğitim seti olacak şekilde bölünmüştür. StratifiedKFold, özellikle sınıflar arasındaki dengesizliklerin olduğu veri setlerinde, her bir katmanda sınıf oranlarını koruyarak modelin daha dengeli ve genellenebilir bir performans sergilemesini sağlar. Bu yöntem, veri setini 10 farklı alt bölüme (fold) ayırır ve her bir fold, sırasıyla modelin doğruluğunu test etmek için kullanılırken, diğer 9 fold modelin eğitimi için kullanılır. Bu çapraz doğrulama stratejisi, modelin genelleme yeteneğini artırır ve model performansının değerlendirilmesinde daha güvenilir sonuçlar elde edilmesini sağlar. Bu çalışmada, sonuçların tekrarlanabilirliğini sağlamak ve rastgelelikten kaynaklanabilecek varyasyonları kontrol etmek amacıyla, random_state=6 parametresi kullanılmıştır. Bu, modelin eğitim sürecindeki rastgele işlemleri sabitleyerek, aynı işlemler tekrarlandığında aynı sonuçların elde edilmesine olanak tanır.

Veri seti bu şekilde hazırlandıktan sonra, K-En Yakın Komşu (KNN), Rastgele Orman (RF) ve Karar Ağacı (CART) algoritmaları kullanılarak modeller ayrı ayrı eğitilmiştir. Bu modellerin performansı bağımsız olarak değerlendirilmiştir. Ancak, özellikle uçuş modlarının tahmininde daha yüksek bir doğruluk oranı elde etmek amacıyla, aynı veri seti, KNN, RF ve Gradient Boosting (GB) algoritmalarının bir araya getirildiği bir Ensemble Model ile de eğitilmiştir. Ensemble model, Voting Classifier kullanılarak yapılandırılmış olup, bu modellerin çıktıları 'soft voting' yöntemi ile birleştirilmiştir. Soft voting yöntemi, her bir modelin tahmin ettiği olasılıkları toplar ve en yüksek ortalama olasılığa sahip olan sınıfı nihai tahmin olarak seçer. Bu yaklaşım, tekil modellerin güçlü yönlerini birleştirerek modelin genel doğruluğunu artırabilir ve özellikle zorlayıcı sınıflandırma görevlerinde, daha dengeli ve güvenilir tahminler yapılmasına olanak tanır.

Çalışmada kullanılan 10 katlı çapraz doğrulama yöntemi, model performansının farklı metrikler üzerinden ortalamasını alarak daha kesin bir değerlendirme yapılmasını mümkün kılar. Bu süreçte, her bir modelin doğruluk, hassasiyet, geri çağırma ve F1-skoru gibi performans metrikleri hesaplanır ve bu metriklerin ortalamaları, modelin genel performansını objektif bir şekilde yansıtacak şekilde değerlendirilir.

Ayrıca, model performansını daha da iyileştirmek amacıyla hiperparametre optimizasyonu gerçekleştirilmiştir. Hiperparametre optimizasyonu, Grid Search (Izgara Araması) yöntemi kullanılarak yapılmış ve bu süreçte her bir model için farklı hiperparametre kombinasyonları test edilmiştir. Grid Search, belirlenen hiperparametreler için tüm olası kombinasyonları deneyerek en iyi performansı sağlayan hiperparametre setini seçer. Bu işlem, modelin performansını optimize ederken, aşırı uyum riskini minimize eder ve böylece modelin yeni veriler üzerinde daha iyi genelleme yapmasını sağlar. Bu kapsamlı optimizasyon süreci, nihai modelin elde edilen veri seti üzerinde en yüksek doğruluğa ve en iyi genelleme yeteneğine sahip olmasını garanti altına alır.

Model eğitiminden elde edilen metrikler ile oluşturulan katışıklık matrisi (confusion matrix), ROC (Receiver Operating Characteristic) eğrisi ve ilgili tablolar, modellerin performansını değerlendirmek için kullanılmıştır. Katışıklık matrisi, sınıflandırma problemlerinde modelin doğruluk ve hata oranlarını analiz etmek için kritik bir araçtır. Bu matris, modelin doğru ve yanlış sınıflandırmalarını dört ana kategoride sunar: Gerçek pozitifler (True Positives), gerçek negatifler (True Negatives), yanlış pozitifler (False Positives) ve yanlış negatifler (False Negatives) (Fawcett, 2006).

ROC eğrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan grafiksel bir araçtır. Bu eğri, modelin doğru pozitif oranını (True Positive Rate) ve yanlış pozitif oranını (False Positive Rate) farklı eşik değerlerinde karşılaştırarak çizer (Kohavi & Provost, 1998). ROC eğrisinin altında kalan alan (AUC - Area Under the Curve), modelin genel performansını değerlendirmek için kullanılır. AUC değeri 0.5 ile 1 arasında değişir; 1'e ne kadar yakınsa modelin performansı o kadar iyidir.

5. TEST SONUÇLARI VE BULGULAR

Bu çalışmada, drone'ların tespiti ve tanımlanmasında kullanılan makine öğrenimi modellerinin performansını değerlendirmek için dört temel metrik kullanılmıştır: duyarlılık (recall), hassasiyet (precision), doğruluk (accuracy) ve F1 skoru.

Duyarlılık (Recall): Modelin gerçek pozitif örnekleri doğru bir şekilde tanımlama yeteneğini ölçer. Başka bir deyişle, modelin gerçekte pozitif olan verileri ne kadar iyi tespit ettiğini gösterir. Bu metrik, yanlış negatif sonuçların maliyetinin yüksek olduğu durumlarda özellikle önemlidir.

Kesinlik (Precision): Pozitif olarak tahmin edilen örnekler arasında gerçekten pozitif olanların oranını gösterir. Bu metrik, modelin pozitif tahminlerinin ne kadar doğru olduğunu ölçer ve yanlış pozitif sonuçların maliyetinin yüksek olduğu durumlarda kritik bir öneme sahiptir.

Doğruluk (Accuracy): Modelin genel performansını yansıtan bu metrik, tüm tahminlerin ne kadarının doğru olduğunu ölçer. Ancak, veri setinde sınıf dengesizliği varsa doğruluk metriği yanıltıcı olabilir.

F1 Skoru: Hassasiyet ve duyarlılığın harmonik ortalamasını alarak bu iki metriğin dengeli bir kombinasyonunu sağlar. F1 skoru, özellikle hem yanlış pozitiflerin hem de yanlış negatiflerin önem taşıdığı durumlarda kullanışlıdır ve modelin genel performansını değerlendirmek için ideal bir ölçüttür.

Bu metrikler, drone tespiti ve tanımlama görevlerinde kullanılan makine öğrenimi algoritmalarının performansını daha kapsamlı bir şekilde değerlendirmek için makro (macro) ve ağırlıklı (weighted) olarak da hesaplanmıştır. Makro metrikler, tüm sınıfların performansını eşit ağırlıkla değerlendirirken; ağırlıklı metrikler, sınıf dengesizliklerini dikkate alarak her sınıfın performansını veri setindeki örnek sayısına göre ağırlıklandırır.

Veri seti eğitimi sonucunda her bir algoritmanın drone algılama (var/yok), drone tanımlama (marka ve model) ve drone'un uçuş modunu belirleme (açık, kapalı, havada

süzülme, video veya bağlı) işlemleri için elde edilen değerlendirme metrikleri Tablo 5.1, Tablo 5.2 ve Tablo 5.3'te verilmiştir.

Tablo 5.1. Tüm algoritmaların drone algılama metrik değerleri

	Accuracy	Precision Macro	Recall Macro	F1 Makro	Precision Weighted	Recall Weighted	F1 Weighted
KNN	0,995	0,995	0,989	0,992	0,995	0,995	0,995
RF	0,999	0,998	0,999	0,998	0,999	0,999	0,999
CART	0,998	0,997	0,996	0,997	0,998	0,998	0,998
Ensemble Model	1,000	1,000	0,999	0,999	1,000	1,000	1,000

Tablo 5.2. Tüm algoritmaların drone tanımlama metrik değerleri

	Accuracy	Precision Macro	Recall Macro	F1 Makro	Precision Weighted	Recall Weighted	F1 Weighted
KNN	0,875	0,885	0,903	0,889	0,886	0,875	0,875
RF	0,848	0,907	0,789	0,817	0,878	0,848	0,843
CART	0,834	0,878	0,778	0,803	0,857	0,834	0,829
Ensemble Model	0,858	0,916	0,804	0,832	0,886	0,858	0,854

Tablo 5.3. Tüm algoritmaların drone modu tanımlama metrik değerleri

	Accuracy	Precision Macro	Recall Macro	F1 Makro	Precision Weighted	Recall Weighted	F1 Weighted
KNN	0,458	0,457	0,414	0,361	0,506	0,458	0,415
RF	0,517	0,598	0,476	0,457	0,630	0,517	0,500
CART	0,473	0,521	0,427	0,407	0,560	0,473	0,454
Ensemble Model	0,480	0,496	0,437	0,383	0,543	0,480	0,436

5.1. Drone Algılama

Drone algılama, drone içeren RF arka plan aktivitelerini ve drone RF iletişimini temsil eden iki sınıflı deneydir. Bu deney drone var mı yok mu tespiti yapar.

Tablo 5.4'te bulunan katışıklık matrisi sonuçlarına göre KNN algoritması; %97,90 doğruluk oranıyla doğru pozitifleri, %99,87 doğruluk oranıyla doğru negatifleri tanımlamaktadır.

Bu değerler, modelin hem pozitif hem de negatif sınıfların belirlenmesinde yüksek bir doğruluğa sahip olduğunu göstermektedir. Bu sonuçlar, modelin drone algılama görevinde güvenilir ve etkili bir performans sergilediğini ortaya koymaktadır.

Tablo 5.4. İki sınıflı KNN algoritması katışıklık matris tablosu

		TAHMİN SINIFI	
		RF Arka Plan	**RF Aktivitesi**
GERÇEK SINIF	**RF Arka Plan**	97,90%	2,10%
	RF Aktivitesi	0,13%	99,87%

Tablo 5.5'te bulunan RF algoritmasının katışıklık matrisi değerleri incelendiğinde, modelin doğru pozitiflerde %99,73 ve doğru negatiflerde %99,89 doğruluk oranlarına sahip olduğu görülmektedir. Bu da, modelin gerçek pozitifleri kaçırma olasılığının düşük olduğunu göstermektedir.

Tablo 5.5. İki sınıflı RF algoritması katışıklık matris tablosu

		TAHMİN SINIFI	
		RF Arka Plan	**RF Aktivitesi**
GERÇEK SINIF	**RF Arka Plan**	99,73%	0,27%
	RF Aktivitesi	0,11%	99,89%

Tablo 5.6'da görüldüğü üzere, CART algoritması doğru pozitiflerde %99,34 ve doğru negatiflerde %99,92 doğruluk oranlarına sahiptir. Bu değerler, modelin genel doğrulukta %99,63 olduğunu ve drone algılamada oldukça yüksek bir başarıya sahip olduğunu göstermektedir. Model, düşük hata oranlarıyla ve yüksek hassasiyetle genel olarak güvenilir ve etkili bir performans ortaya koymaktadır.

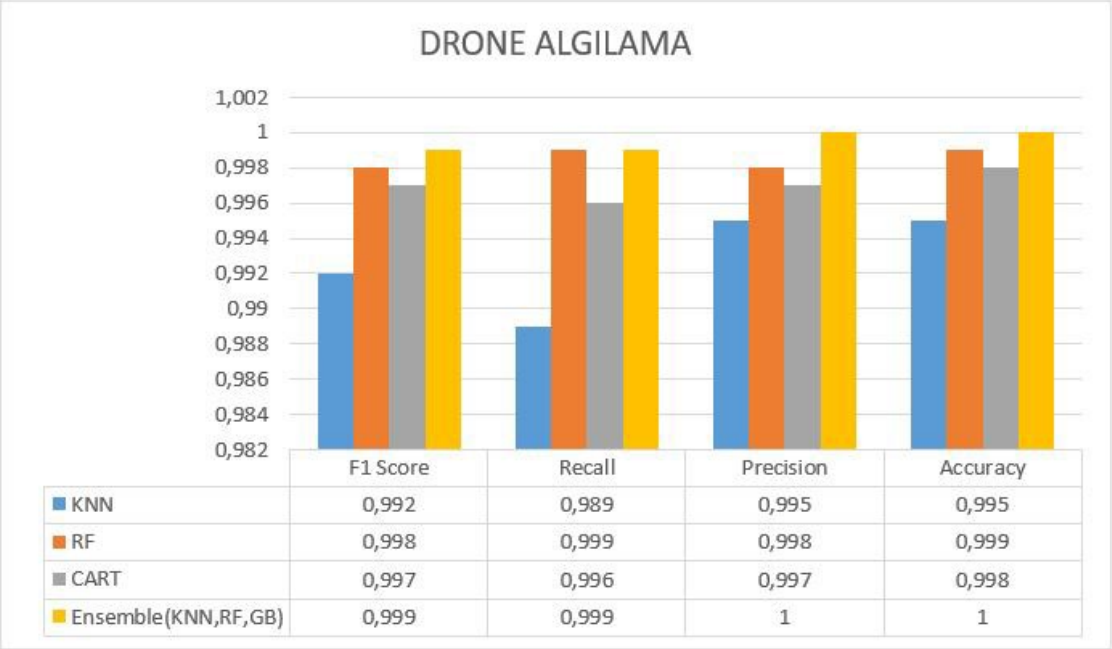
Tablo 5.6. İki sınıflı CART algoritması katışıklık matris tablosu

		TAHMİN SINIFI	
		RF Arka Plan	**RF Aktivitesi**
GERÇEK SINIF	**RF Arka Plan**	99,34%	0,66%
	RF Aktivitesi	0,08%	99,92%

Tablo 5.7'de görüldüğü üzere, Ensemble model doğru pozitiflerde %99,99 ve doğru negatiflerde %99,78 doğruluk oranlarına sahiptir. Bu değerler, modelin genel doğrulukta %99,89 olduğunu ve drone algılama görevinde son derece yüksek bir başarıya sahip olduğunu göstermektedir. Model, düşük hata oranlarıyla ve yüksek hassasiyetle çalışarak, drone algılama konusunda güvenilir ve etkili bir performans sergilemektedir. Hem yanlış pozitiflerin hem de yanlış negatiflerin son derece düşük seviyelerde olması, modelin drone olan ve olmayan durumları neredeyse kusursuz bir şekilde ayırt edebildiğini ortaya koymaktadır.

Tablo 5.7. İki sınıflı Ensemble model katışıklık matris tablosu

		TAHMİN SINIFI	
		RF Arka Plan	**RF Aktivitesi**
GERÇEK SINIF	**RF Arka Plan**	99,78%	0,22%
	RF Aktivitesi	0,01%	99,99%



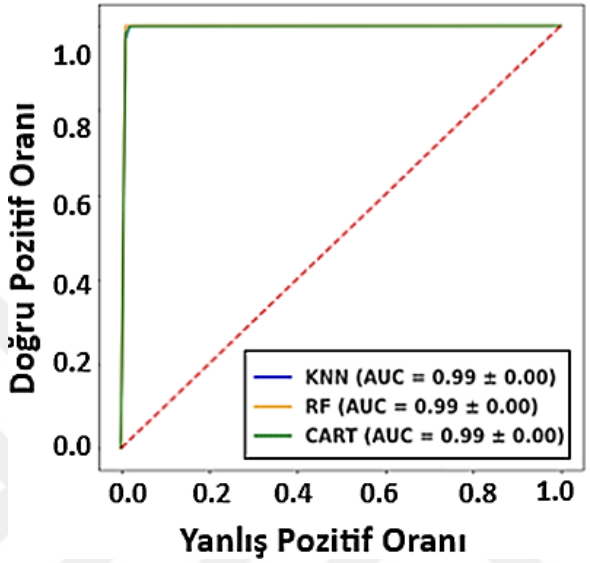
	F1 Score	Recall	Precision	Accuracy
KNN	0,992	0,989	0,995	0,995
RF	0,998	0,999	0,998	0,999
CART	0,997	0,996	0,997	0,998
Ensemble(KNN,RF,GB)	0,999	0,999	1	1

Şekil 5.1. Tüm algoritmaların drone algılama sonuçları

Şekil 5.1'de Tüm algoritmaların drone algılama performansları verilmiştir. Buna göre, Ensemble modeli (KNN, RF, GB) tüm metriklerde en yüksek performansı göstererek, diğer algoritmaların güçlü yanlarını birleştirmesi sayesinde en etkili sonuçları elde etmiştir. Bu sonuçlar, modelin drone algılama görevinde diğer algoritmalardan daha üstün bir performans sunduğunu göstermektedir. Ensemble modelinin F1 skoru, recall, precision ve accuracy gibi metriklerde üstünlük sağlaması, modelin hem doğru pozitifleri hem de doğru negatifleri başarıyla tespit ettiğini ve genel doğruluğunun çok yüksek olduğunu ortaya koymaktadır.

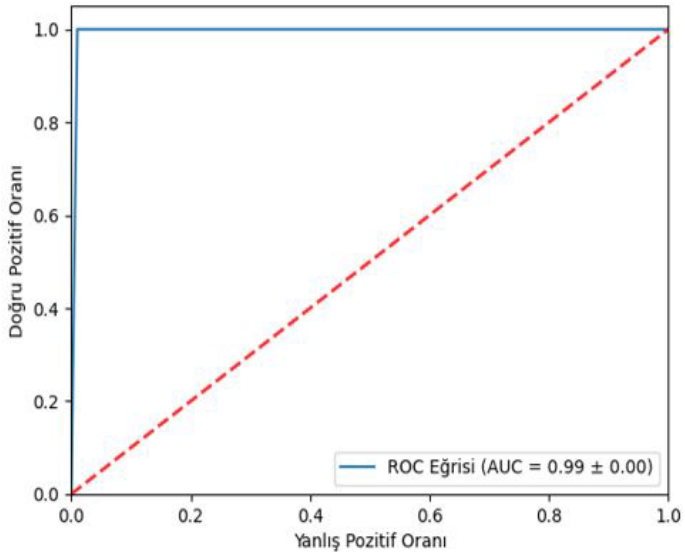
Diğer yandan, KNN, RF ve CART algoritmaları da oldukça iyi performans sergilemiştir. KNN, özellikle precision metriğinde güçlü sonuçlar elde etmiş ve doğru pozitif tahminlerde başarılı olduğunu göstermiştir. RF modeli, recall ve precision metriklerinde yüksek puanlarla dikkat çekmiş, pozitif örnekleri doğru şekilde tanımlamada başarılı olduğunu kanıtlamıştır. CART algoritması ise recall ve accuracy metriklerinde iyi sonuçlar elde ederek, drone algılama görevinde güvenilir bir performans sergilemiştir. Ancak, genel olarak tüm bu algoritmalar arasında Ensemble modelinin en yüksek performansı sunduğu, çeşitli algoritmaların güçlü yönlerini bir araya getirerek drone algılama görevinde en başarılı sonuçları sağladığı görülmektedir.

Drone algılama deneyinin ROC eğrileri RF, CART ve KNN algoritmaları için ayrı, RF, KNN ve GB algoritmalarının birlikte kullanılmasıyla oluşturulan Ensemble model için ayrı çizilmiş ve değerlendirilmiştir. Şekil 5.2'de görülen ROC eğrisi grafiğine göre; algoritmaların her biri AUC = 0,99 ± 0.00 değerine sahiptir. Bu değerler, algoritmaların oldukça yüksek performansa sahip olduğunu göstermektedir.



Şekil 5.2. Drone algılama RF, CART ve KNN ROC eğrisi

Şekil 5.3'te görüldüğü üzere Ensemble modelde çok yüksek AUC değerine sahiptir ve drone algılamada çok iyi performans göstermiştir.



Şekil 5.3. Drone algılama Ensemble model ROC eğrisi

5.2. Drone Tanımlama

Drone tanımlama işlemi dört sınıftan oluşan drone'ların marka modellerini tespit etmeye çalışan çok sınıflı bir deneydir. Birinci sınıf RF arka plan aktivitelerini temsil ederken, iki, üç ve dördüncü sınıflar sırasıyla Bebop, AR ve Phantom drone'larının RF iletişim sinyallerini temsil etmektedir.

Tablo 5.8'de görülen KNN algoritmasının drone tanımlama matrisine göre algoritmanın genel olarak yüksek doğruluğa sahip olduğu, Bebop ve Phantom drone'ları çok iyi tanımladığı; ancak AR marka için daha fazla yanlış tanımlama yaptığı görülmektedir. Bu sonuçlar, algoritmanın genel olarak iyi bir performans sergilediğini; ama belirli sınıflar arasındaki ayrımı yapmada bazı zorluklar yaşadığını göstermektedir.

Tablo 5.8. Dört sınıflı KNN algoritması katışıklık matris tablosu

		TAHMİN SINIFI			
		RF Arkaplan	**Bebop**	**AR**	**Phantom**
GERÇEK SINIF	**RF Arkaplan**	98,29%	0,27%	1,02%	0,41%
	Bebop	0,10%	91,60%	2,74%	5,57%
	AR	0,15%	23,88%	75,94%	0,04%
	Phantom	0,67%	1,76%	2,33%	95,24%

RF algoritmasının Tablo 5.9'da bulunan matris değerleri incelendiğinde, RF'nin genel olarak yüksek doğruluğa sahip olduğu, Bebop drone'u yüksek doğrulukla tanımladığı; ancak AR ve Phantom drone'larda yanlış tanımlama yaptığı görülmektedir.

Tablo 5.9. Dört sınıflı RF algoritması katışıklık matris tablosu

		TAHMİN SINIFI			
		RF Arkaplan	**Bebop**	**AR**	**Phantom**
GERÇEK SINIF	**RF Arkaplan**	99,83%	0,17%	0,00%	0,00%
	Bebop	0,05%	96,61%	2,74%	0,61%
	AR	0,00%	24,20%	75,79%	0,01%
	Phantom	0,81%	55,38%	0,38%	43,43%

Tablo 5.10 CART algoritması katışıklık matrisi sonuçlarına göre de algoritmanın genel olarak yüksek doğruluğa sahip olduğu; ancak AR ve Phantom markalarında daha fazla yanlış tahmin yaptığı görülmektedir.

Tablo 5.10. Dört sınıflı CART algoritması katışıklık matris tablosu

		TAHMİN SINIFI			
		RF Arkaplan	**Bebop**	**AR**	**Phantom**
GERÇEK SINIF	**RF Arkaplan**	99,56%	0,15%	0,10%	0,20%
	Bebop	0,10%	93,39%	5,30%	1,21%
	AR	0,04%	25,02%	74,77%	0,17%
	Phantom	0,14%	56,71%	0,52%	42,62%

Tablo 5.11'de görüldüğü gibi Ensemble model drone marka ve model tanımlama görevinde genel olarak iyi bir performans sergilemiştir. Özellikle Bebop marka drone tanımlamada Ensemble model diğer algoritmalardan daha iyi performans göstermiştir Ancak model bazı sınıflar arasında, özellikle Phantom ve Bebop sınıfları ile AR ve Bebop sınıflarını ayırmada belirgin bir karışıklık yaşamıştır.

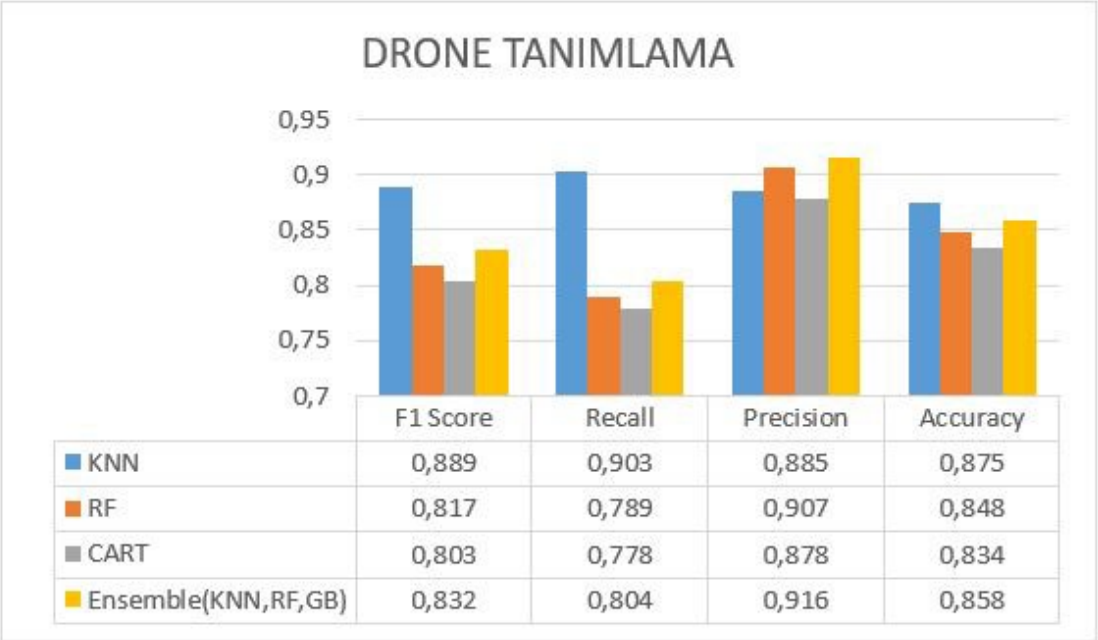
Tablo 5.11. Dört sınıflı Ensemble model katışıklık matris tablosu

		TAHMİN SINIFI			
		RF Arkaplan	**Bebop**	**AR**	**Phantom**
GERÇEK SINIF	**RF Arkaplan**	99,93%	0,05%	0,02%	0,00%
	Bebop	0,01%	97,20%	2,35%	0,44%
	AR	0,00%	23,14%	76,85%	0,01%
	Phantom	0,00%	52,43%	0,57%	46,95%

Tüm algoritmaların drone tanımlama performanslarını gösteren

Şekil 5.4'e göre; KNN, drone tanımlama görevinde tüm metriklerde en yüksek veya ikinci en yüksek performansı göstererek en başarılı model olarak öne çıkmaktadır. Bu model, özellikle duyarlılık ve doğruluk açısından dengeli bir performans sergilemiş, pozitif örnekleri doğru bir şekilde tanımlamada oldukça başarılı olmuştur. Ensemble model ise genel olarak yüksek performans göstermiş ve özellikle hassasiyet açısından

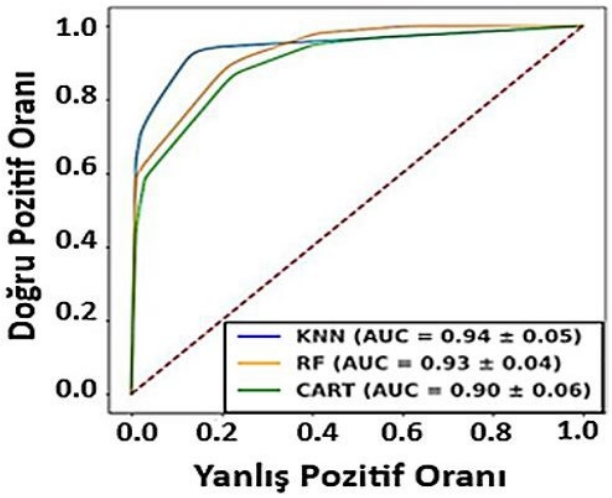
en iyi sonuçları vermiştir. Bu, modelin yanlış pozitiflerden kaçınmada başarılı olduğunu ve genel olarak doğru tahminler yapabildiğini göstermektedir.



	F1 Score	Recall	Precision	Accuracy
KNN	0,889	0,903	0,885	0,875
RF	0,817	0,789	0,907	0,848
CART	0,803	0,778	0,878	0,834
Ensemble(KNN,RF,GB)	0,832	0,804	0,916	0,858

Şekil 5.4. Tüm algoritmaların drone tanımlama sonuçları

RF ve CART ise genellikle KNN ve Ensemble modelden daha düşük performans sergilemiştir. Ancak bu modeller de belirli metriklerde oldukça iyi sonuçlar elde etmişlerdir. Genel olarak bu sonuçlar, KNN ve Ensemble modelin drone tanımlama görevinde etkili olduğunu ve farklı metriklerde dengeli bir performans sunduğunu ortaya koymaktadır.

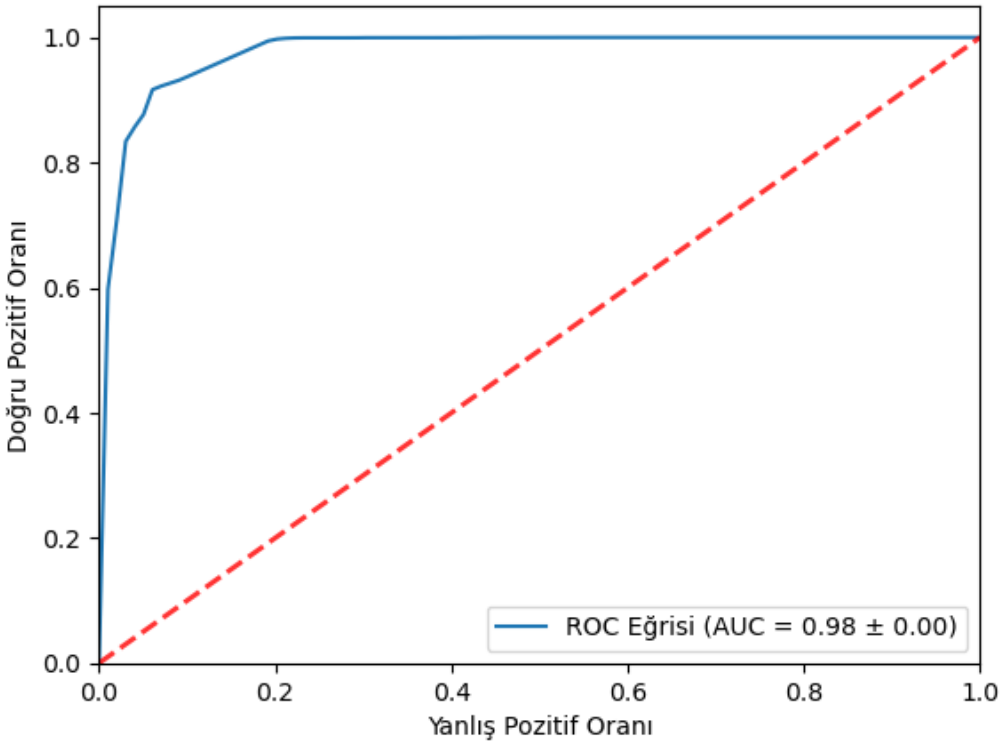


Şekil 5.5. Drone tanımlama RF, CART ve KNN ROC eğrisi

Drone tanımlama için Şekil 5.5'te bulunan ROC eğrisi grafiğine göre, KNN modeli, 0,94 ± 0,05 AUC değeri ile en yüksek performansı sergilemektedir. Bu, KNN modelinin pozitif sınıfları ayırt etmede oldukça başarılı olduğunu ve genel olarak yüksek bir doğruluğa sahip olduğunu gösterir.

RF ise 0,93 ± 0,04 AUC değeri ile KNN'ye çok yakın bir performans sergilemekte, doğru pozitif oranını yüksek tutarken yanlış pozitif oranını düşük seviyede tutabilmektedir. CART ise 0,90 ± 0,06 AUC değeri ile diğer iki modele göre biraz daha düşük bir performans sergilemektedir; ancak genel olarak yine de iyi bir doğruluk sunmaktadır.

Genel olarak, tüm algoritmalar oldukça yüksek performans göstermektedir, ancak KNN ve RF modelleri, doğru ve yanlış pozitif oranlarını dengelemede CART'a kıyasla daha üstün bir performans sergilemektedir.



Şekil 5.6. Drone tanımlama ensemble model ROC eğrisi

Şekil 5.6'da görüldüğü gibi ROC eğrisinin AUC değeri 0,98 ± 0,00 olarak hesaplanmıştır, bu da Ensemble modelin sınıfları ayırt etme yeteneğinin son derece yüksek olduğunu gösterir. Eğrinin şekli, modelin doğru pozitif oranını neredeyse

maksimum seviyeye çıkarırken yanlış pozitif oranını minimumda tuttuğunu ortaya koymaktadır.

Bu sonuçlar, Ensemble modelin drone tanımlama görevinde son derece etkili bir performans sergilediğini ve sınıfları neredeyse çok iyi bir doğrulukla ayırt ettiğini göstermektedir.

5.3. Drone Modu Tanımlama

Drone modu tanımlama işlemi; drone'un açık olup olmadığı, bağlı olup olmadığı, uçuş modunda olup olmadığı veya uçuş ve video kaydı yapıp yapmadığını tespit etmeye çalışan 10 sınıflı bir deneydir. Bu deneyin katışıklık matrisi tablolarında kullanılan kısaltmalar ve anlamları şu şekildedir:

- D.Y : Drone yok
- B.O : Bebop bağlı ve açık
- B.S : Bebop havada süzülme modu
- B.U : Bebop uçuş modu
- B.UV : Bebop uçuş ve video modu
- A.O : AR bağlı ve açık
- A.S : AR havada süzülme modu
- A.U : AR uçuş modu
- A.UV : AR uçuş ve video modu
- P.O : Phantom bağlı ve açık modu

Tablo 5.12 sonuçlarına göre KNN Algoritması, drone yok durumunu yüksek bir doğrulukla tespit edebilmekte, Bebop ve AR drone'larının videolu uçuş modlarında da oldukça başarılı sonuçlar elde etmektedir. Ancak, özellikle havada süzülme ve uçuş modlarında, diğer modlarla karışıklıklar yaşanmaktadır.

Bebop drone'un bağlı ve açık modu gibi bazı modlar arasında ise doğru ayrım yapma konusunda sınırlı bir kapasite sergilemektedir.

Bu sonuçlar, KNN algoritmasının bazı modlarda yüksek performans gösterirken, diğer modlar arasında doğru ayrım yapmada zorluk çektiğini göstermektedir.

Tablo 5.12. On sınıflı KNN algoritması katışıklık matris tablosu (%)

		TAHMİN SINIFI									
		D.Y	**B.O**	**B.S**	**B.U**	**B.UV**	**A.O**	**A.S**	**A.U**	**A.UV**	**P.O**
GERÇEK SINIF	**D.Y**	98,61	0,15	0,00	0,05	0,05	0,24	0,17	0,20	0,12	0,41
	B.O	0,33	17,33	45,10	27,24	6,05	0,67	0,19	0,76	1,24	1,10
	B.S	0,05	3,62	10,48	2,90	80,29	0,29	0,19	0,29	1,57	0,33
	B.U	0,24	2,14	4,52	7,33	81,43	0,24	0,19	0,29	2,38	1,24
	B.UV	0,10	1,14	2,62	1,95	71,19	0,43	0,38	0,10	1,14	20,95
	A.O	0,05	4,14	40,57	40,10	1,57	12,76	0,24	0,29	0,24	0,05
	A.S	0,38	0,76	0,24	0,05	0,05	1,24	7,24	3,71	86,24	0,10
	A.U	0,24	1,90	0,67	0,19	0,24	0,81	7,52	6,95	81,48	0,00
	A.UV	0,61	1,78	1,44	1,78	0,61	2,78	2,89	2,28	85,78	0,06
	P. O	0,76	0,29	0,71	0,29	0,24	1,05	0,48	0,38	0,10	95,71

Tablo 5.13. On sınıflı RF algoritması katışıklık matris tablosu (%)

		TAHMİN SINIFI									
		D.Y	**B.O**	**B.S**	**B.U**	**B.UV**	**A.O**	**A.S**	**A.U**	**A.UV**	**P.O**
GERÇEK SINIF	**D.Y**	100,0	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	B.O	0,43	21,71	2,71	1,14	67,86	2,90	0,10	0,14	1,24	1,76
	B.S	0,10	5,52	6,57	2,81	80,71	0,86	0,05	0,10	2,38	0,90
	B.U	0,00	1,95	3,00	5,76	81,95	1,62	0,00	0,10	4,48	1,14
	B.UV	0,19	0,62	1,76	2,62	91,14	0,71	0,00	0,14	2,10	0,71
	A.O	0,00	4,48	1,29	1,19	76,24	15,38	0,00	0,05	1,14	0,24
	A.S	0,00	1,52	0,19	0,00	0,05	0,10	52,52	39,62	5,95	0,05
	A.U	0,00	2,10	0,52	0,14	0,10	0,10	47,43	45,48	4,14	0,00
	A.UV	0,00	1,50	0,50	0,22	0,11	1,72	4,33	3,61	88,00	0,00
	P. O	0,81	0,95	0,71	0,48	50,24	0,24	0,10	0,05	0,00	46,43

Tablo 5.13'te gösterilen RF algoritmasının karmaşıklık matrisi, modelin drone yok, Bebop ve AR drone'larının videolu uçuş modlarını yüksek doğrulukla tanımlayabildiğini, ancak bazı sınıflar arasında karışıklıklar yaşadığını ortaya

koymaktadır. Özellikle drone yok durumu %100 doğrulukla tespit edilse de, Bebop ve AR modlarında, yanlış tahminlerin olduğu gözlemlenmektedir.

Bebop'un bağlı ve açık modları arasında belirgin karışıklıklar bulunmakta, bu durum modelin bazı modlar arasında doğru ayrım yapma kapasitesinin sınırlı olduğunu göstermektedir.

Genel olarak RF algoritması, bazı modlarda yüksek doğrulukla çalışsa da daha karmaşık modlar arasında doğru ayrımlar yapmada güçlük çekmektedir, bu da modelin genel performansını etkileyebilecek bir faktör olarak öne çıkmaktadır.

Tablo 5.14. On sınıflı CART algoritması katışıklık matris tablosu (%)

		TAHMİN SINIFI									
		D.Y	**B.O**	**B.S**	**B.U**	**B.UV**	**A.O**	**A.S**	**A.U**	**A.UV**	**P.O**
GERÇEK SINIF	**D.Y**	99,71	0,07	0,05	0,05	0,05	0,02	0,02	0,00	0,00	0,02
	B.O	0,24	13,71	4,57	2,52	71,48	2,67	0,57	1,43	1,05	1,76
	B.S	0,05	4,29	5,29	2,95	81,71	1,43	0,57	0,95	1,71	1,05
	B.U	0,10	2,33	2,81	5,76	83,10	1,38	1,14	1,10	1,57	0,71
	B.UV	0,05	1,24	2,29	3,76	89,10	1,14	0,33	0,43	1,14	0,52
	A.O	0,00	2,38	1,76	1,81	79,48	11,67	0,38	0,67	1,43	0,43
	A.S	0,05	1,00	0,76	0,43	0,19	0,76	46,29	41,67	8,81	0,05
	A.U	0,05	1,19	0,90	0,52	0,48	0,29	45,24	45,10	6,14	0,10
	A.UV	0,06	1,44	2,22	1,78	1,00	1,94	10,50	8,22	72,78	0,06
	P. O	0,10	1,95	0,76	0,52	53,86	0,38	0,19	0,10	0,00	42,14

Tablo 5.14'e bakıldığında, CART algoritmasının drone yok, Bebop ve AR videolu uçuş modlarını diğer algoritmalara göre daha düşük doğruluk oranlarıyla tahmin ettiği, ancak bu modlar için genel olarak iyi bir performans gösterdiği görülmektedir. Özellikle, drone yok durumu %99,71 doğrulukla tespit edilmiş, ancak Bebop ve AR modlarında daha fazla karışıklık yaşandığı ve bu modların diğer modlarla karıştırıldığı anlaşılmaktadır.

Bu sonuçlar, CART algoritmasının bazı sınıflar arasında daha net bir ayrım yapabilmesi için iyileştirilmesi gerektiğini ve genel performansın artırılabileceğini göstermektedir.

Dolayısıyla, belirli sınıflar arasındaki ayrımı güçlendirmek, algoritmanın genel doğruluk oranını yükseltebilir.

Tablo 5.15. On sınıflı Ensemble model katışıklık matris tablosu(%)

		TAHMİN SINIFI									
		D.Y	**B.O**	**B.S**	**B.U**	**B.UV**	**A.O**	**A.S**	**A.U**	**A.UV**	**P.O**
GERÇEK SINIF	**D.Y**	99,98	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	B.O	0,14	19,33	35,57	29,10	11,67	1,67	0,10	0,33	0,90	1,19
	B.S	0,00	3,05	9,86	2,56	81,57	0,24	0,10	0,14	2,00	0,48
	B.U	0,05	1,29	3,19	7,33	82,81	0,48	0,10	0,00	3,57	1,19
	B.UV	0,05	0,24	0,86	1,76	74,19	0,33	0,19	0,19	1,62	20,57
	A.O	0,00	3,19	33,33	44,05	3,52	15,00	0,10	0,29	0,52	0,00
	A.S	0,10	0,67	0,10	0,10	0,00	0,48	8,33	6,00	84,19	0,05
	A.U	0,00	1,38	0,76	0,14	0,05	0,48	9,33	11,24	76,57	0,05
	A.UV	0,17	0,50	0,39	0,33	0,17	2,22	1,11	1,89	93,22	0,00
	P. O	0,05	0,10	0,36	0,10	0,29	0,10	0,10	0,14	0,00	98,76

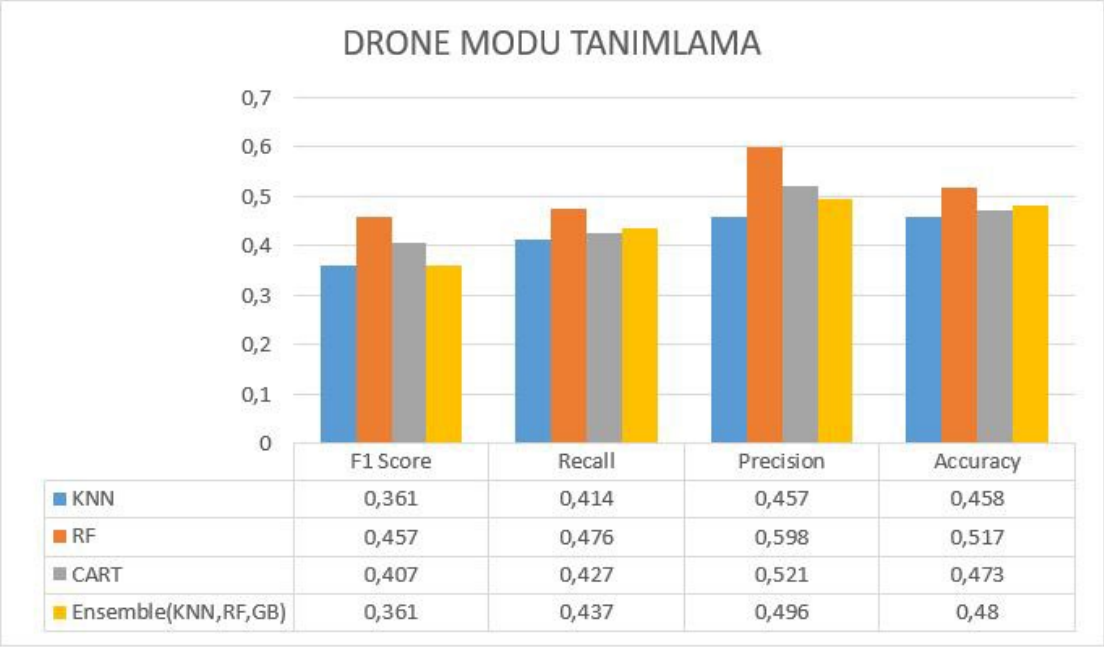
Tablo 5.15’te görüldüğü üzere Ensemble model drone yok tahmininde oldukça yüksek bir doğruluk sergilemiş ve diğer sınıflarla neredeyse hiç karışıklık yaşamamıştır.

Bebop ve AR drone'larının modları arasında ise model bazı karışıklıklar yaşamaktadır; özellikle Bebop'un bağlı ve açık modları ile uçuş modları arasında belirgin bir yanlış sınıflandırma eğilimi gözlemlenmektedir. Bu durum, modelin bu iki mod arasındaki farkı ayırt etmede zorlandığını göstermektedir.

Phantom drone'un modları arasında model daha iyi performans sergilemiş, özellikle Phantom bağlı ve açık modu doğru bir şekilde sınıflandırılmıştır. Bununla birlikte, bazı AR modları arasında da karışıklıklar mevcuttur. Modelin özellikle karmaşık ve benzer modlar arasında daha fazla karışıklık yaşadığı, ancak genel olarak iyi bir performans sergilediği söylenebilir.

Bu sonuçlar, Ensemble modelin genel olarak drone modlarını ayırt etme konusunda başarılı olduğunu, ancak benzer modlar arasındaki ince farkları ayırt etme kapasitesinin sınırlı olabileceğini göstermektedir.

Şekil 5.7'de görüldüğü gibi RF algoritması genel olarak en yüksek performansı sergilemiştir. RF algoritması, özellikle Precision ve Accuracy metriklerinde diğer modellere göre üstünlük sağlamaktadır, bu da modelin doğru tahmin oranının yüksek olduğunu ve yanlış tahminlerin düşük olduğunu gösterir.



	F1 Score	Recall	Precision	Accuracy
KNN	0,361	0,414	0,457	0,458
RF	0,457	0,476	0,598	0,517
CART	0,407	0,427	0,521	0,473
Ensemble(KNN,RF,GB)	0,361	0,437	0,496	0,48

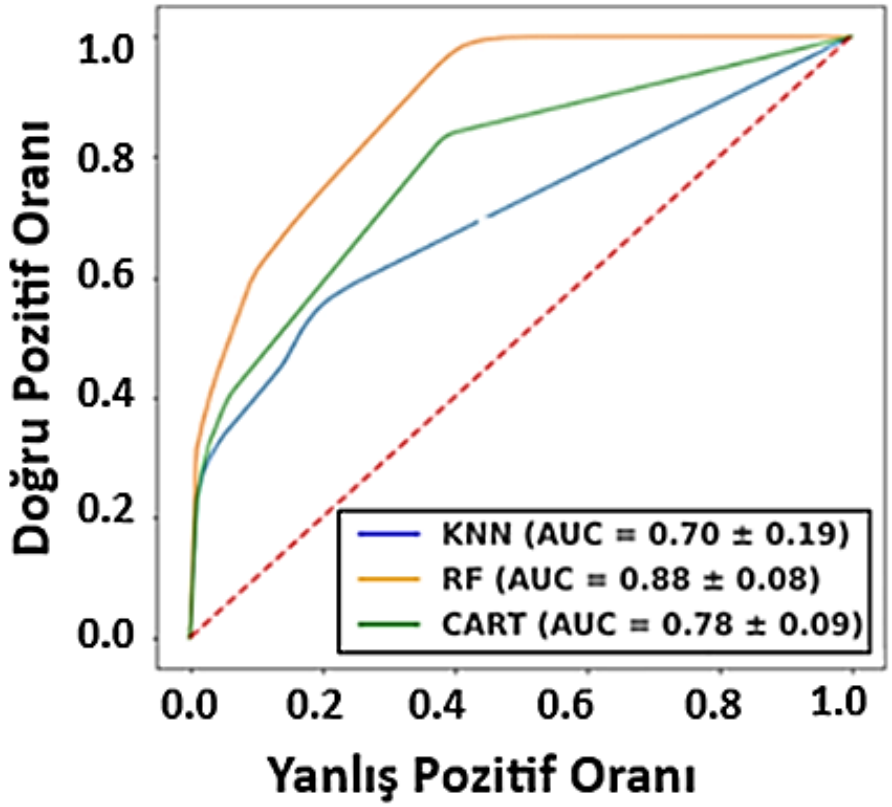
Şekil 5.7. Tüm algoritmaların drone modu tanımlama sonuçları

CART algoritması, RF'ye kıyasla daha düşük performans sergilese de F1 Skoru ve Precision metriklerinde nispeten dengeli bir sonuç sunmaktadır.

KNN ise, bu üç algoritma arasında en düşük performansı sergilemektedir, özellikle F1 Skoru ve Precision metriklerinde zayıf kalmaktadır.

Ensemble modeli (KNN, RF, GB), çeşitli algoritmaların güçlü yönlerini birleştirmeyi amaçlamasına rağmen, beklenenden daha düşük bir performans göstermiştir. Ensemble modelin Precision ve Accuracy metrikleri, tekil RF modeline kıyasla daha düşük çıkmıştır. Bu durum, Ensemble modelin bu özel görevde, bireysel modellerin performansını artırmak yerine, ortalama bir performans sergilemesine neden olmuştur. Bu sonuçlar, Ensemble modelin her zaman en iyi çözüm olmayabileceğini ve her durumda tekil modellerin üstün performans gösterebileceğini işaret eder.

Şekil 5.8'de bulunan ROC eğrilerine göre; RF algoritması, eğrinin en üstünde yer almakta ve en yüksek performansı sergilemektedir. Bu, algoritmanın pozitif sınıfları etkili bir şekilde ayırt edebildiğini gösterir.

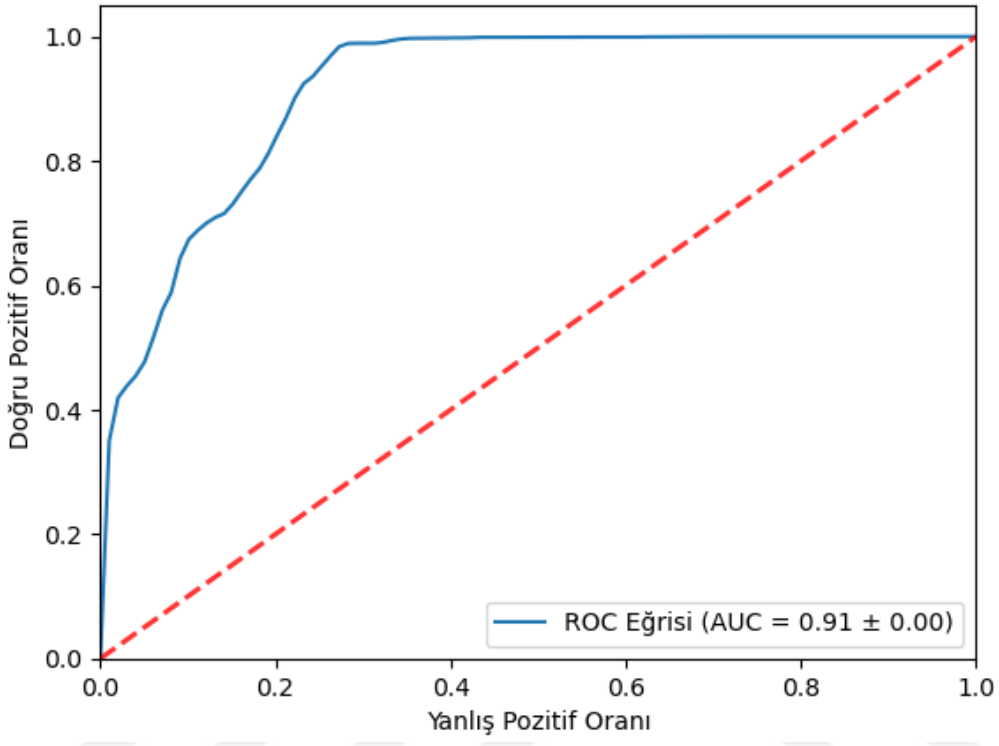


Şekil 5.8. Drone modu tanımlama RF, CART ve KNN ROC eğrisi

CART algoritması, RF'ye kıyasla daha düşük bir performans sergilemekle birlikte, yine de makul bir doğruluk oranına sahiptir. Ancak, ROC eğrisinde görüldüğü üzere, bazı yanlış pozitif oranlarında RF'ye göre daha düşük bir performans sergilemektedir. KNN algoritması ise bu üç model arasında en düşük performansı göstermektedir. Bu sonuçlar, KNN'nin drone modu tanımlama görevinde RF ve CART modellerine göre daha düşük bir performans sergilediğini ve sınıflandırma görevinde daha az etkili olduğunu ortaya koymaktadır.

Şekil 5.9'da verilen ROC eğrisi ise Ensemble modelin doğru pozitif oranını yüksek tutarken, yanlış pozitif oranını düşük tutabildiğini ve genel olarak güçlü bir performans sergilediğini göstermektedir.

Bu sonuçlar Ensemble modelin, RF, CART ve KNN algoritmalarına kıyasla daha dengeli ve başarılı bir performans sunduğunu, özellikle uçuş modlarını ayırt etmede daha etkili olduğunu ortaya koymaktadır.



Şekil 5.9. Drone modu tanımlama Ensemble model ROC eğrisi

6. SONUÇ VE ÖNERİLER

Bu çalışmada, farklı makine öğrenimi algoritmalarının (RF, KNN, CART) ve Ensemble modelin drone algılama, tanımlama ve mod tanımlama görevlerinde gösterdiği performans detaylı bir şekilde incelenmiştir. Sonuçlar, her bir algoritmanın çeşitli metrikler üzerinden değerlendirilmesiyle, hangi modelin hangi durumda daha etkili olduğu konusunda önemli bulgular sunmaktadır.

RF Algoritması: RF algoritması, özellikle drone algılama ve tanımlama görevlerinde yüksek performans sergilemiştir. Bu model, doğru pozitif oranını yüksek tutarken, yanlış pozitif oranını düşük tutma konusunda oldukça başarılıdır. Bu durum, RF algoritmasının özellikle sınıflandırma problemlerinde güçlü bir seçenek olduğunu göstermektedir. Bununla birlikte, mod tanımlama görevinde RF algoritması, diğer görevlere kıyasla biraz daha düşük performans sergilemiştir; ancak genel olarak makine öğrenimi algoritmaları arasında en yüksek doğruluk oranlarından birini elde etmiştir.

KNN Algoritması: KNN algoritması, özellikle drone algılama ve tanımlama görevlerinde iyi bir performans göstermiştir. Ancak, mod tanımlama gibi daha karmaşık görevlerde KNN'nin performansı düşmüştür. Bu durum, KNN'nin daha basit sınıflandırma problemlerinde etkili olmasına rağmen, karmaşık yapıların sınıflandırılmasında yetersiz kalabileceğini göstermektedir. Bununla birlikte, KNN algoritmasının kullanımının kolay olması ve düşük hesaplama maliyetleri, onu hala birçok durumda tercih edilebilir bir seçenek haline getirmektedir.

CART Algoritması: CART algoritması, drone algılama ve tanımlama görevlerinde diğer algoritmalara kıyasla daha düşük performans sergilemiştir. Özellikle mod tanımlama görevinde, doğru sınıflandırma yapma oranı oldukça düşüktür. Bu sonuçlar, CART algoritmasının karmaşık sınıflandırma görevlerinde yetersiz kalabileceğini göstermektedir. Ancak, basit yapısı ve yorumlanabilirliği, CART algoritmasını bazı durumlarda hala kullanışlı bir araç haline getirmektedir.

Ensemble Model: Farklı makine öğrenimi algoritmalarının (KNN, RF, GB) birleştirilmesiyle oluşturulmuştur ve bu modelin performansı, tekil modellerin çoğundan daha yüksektir. Özellikle, doğru sınıflandırma oranlarında önemli bir artış sağlanmış ve

mod tanımlama görevlerinde dahi yüksek doğruluk elde edilmiştir. Ensemble yaklaşımı, bu nedenle karmaşık sınıflandırma problemlerinde etkili bir yöntem olarak değerlendirilebilir.

Tablo 6.1'de bu çalışmada elde edilen sonuçlar ile CNN ve DNN modellerinin sonuçları görülmektedir (S. Al-Emadi & F. Al-Senaid, 2020).

Tablo 6.1. Tüm modellerin karşılaştırılması

		F1 Score	Recall	Precision	Accuracy
ALGILAMA	**KNN**	0,992	0,989	0,995	0,995
	RF	0,998	0,999	0,998	0,999
	CART	0,997	0,996	0,997	0,998
	Ensemble	0,999	0,999	1,00	1,00
	CNN	0,997	0,995	0,998	0,998
	DNN	0,995	0,994	0,996	0,997
TANIMLAMA	**KNN**	0,889	0,903	0,885	0,875
	RF	0,817	0,789	0,907	0,848
	CART	0,803	0,778	0,878	0,834
	Ensemble	0,832	0,804	0,916	0,858
	CNN	0,846	0,817	0,913	0,858
	DNN	0,788	0,764	0,910	0,845
MOD TANIMLAMA	**KNN**	0,361	0,414	0,457	0,458
	RF	0,457	0,476	0,598	0,517
	CART	0,407	0,427	0,521	0,473
	Ensemble	0,361	0,437	0,496	0,480
	CNN	0,551	0,555	0,589	0,592
	DNN	0,430	0,419	0,535	0,468

Bu sonuçlar, makine öğrenmesi yaklaşımlarının derin öğrenme modelleriyle karşılaştırıldığında, birçok durumda oldukça rekabetçi olduğunu ortaya koymaktadır. Özellikle algılama ve tanımlama görevlerinde, makine öğrenmesi modelleri (KNN, RF, CART ve Ensemble) derin öğrenme yaklaşımlarına yakın performanslar sergilemiş ve hatta bazı durumlarda daha üstün sonuçlar elde etmiştir. Bu durum, geleneksel makine öğrenmesi tekniklerinin, doğru yapılandırıldıklarında, hâlâ son derece etkili olabileceğini göstermektedir.

Algılama görevinde, özellikle Ensemble modelin öne çıktığı ve neredeyse tüm metriklerde en yüksek performansı sergilediği gözlemlenmiştir. Ensemble modelin başarısı, farklı algoritmaların güçlü yönlerini bir araya getirerek, daha dengeli ve etkili

bir tahmin yeteneği sunmasından kaynaklanmaktadır. CNN ve DNN gibi derin öğrenme modelleri de güçlü performans göstermiş olsalar da Ensemble modelin genel doğruluk ve hassasiyet açısından daha iyi sonuçlar verdiği durumlar dikkat çekicidir. Bu da daha az hesaplama gücü gerektiren makine öğrenmesi tekniklerinin belirli senaryolarda derin öğrenmeye tercih edilebileceğini göstermektedir.

Mod tanımlama görevinde ise, derin öğrenme modelleri bazı avantajlar sunmuş olsa da genel olarak RF ve Ensemble gibi makine öğrenmesi modelleri de yüksek performans göstermiştir. Özellikle, bu iki modelin, mod tanımlama görevlerinde derin öğrenme modellerine çok yakın sonuçlar elde edebildiği, hatta belirli durumlarda daha başarılı olduğu gözlemlenmiştir. Bu sonuçlar, makine öğrenmesi tekniklerinin, derin öğrenme yaklaşımlarına karşı güçlü bir alternatif sunduğunu ve çeşitli uygulamalarda hâlâ değerli bir araç olduğunu vurgulamaktadır.

Bu çalışmanın sonuçlarına dayanarak, mevcut modellerin performansını artırmak için aşağıdaki önerilerde bulunulabilir:

- Gelişmiş Özellik Mühendisliği: Özellikle mod tanımlama gibi karmaşık görevlerde, daha ayırt edici özelliklerin çıkarılması için gelişmiş özellik mühendisliği yöntemleri kullanılabilir. Zaman-frekans analizi, spektral analiz gibi teknikler model performansını artırabilir.
- Transfer Öğrenme: Karmaşık görevlerde, transfer öğrenme kullanılarak önceden eğitilmiş modellerden faydalanılabilir. Bu yöntem, küçük veri setlerinde bile yüksek performans elde edilmesini sağlayabilir.
- Daha Gelişmiş Ensemble Teknikleri: Bagging, boosting ve stacking gibi gelişmiş Ensemble teknikleri, modelin genel performansını ve doğruluğunu artırmak için kullanılabilir. Bu, özellikle zorlayıcı sınıflandırma görevlerinde faydalı olacaktır.

Bu öneriler, makine öğrenimi ve derin öğrenme yöntemlerinin karmaşık görevlerde nasıl iyileştirilebileceğini göstermektedir. Gelecek çalışmalarda, bu tekniklerin kullanılması, daha yüksek doğruluk ve genelleme yeteneği sağlayabilir.

KAYNAKLAR

Al-Adwan, R., Al-Habahbeh, O. (2022). Unmanned Aerial Vehicles Sensor-Based Detection Systems Using Machine Learning Algorithms. *International Journal of Mechanical Engineering and Robotics Research*, *11*(9), 662-668. DOI: 10.18178/ijmerr.11.9.662-668

Al-Emadi, S., Al-Senaid, F. (2020). Drone Detection Approach Based on Radio-Frequency Using Convolutional Neural Network. *2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT)*, Doha, Katar, 02-05 Şubat 2020. DOI: 10.1109/ICIoT48696.2020.9089489

Al-Syouf, R., Bani-Hani, R., Al-Jarrah, O. (2024). Machine Learning Approaches to Intrusion Detection in Unmanned Aerial Vehicles (UAVs). *Neural Computing and Applications*, *36*, 18009-18041. DOI: 10.1007/s00521-024-10306-y

Allahham, M. S., Al-Sa'd, M. F., Al-Ali, A., Mohamed, A., Khattab, T., Erbad, A. (2019). Dronerf Dataset: A Dataset of Drones for RF-Based Detection, Classification and Identification. *Data in Brief*, *26*, 104313. DOI: 10.1016/j.dib.2019.104313

Arf, C. (1960). Makineler Düşünebilir Mi?. *Matematik ve Bilgisayar Bilimleri Dergisi*, 2(1), 25-35.

Austin, R. (2010). *Unmanned Aircraft Systems: UAVs Design, Development and Deployment*. John Wiley & Sons, Chichester.

Breiman, L. (2001). Random Forests. *Machine Learning*, *45*(1), 5-32. DOI: 10.1023/A:1010933404324

Chen, J., Miao, X., Jiang, H., Chen, J., Liu, X. (2017). Identification Of Autonomous Landing Sign for Unmanned Aerial Vehicle Based on Faster Regions with Convolutional Neural Network. *Proceedings of the 2017 IEEE Conference on Control and Automation*, 2109-2114. DOI: 10.1109/CAC.2017.8243120

Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. In J. Kittler & F. Roli (Eds.), *Multiple Classifier Systems*, *1857*, 1-15. DOI: 10.1007/3-540-45014-9_1

El Alami, H., Mensi, N., Rawat, D. B. (2023). On the Study of Joint Naive Bayes and Multi-Layer Perception for Detecting Gps Jamming in UAS. *GLOBECOM 2023-2023 IEEE Global Communications Conference*, Kuala Lumpur, Malezya, 04-08 Aralık 2023. DOI: 10.1109/GLOBECOM54140.2023.10437038

Elumalai, M., Fernandez, T., Ragab, M. (2024). Machine Learning (ML) Algorithms on Iot and Drone Data for Smart Farming. In *Proceedings of the International Conference on Smart Farming*, 179-206. DOI: 10.1007/978-3-031-51195-0_10

Ezuma, M., Erden, F., Anjinappa, C. K., Ozdemir, O., Guvenc, I. (2019). Micro-UAV Detection and Classification from RF Fingerprints Using Machine Learning Techniques. *2019 IEEE Aerospace Conference*, 1-13. DOI: 10.1109/AERO.2019.8741970

Fawcett, T. (2006). An Introduction to ROC Analysis. *Pattern Recognition Letters*, *27*(8), 861-874. DOI: 10.1016/j.patrec.2005.10.010

Guo, S., Sahagun, J. (2024). AirWatch: A Real-Time and Fine-Granularity Air Quality Monitoring And Analytical System Using Machine Learning and Drone Technology. *Proceedings of the Computer Science and Information Technology Conference*, 193-203. DOI: 10.5121/csit.2024.141017

Gupta, P., Pareek, B., Singal, G., Rao, D. V. (2021). Edge Device-Based Military Vehicle Detection and Classification From UAV. *Multimedia Tools and Applications*, *81*, 19813-19834. DOI: 10.1007/s11042-021-11242-y

Hasan, S. H., Cansever, G. (2023). Drone Tracking and Object Detection By YOLO And CNN. *International Journal of Scientific Trends*, *2*(7), 78–108.

Hastie, T., Tibshirani, R., Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). New York: Springer.

Haykin, S. (2001). *Communication Systems* (4th ed.). New York: John Wiley & Sons.

Hinton, G. E., Salakhutdinov, R. R. (2006). Reducing the Dimensionality of Data With Neural Networks. *Science*, *313*(5786), 504-507. DOI: 10.1126/science.1127647

Jordan, M. I., Mitchell, T. M. (2015). Machine Learning: Trends, Perspectives, and Prospects. *Science*, *349*(6245), 255-260. DOI: 10.1126/science.aaa8415

Kim, J., Kim, S., Ju, C., Son, H. I. (2019). Unmanned Aerial Vehicles in Agriculture: A Review of Perspective of Platform, Control, and Applications. *IEEE Access*, *7*, 105100-105115. DOI: 10.1109/ACCESS.2019.2932119

Kohavi, R., Provost, F. (1998). Glossary of Terms. *Machine Learning*, *30*(2-3), 271-274

Lee, S., Kim, J., Park, H. (2018). Human Tracking for UAVs Using RNN and SVM. *Sensors*, *18*(12), 4125. DOI: 10.3390/s18124125

Lin, Y., Wang, T., Wang, S. (2019). UAV-Assisted Emergency Communications: an Extended Multi-Armed Bandit Perspective. *IEEE Communications Letters*, *23*(5), 938-941.

Ma, Y., Liu, K., Guan, Z., Xu, X., Qian, X., Bao, H. (2018). Background Augmentation Generative Adversarial Networks (BAGANs): Effective Data Generation Based on GAN-Augmented 3D Synthesizing. *Symmetry*, *10*(12), 734. DOI: 10.3390/sym10120734

Minsky, M., Papert, S. (1969). *Perceptrons: An Introduction to Computational Geometry*. Cambridge, MA: MIT Press.

Nguyen, P., Ravindranatha, M., Nguyen, A., Han, R., Vu, T. (2016). Investigating Cost-Effective RF-Based Detection of Drones. *Proceedings of the 2nd Workshop on Micro Aerial Vehicle Networks, Systems, and Applications for Civilian Use*, Singapur, 26 Haziran 2016. DOI: 10.1145/2935620.2935632

Quinlan, J. R. (1986). Induction of Decision Trees. *Machine Learning*, *1*(1), 81-106. DOI: 10.1023/A:1022643204877

Pham H.X., La H.M., Feil-Seifer D., Van Nguyen L.(2018). Reinforcement Learning for Autonomous UAV Navigation Using Function Approximation, *2018 IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR),* Philadelphia, PA, USA, 06-08 Ağustos 2018, DOI: 10.1109/SSRR.2018.8468611.

Rahman, M., Sejan, M. A., Aziz, M. A., Tabassum, R., Baik, J. I., Song, H. K. (2024). A Comprehensive Survey of Unmanned Aerial Vehicles Detection and Classification Using Machine Learning Approach: Challenges, Solutions, and Future Directions. *Remote Sensing*, *16*(5), 879. DOI: 10.3390/rs16050879

Raouhi, E. M., Lachgar, M., Hrimech, H., Kartit, A. (2023). Unmanned Aerial Vehicle-Based Applications in Smart Farming: a Systematic Review. *International Journal of Advanced Computer Science and Applications*, *14*(6), 2023. DOI: 10.14569/IJACSA.2023.01406123

Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, *3*(3), 210-229. DOI: 10.1147/rd.33.0210

Seo, Y., Jang, B., Im, S. (2018). Drone Detection Using Convolutional Neural Networks with Acoustic STFT features. *2018 15th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, Auckland, Yeni Zelanda, 27-30 Kasım 2018. DOI: 10.1109/AVSS.2018.8639425

Tejera-Berengue, D., Zhu-Zhou, F., Utrilla-Manso, M., Gil-Pita, R., Rosa-Zurera, M. (2024). Analysis of Distance and Environmental Impact on Uav Acoustic Detection. *Electronics*, *13*(3), 643. DOI: 10.3390/electronics13030643

Toorchi, N., Hu, F., Bentley, E. S., Kumar, S. (2021). Skeleton-Based Swarm Routing (SSR): Intelligent Smooth Routing For Dynamic UAV Networks. *IEEE Access*, *9*, 1286-1303. DOI: 10.1109/ACCESS.2020.3043672

Shalu, Singh, G. (2023). Environmental Monitoring With Machine Learning. *EPRA International Journal of Multidisciplinary Research(IJMR),* 208-212. DOI: 10.36713/epra13330

Yang, J., Wang, Y., Zhang, W. (2020). Real-time UAV-Based Flood Monitoring System with Optimized Deep Learning Model. *Remote Sensing*, *12*(6), 1012. DOI: 10.3390/rs12061012

Zhang, X., Liu, X., Wang, Y. (2019). UAV-Based Wildfire Detection and Monitoring With Machine Learning Algorithms. *Remote Sensing*, *11*(10), 1189. DOI: 10.3390/rs11101189

Zualkernan, I., Abuhani, D.A., Hussain, M.H., Khan, J., ElMohandes, M. (2023). Machine Learning for Precision Agriculture Using Imagery from Unmanned Aerial Vehicles (UAVs): A Survey. *Drones*, *7*(6), 382. DOI: 10.3390/drones7060382

KİŞİSEL YAYIN VE ESERLER

Okkalı, E. (2024). İnsansız hava araçlarında makine öğrenmesi çözümleri. *Uluslararası Fen Bilimlerinde Yeni Ufuklar Kongresi*, İstanbul Teknik Üniversitesi Mesleki ve Teknik Anadolu Lisesi, 11-12 Mayıs 2024.

Okkalı, E., Şolpan, Ş., Küçük, K. (2024). Radyo Frekansı Sinyalleri ile İnsansız Hava Araçlarının Makine Öğrenmesi Temelli Tespit Edilmesi. *Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı*, Gazi Üniversitesi, 16-18 Ekim 2024.

ÖZGEÇMİŞ

İlk, orta ve lise öğrenimini Malatya'da tamamladı. 2005 yılında girdiği Muğla Sıtkı Koçman Üniversitesi Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Öğretmenliği Bölümü'nden 2010 yılında Bilişim Teknolojileri Öğretmeni olarak mezun oldu. 2019 yılında Kocaeli Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde mühendislik tamamlama programını tamamladı. 2020 yılından başladığı, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Bilişim Sistemleri Mühendisliği Anabilim Dalı'ndaki Yüksek Lisans eğitimine devam etmektedir. 2011 yılından beri Millî Eğitim Bakanlığı'nda Bilişim Teknolojileri Öğretmeni olarak görev yapmaktadır. Aynı zamanda Tübitak Fen Lisesi'nde okutulacak olan Otonom Araçlar ve Nesnelerin İnterneti derslerinin ders kitaplarını yazmaktadır.