



**İNSANSIZ HAVA ARAÇLARININ DERİN ÖĞRENME TABANLI TESPİTİ
VE SINIFLANDIRILMASI**

Ozan DEMİR

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2019

Ozan DEMİR tarafından hazırlanan “İNSANSIZ HAVA ARAÇLARININ DERİN ÖĞRENME TABANLI TESPİTİ VE SINIFLANDIRILMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Elektrik Elektronik Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Özgül SALOR DURNA

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

.....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Başkan: Doç. Dr. Murat GÖL

Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı, ODTÜ

.....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Üye: Doç. Dr. Süleyman Sungur TEZCAN

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

.....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Tez Savunma Tarihi: 06/12/2019

Jüri tarafından kabul edilen bu çalışmanın Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum

.....

Prof. Dr. Sena YAŞYERLİ

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

.....
Ozan DEMİR
06/12/2019

İNSANSIZ HAVA ARAÇLARININ DERİN ÖĞRENME TABANLI TESPİTİ VE SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Ozan DEMİR

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2019

ÖZET

İnsansız hava araçları (İHA) son yıllarda yaygın şekilde kullanılmaktadırlar. Sayıları ve çeşitleri artan bu hava araçlarının yetenekleri önemli ölçüde geliştirilmiştir. Bu durum, kritik bölgelerde İHA'ları tespit etmeyi ve sınıflandırmayı zorunlu hale getirmiştir. Bu tezde, İHA'ları öznitelik görüntüleriyle tespit etmek ve sınıflandırmak amacıyla bir model önerilmiştir. Öznitelik görüntülerini birbirinden ayırmak için derin öğrenmenin bir algoritması olan evrişimli sinir ağları (ESA) araştırılmıştır. Kısa zamanlı Fourier dönüşümü (KZFD), Mel frekans kepsral katsayıları (MFKK) ve Gramian açısai alan dönüşümü (GAAD) kullanılarak üç öznitelik görüntüsü çıkarım yöntemi önerilmiştir. Ortamsal gürültüye ve iki İHA'ya ait gerçek dış ortamda toplanmış akustik sinyallerden faydalanılarak oluşturulan öznitelik görüntüleri ESA'nın eğitimi ve testi için kullanılmıştır. Önerilen modelin öznitelik görüntüsü çıkarım yöntemine ve mesafeye göre performans değerlendirmesi yapılmıştır. İHA ve kayıt alan mikrofön arasındaki mesafeye göre üç farklı veri kümesi oluşturulmuştur. Veri kümesi-1, veri kümesi-2 ve veri kümesi-3, sırasıyla 1-100 metre, 1-300 metre ve 1-500 metre arasında kaydedilen akustik sinyalleri içermektedirler. Ayrıca, bu veri kümelerine ortamsal gürültü kayıtları da eklenmiştir. Bu veri kümeleri için, ESA ayrı ayrı eğitilmiş ve eğitimde kullanılmayan öznitelik görüntüleriyle test edilmiştir. Deneyisel sınıflandırma sonuçları, ESA'nın KZFD kullanılarak elde edilen öznitelik görüntüleriyle eğitildiğinde, veri kümeleri için sırasıyla %96.4, %87.0 ve %85.6 makro f-ölçüm değerlerine ulaştığını göstermiştir. MFKK kullanılarak %94.0, %78.0 ve %78.3 ve GAAD kullanılarak %82.9, %67.4 ve %63.9 makro f-ölçüm değerlerine ulaşılmıştır. Sonuçlara göre yüksek sinyal gürültü oranına sahip akustik sinyallerle elde edilen öznitelik görüntülerinin ESA tarafından daha yüksek başarıyla sınıflandırıldığı gösterilmiştir. KZFD yönteminin MFKK ve GAAD yöntemlerine göre daha güçlü olduğu gösterilmiştir.

Bilim Kodu : 90542

Anahtar Kelimeler : İHA tespiti, İHA sınıflandırma, derin öğrenme, evrişimli sinir ağları, kısa zamanlı Fourier dönüşümü, Mel frekans kepsral katsayıları, Gramian açısai alan dönüşümü

Sayfa Adedi : 53

Danışman : Prof. Dr. Özgöl SALOR DURNA

2. Danışman : Dr. Alper BEREKETLİ

DEEP LEARNING BASED DETECTION AND CLASSIFICATION OF UNMANNED AERIAL VEHICLES

(M. Sc. Thesis)

Ozan DEMİR

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2019

ABSTRACT

The number and variety of unmanned aerial vehicles (UAVs) have increased, and their capabilities have been improved in recent years. This necessitates the detection and classification of UAVs in mission-critical applications. In this thesis, a model is proposed to detect and classify UAVs based on their feature images. We investigate convolutional neural networks (CNN), a subset of deep learning, to distinguish feature images. The feature images extracted from short-time Fourier transform (STFT), Mel-frequency cepstral coefficients (MFCC) and Gramian angular field transformation (GAFT) are used for training and testing of the CNN. We exploit acoustic signals of two commercial UAVs collected at actual outdoor environments, as well as ambient-noise for feature images extraction. The proposed model is evaluated in term of feature images extraction methods and distance. Three datasets are constructed based on the distance between UAV and the recording microphone. Dataset-1, dataset-2 and dataset-3 include acoustic signals recorded between 1-100 meters, 1-300 meters and 1-500 meters, respectively. Then, ambient-noise recordings are added to the datasets. For the datasets, the CNN is separately trained, and tested with unseen data. The experimental classification results show that the network achieves macro f-score of 96.4%, 87.0% and 85.6% using STFT feature images for the datasets respectively. MFCC technique yields macro f-score of 94.0%, 78.0% and 78.3%, and GAFT, 82.9%, 67.4% and 63.9%. According to the results, the CNN classify the feature images obtained with acoustic signals having high signal-to-noise ratio with higher success. STFT method outperforms MFCC and GAFT methods in term of robustness.

Science Code : 90542

Key Words : UAV detection, UAV classification, deep learning, convolutional neural network, short-time Fourier transform, Mel-frequency cepstral coefficients, Gramian angular field transformation

Page Number : 53

Supervisor : Prof. Dr. Özgül SALOR DURNA

Co Supervisor : Dr. Alper BEREKETLİ

TEŞEKKÜR

Tez süreci boyunca yardımlarını esirgemeyen danışman hocam Prof. Dr. Özgül SALOR DURNA'ya ve ikinci danışman hocam Dr. Alper BEREKETLİ'ye, veri toplama ve deneysel kurulum için destek sağlayan Aselsan SST Sualtı Akustik Sistemler Sistem Mühendisliği Müdürlüğü'ne ve desteğiyle hep yanımda olan Seda DEMİRHAN'a çok teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ	1
2. EVRİŞİMLİ SİNİR AĞLARI.....	5
2.1. Genel Bilgiler	5
2.2. ESA Katmanları.....	6
2.2.1. Giriş katmanı.....	6
2.2.2. Evrişim katmanı.....	6
2.2.3. Havuzlama katmanı	7
2.2.4. Aktivasyon fonksiyonu katmanı	9
2.2.5. Yığın normalizasyonu katmanı.....	9
2.2.6. Tam bağlaşımlı katman.....	10
2.2.7. Çıkış katmanı	10
2.3. Hiper Parametreler.....	10
2.4. Kullanılan Ağ Mimarisi.....	12
3. ÖZNİTELİK ÇIKARIM YÖNTEMLERİ	13
3.1. Akustik Sinyal Kaydı ve Ön İşleme	13

Sayfa

3.2. Kısa Zamanlı Fourier Dönüşümü	14
3.3. Mel Frekans Kepstral Katsayıları	19
3.4. Gramian Açısai Alan Dönüşümü.....	23
4. DENEYSEL SONUÇLAR.....	27
5. SONUÇ	47
KAYNAKLAR	49
ÖZGEÇMİŞ.....	53

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Örnek aktivasyon fonksiyonları.....	9
Çizelge 3.1 Kayıt Süreleri.....	13
Çizelge 3.2. İHA'ların mesafeye göre SNR bilgisi.....	14
Çizelge 4.1. KZFD yöntemiyle oluşturulan öznelik görüntüsü sayısı.....	27
Çizelge 4.2. MFKK yöntemiyle oluşturulan öznelik görüntüsü sayısı.....	27
Çizelge 4.3. GAAD yöntemiyle oluşturulan öznelik görüntüsü sayısı.....	28
Çizelge 4.4 Örnek hata matrisi parametre değerleri	29
Çizelge 4.5. Test-1 hata matrisi parametreleri.	30
Çizelge 4.6. Test-2 hata matrisi parametreleri.	31
Çizelge 4.7. Test-3 hata matrisi parametreleri.	32
Çizelge 4.8. Test-4 hata matrisi parametreleri.	33
Çizelge 4.9. Test-5 hata matrisi parametreleri	34
Çizelge 4.10. Test-6 hata matrisi parametreleri	35
Çizelge 4.11. Test-7 hata matrisi parametreleri	36
Çizelge 4.12. Test-8 hata matrisi parametreleri	37
Çizelge 4.13. Test-9 hata matrisi parametreleri	38
Çizelge 4.14. Test-1, Test-2 ve Test-3 için kesinlik değerleri	41
Çizelge 4.15. Test-4, Test-5 ve Test-6 için kesinlik değerleri	41
Çizelge 4.16. Test-7, Test-8 ve Test-9 için kesinlik değerleri	41
Çizelge 4.17. Test-1, Test-2 ve Test-3 için duyarlılık değerleri	41
Çizelge 4.18. Test-4, Test-5 ve Test-6 için duyarlılık değerleri	41
Çizelge 4.19. Test-7, Test-8 ve Test-9 için duyarlılık değerleri	41

Çizelge	Sayfa
Çizelge 4.20 Tüm testleri için makro kesinlik değerleri.....	42
Çizelge 4.21 Tüm testler için makro duyarlılık değerleri.	42

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. İHA spektrumu	1
Şekil 1.2. Önerilen model	3
Şekil 1.3. DJI Phantom 4 Pro 2.0 (sol) ve DJI Mavic Pro (sağ)	3
Şekil 2.1. LeNet mimarisi	5
Şekil 2.2. AlexNet mimarisi.....	6
Şekil 2.3. Evrişim katmanında, 4x4 girdi ve 3x3 filtrenin evrişim işlemi	7
Şekil 2.4. Maksimum havuzlama.....	8
Şekil 2.5. Ortalama havuzlama	8
Şekil 2.6. Evrişim katmanında kullanılan 3x3 boyutlu örnek filtre	11
Şekil 2.7. $P = 1$ olmak üzere sıfır dolgulama	11
Şekil 2.8. Kullanılan ESA mimarisi.....	12
Şekil 3.1. Ön işleme	13
Şekil 3.2. 128 noktalı bir Hamming penceresi.....	15
Şekil 3.3. Şakıma (Chirp) sinyalinin zaman alanı görüntüsü.....	16
Şekil 3.4. Şakıma (Chirp) sinyalin KZFD görüntüsü	16
Şekil 3.5. Ortamsal gürültünün KZFD görüntüsü.....	17
Şekil 3.6. Mavic'in KZFD görüntüsü	17
Şekil 3.7. Phantom'un KZFD görüntüsü	18
Şekil 3.8. Örnek KZFD öznelik görüntüleri	18
Şekil 3.9. Mel filtre bankası.....	19
Şekil 3.10. Şakıma (Chirp) sinyalin MFKK görüntüsü	20
Şekil 3.11. Ortamsal gürültünün MFKK görüntüsü.....	21

Şekil	Sayfa
Şekil 3.12. Mavic'in MFKK görüntüsü	21
Şekil 3.13. Phantom'un MFKK görüntüsü	22
Şekil 3.14. Örnek MFKK öznitelik görüntüleri	22
Şekil 3.15. GAAD örneği.....	23
Şekil 3.16. Ortamsal gürültünün GAAD görüntüsü.....	24
Şekil 3.17. Mavic'in GAAD görüntüsü	24
Şekil 3.18. Phantom'un GAAD görüntüsü	25
Şekil 3.19. Örnek GAAD öznitelik görüntüleri	25
Şekil 4.1 Üç sınıflı örnek hata matrisi	29
Şekil 4.2. Test-1 (Veri kümesi-1, KZFD) sonuçlarına göre hata matrisi.....	30
Şekil 4.3. Test-2 (Veri kümesi-1, MFKK) sonuçlarına göre hata matrisi.....	31
Şekil 4.4. Test-3 (Veri kümesi-1, GAAD) sonuçlarına göre hata matrisi.....	32
Şekil 4.5. Test-4 (Veri kümesi-2, KZFD) sonuçlarına göre hata matrisi.....	33
Şekil 4.6. Test-5 (Veri kümesi-2, MFKK) sonuçlarına göre hata matrisi.....	34
Şekil 4.7. Test-6 (Veri kümesi-2, GAAD) sonuçlarına göre hata matrisi.....	35
Şekil 4.8. Test-7 (Veri kümesi-3, KZFD) sonuçlarına göre hata matrisi.....	36
Şekil 4.9. Test-8 (Veri kümesi-3, MFKK) sonuçlarına göre hata matrisi.....	37
Şekil 4.10. Test-9 (Veri kümesi-3, GAAD) sonuçlarına göre hata matrisi.....	38
Şekil 4.11. Sınıflandırma genel doğruluk metriği değerleri	40
Şekil 4.12. Sınıflandırma makro f-ölçüm metriği değerleri.....	43
Şekil 4.13. Tespit genel doğruluk metriği değerleri	44
Şekil 4.14. Tespit makro f-ölçüm metriği değerleri.....	45

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

Hz

Hertz

dB

Desibel

m

Metre

kg

Kilogram

sn

Saniye

GB

Gigabayt

Kısaltmalar

Açıklamalar

CNN

Convolutional Neural Network

CPU

Central Processing Unit

DFT

Discrete Fourier Transform

DN

Doğru Pozitif

DY

Doğru Negatif

ESA

Evrişimli Sinir Ağları

FFT

Fast Fourier Transform

GAAD

Gramian Açısız Alan Dönüşümü

GAFT

Gramian Angular Field Transformation

GPU

Graphics Processing Unit

İHA

İnsansız Hava Aracı

KZFD

Kısa Zamanlı Fourier Dönüşümü

MFCC

Mel-Frequency Cepstral Coefficients

MFKK

Mel Frekans Cepstral Katsayıları

RAM

Random Access Memory

ReLU

Rectified Linear Unit

RF

Radio Frequency

SNR

Signal-to-Noise Ratio,

Kısaltmalar**Açıklamalar****STFT**

Short-Time Fourier Transform

UAV

Unmanned Aerial Vehicle

YP


Yanlış Pozitif

YN

Yanlış Negatif

1. GİRİŞ

İnsansız hava aracı (İHA), içerisinde operatör bulunmadan uçabilen hava araçlarına denilmektedir. İHA'lar uzaktan kontrol edilebilir veya otonom olarak görev icra edebilmektedirler. Üretim, sensör, kontrol, haberleşme ve güç depolama sistemlerindeki gelişmeler, insan varlığının zor, imkansız veya tehlikeli olduğu durumlarda kullanılabilecek çeşitli tür ve modelde İHA'nın geliştirilmesini mümkün kılmıştır [1]. Son yıllarda yaygın şekilde kullanılmakta olan İHA'ların, sayıları ve çeşitleri artmış ve yetenekleri önemli ölçüde geliştirilmiştir. İHA'ların, askeri amaçlı uygulamalar, gözlem ve keşif, uzaktan algılama, arama ve kurtarma, malzeme taşıma, gerçek zamanlı görüntüleme, güvenlik, kablosuz bağlantı sağlama, tarımda öngörü uygulamaları ve sivil altyapı kontrolleri gibi alanlarında bulunduğu sayısız kullanım alanı bulunmaktadır [2]. Uluslararası insansız araç sistemleri birliği, 2025 yılına kadar İHA'lar için 100.000'den fazla yeni iş öngörmektedir [3]. Sivil İHA küresel satış büyüklüğü 2018 yılında 14 milyar dolardan, %20.5 yıllık bileşik büyüme oranıyla 2024 yılında 43 milyar dolara çıkacağı öngörülmektedir [4]. İHA'ların uçuş görevlerine bağlı olarak, fiziksel özellikleri ve üzerinde kurulu ekipmanları farklılık gösterebilmektedir. Bundan dolayı farklı özellikler temel alınarak birçok sınıflandırma yapılmıştır, örnek olarak ağırlık ve kanat açıklığına göre İHA sınıflandırılması Şekil 1.1'de verilmiştir [1].




Şekil 1.1. İHA spektrumu

İHA'ların kötü niyetli kişiler tarafından kullanılması durumunda, insanlara, kurumlara veya altyapıya doğrudan fiziksel saldırılarda bulunma, silah, patlayıcı madde veya yasaklı malzeme taşınma, fotoğraf veya video çekerek kötüye kullanma ve izinsiz keşif gibi büyük tehditler içeren görevlerin yapılabilmesi göz ardı edilemez bir durum haline gelmiştir [5].

16.09.2013 tarihli Spiegel gazetesinin haberine göre, İHA'nın Almanya başbakanının hemen yanına kadar yaklaştırılabilmesi [6], 26.01.2015 tarihli Time gazetesinin haberine göre, Beyaz Saray güvenli bölgesinde şüpheli bir İHA bulunması [7], 16.02.2016 tarihli The Japan Times gazetesinin haberine göre, başbakanlık ofisinin çatısında İHA bulunması [8] ve 11.11.2018 tarihli Sabah gazetesinin haberine göre, bomba düzenekli 10 adet İHA'yla Şırnak ilinde sivilleri hedef alan terör saldırısı [9] bu durumun örneklerindendir.

İHA'lar, değişken dış görünüş, küçük boyut ve alçak yüksekliklerde uçabilme kabiliyeti özelliklerinden dolayı tespiti ve sınıflandırılması karmaşık ve zor araçlar haline gelmiştir. İHA'ları tespit etmek ve sınıflandırmak için hedeften yayınlan RF sinyaller, radar, akustik sensör, görüntü işleme ve sensör füzyonu gibi çözüm yaklaşımları bulunmaktadır. Akustik, diğer yaklaşımlara önemli bir alternatiftir. Düşük maliyet, karmaşık olmayan sistem, başarımın hedef boyutuna bağlı olmaması ve hedefin görüş hattında olmasına gerek olmaması akustik sistemlerin en önemli avantajlarından sayılabilmektedir [10].

Literatüre bakıldığında, İHA'ların akustik bilgileri kullanılarak farklı sinyal işleme yöntemleri aracılığıyla öznitelik çıkarımlarının ve bu özniteliklere uygun makine öğrenmesi tabanlı sınıflandırıcıların araştırıldığı görülmektedir. Örneğin, evrimsel sinir ağı, İHA akustik sinyallerinin kısa zamanlı Fourier dönüşümü kullanılarak eğitilmiş ve eğitim çevrim sayısına göre tespit performansı değerlendirilmiştir [11]. Doğrusal öngörü kepsral katsayıları ve Mel frekans kepsral katsayıları kullanılarak oluşturulan İHA öznitelik görüntülerinin destek vektör makineleri aracılığıyla tespit edilme başarısı araştırılmıştır [12]. İHA akustik sinyallerinin kısa zamanlı enerji (short time energy), zamansal ortalama (temporal centroid), sıfır geçiş oranı (zero crossing rate), spektral ortalama (spectral centroid), spektral azaltma (spectral roll-off) ve Mel frekans kepsral katsayıları parametreleri hesaplanarak öznitelik kümesi oluşturulmuş ve destek vektör makineleriyle entegre edilerek önerilen yaklaşımın tespit başarısı değerlendirmiştir [13]. Bir diğer çalışmada, Mel frekans kepsral katsayılarıyla oluşturulan İHA öznitelik görüntülerinin, Gaussian karışım modeli, evrimsel sinir ağı ve tekrarlamalı sinir ağı sınıflandırıcıları kullanılarak tespit başarısı araştırılmıştır [14].



Şekil 1.2. Önerilen model

Bu tez çalışmasında, İHA tespiti ve sınıflandırılması amacıyla Şekil 1.2’te gösterilen yapı önerilmiştir. Bu model üç aşamadan oluşmaktadır. İlk aşama, İHA’lara ve ortamsal gürültüye ait akustik sinyal kayıtlarının alınması ve ön işlemlerden geçirilmesidir. İkinci aşama, ham akustik sinyaller kullanılarak öznitelik görüntülerinin oluşturulduğu aşamadır. Üç farklı öznitelik görüntüsü oluşturma yöntemi önerilmiştir. Bu yöntemlerde kısa zamanlı Fourier dönüşümü (KZFD), Mel frekans kepstal katsayıları (MFKK) ve Gramian açısıl alan dönüşümü (GAAD) algoritmaları kullanılmaktadır. Diğer aşamada ise çıkarılan öznitelik görüntülerinin birbirinden ayrılması için derin öğrenmenin bir algoritması olan evrişimli sinir ağları (ESA) kullanılmaktadır. İHA olarak Şekil 1.3’te verilen Phantom (DJI Phantom 4 Pro 2.0) [15] ve Mavic (DJI Mavic Pro) [16] ticari ürünleri kullanılmıştır. İHA’lara ve ortamsal gürültüye ait akustik sinyaller dış ortamda kaydedilmiştir. Alınan akustik sinyal kayıtlarından İHA ile kayıt mikrofonu arasındaki mesafeye göre üç ayrı veri kümesi oluşturulmuştur. Bu mesafe 1-100 metre arasındayken alınan akustik sinyal kayıtları veri kümesi-1, 1-300 metre arasındayken alınan akustik sinyal kayıtları veri kümesi-2 ve 1-500 metre arasındayken alınan akustik sinyal kayıtları veri kümesi-3 olarak belirlenmiştir. Ayrıca bu veri kümelerine ortamsal gürültünün akustik sinyal kayıtları da eklenmiştir. Her veri kümesi ortamsal gürültü, Mavic ve Phantom olmak üzere üç ayrı sınıftan oluşmaktadır. Önerilen modelin üç ayrı öznitelik görüntüsü oluşturma yöntemine ve mesafeye göre başarısı değerlendirilmiştir.




Şekil 1.3. DJI Phantom 4 Pro 2.0 (sol) ve DJI Mavic Pro (sağ)


2. EVRİŞİMLİ SİNİR AĞLARI

2.1. Genel Bilgiler

Evrışimli sinir ağı (ESA), canlıların doğal görsel algı mekanizmalarından esinlenerek ortaya çıkan bir derin öğrenme algoritmasıdır. Yapay sinir ağlarından en önemli farkı, farklı katmanlar eklenerek parametre sayısının ve dolayısıyla işlem yükünün azaltılmasıdır. ESA'nın bir başka önemli yönü, giriş derin katmanlara doğru yayıldığında girdi özneteliklerinin genel olarak elde edilmesidir [17]. Görüntü tanımanın yanı sıra örüntü tanıma, nesne bulma, nesne takip etme, yazı tanıma, imza tanıma, hareket tespiti , konuşma işleme ve doğal dil işleme gibi pek çok alanda araştırma konusu olmuştur. İlk olarak 1998 yılında el yazısı rakam görüntülerinin birbirinden ayrılması amacıyla Şekil 2.1'de mimarisi gösterilen LeNet ortaya atılmıştır [20]. Sonraki yıllarda, çokça veri kümelerinin oluşturulabilmesi ve GPU teknolojisinin gelişmesiyle bilgisayarların hızlı işlem yapabilme kapasitesi artırılarak ESA kolay uygulanabilir hale gelmiştir. 2012 yılında yapılan ImageNet (ImageNet Large Scale Visual Recognition Challenge – ILSVRC) [18] yarışmasında yüksek doğrulukla birincilik kazanan ve LeNet'e benzeyen fakat daha derin mimariye sahip Şekil 2.2'de mimarisi gösterilen AlexNet, ESA'nın popüler hale gelmesinde büyük rol oynamıştır. Daha sonra ZFNet, VGGNet, GoogLeNet ve ResNet gibi farklı mimariler ortaya çıkmıştır [19].



Şekil 2.1. LeNet mimarisi



Şekil 2.2. AlexNet mimarisi

ESA, öznitelik çıkarımı ve sınıflandırma olmak üzere kısaca iki bölümden oluşmaktadır. Öznitelik çıkarımı bölümünde genel olarak giriş katmanı, evrişim katmanı, havuzlama katmanı, aktivasyon fonksiyonu katmanı ve farklı normalizasyon ve işlem katmanları bulunabilmektedir. Sınıflandırma bölümünde ise tam bağlaşımlı katman ve çıkış katmanı bulunabilmektedir. Farklı katmanlar, bu katmanların farklı dizilimleri veya farklı hiper parametreler kullanılarak birbirinden farklı birçok ESA mimarileri ortaya çıkmıştır [22].

2.2.ESA Katmanları

2.2.1. Giriş katmanı

Giriş katmanı, veri kümesinin ESA'ya beslendiği ve ön işlem yapıldığı katmandır. Bu katmanda, evrensel data normalizasyonu yapılabilmektedir. Bu normalizasyonla giriş veri kümesi, sıfır ortalama ve birim varyansa sahip olmaktadır [19].

2.2.2. Evrişim katmanı

Birim dürtü yanıtı $W(t)$ olan doğrusal ve zamanla değişmeyen bir sistemde, $I(t)$ girdisi için $S(t)$ çıktısının verildiği varsayılmaktadır. $S(t)$, $I(t)$ ile $W(t)$ 'nin evrişimiyle (konvolüsyon) elde edilmektedir. Eşitlik (2.1)'de evrişim işlemi gösterilmiştir.

$$S(t) = I(t) * W(t) = \sum_{k=-\infty}^{\infty} I(k) W(t-k) \quad (2.1)$$

ESA’da evriřim iřlemin yapıldığı katmana evriřim katmanı denilmektedir. Evriřim katmanı, ESA’nın temel katmanıdır ve iřlem yükünün en fazla olduđu katmandır [23]. Bu katman eğitilebilir ağırlıklara sahip filtreler ve eğitilebilir yanlılık (bias) parametreleri içermektedir. İleri yayılım sırasında, ilk değeri atanmış tüm filtreler, girdi boyutunca yatay ve düşey olarak kaydırılarak girdi ile nokta çarpımı hesaplanır ve son olarak yanlılık değeri eklenerek çıktı elde edilir [23]. İki boyutlu girdi $I(i,j)$ ve filtre $W(i,j)$ ’nin evriřim iřlemi Eřitlik (2.2)’de verilmiřtir.

$$S(i,j) = I(i,j) * W(i,j) = \sum_m \sum_n I(i,j) W(i-m,j-n) \quad (2.2)$$

0 ₂	4 ₀	0 ₁	2			0	4 ₂	0 ₀	2 ₁		
1 ₀	3 ₁	2 ₀	3	11	14	1	3 ₀	2 ₁	3 ₀	11	14
0 ₁	2 ₀	4 ₂	0	7	23	0	2 ₁	4 ₀	0 ₂	7	23
1	4	0	3			1	4	0	3		
0	4	0	2			0	4	0	2		
1 ₂	3 ₀	2 ₁	3	11	14	1	3 ₂	2 ₀	3 ₁	11	14
0 ₀	2 ₁	4 ₀	0	7	23	0	2 ₀	4 ₁	0 ₀	7	23
1 ₁	4 ₀	0 ₂	3			1	4 ₁	0 ₀	3 ₂		

řekil 2.3. Evriřim katmanında, 4x4 girdi ve 3x3 filtrenin evriřim iřlemi

2.2.3. Havuzlama katmanı

Havuzlama, ESA’nın önemli bir kavramıdır. Havuzlama katmanında, girdinin özellik haritasının belirlenen alt bölgelerinin maksimum, ortalama veya farklı yöntemlerle özet değeri alınarak boyut indirmesi yapılır ve iřlem yükü azaltılır. İlgili değeri alt bölgelerin özeti olarak değerlendirilmektedir ve bu özet değeri çıktı olarak atanır [23].

0	1	0	2			0	1	0	2		
1	3	2	1	3	2	1	3	2	1	3	2
0	1	4	0	1	4	0	1	4	0	1	4
1	0	0	3			1	0	0	3		
0	1	0	2			0	1	0	2		
1	3	2	1	3	2	1	3	2	1	3	2
0	1	4	0	1	4	0	1	4	0	1	4
1	0	0	3			1	0	0	3		

Şekil 2.4. Maksimum havuzlama

0	1	0	2			0	1	0	2		
1	3	2	1	1.25	1.25	1	3	2	1	1.25	1.25
0	1	4	0	0.5	1.75	0	1	4	0	0.5	1.75
1	0	0	3			1	0	0	3		
0	1	0	2			0	1	0	2		
1	3	2	1	1.25	1.25	1	3	2	1	1.25	1.25
0	1	4	0	0.5	1.75	0	1	4	0	0.5	1.75
1	0	0	3			1	0	0	3		

Şekil 2.5. Ortalama havuzlama

2.2.4. Aktivasyon fonksiyonu katmanı

Aktivasyon fonksiyonu katmanı, ESA'ya doğrusal olmayan özellik kazandırılması için kullanılmaktadır. Genellikle evrişim katmanından sonra eklenmektedir. Örnek aktivasyon fonksiyonları Çizelge 2.1'de verilmiştir [19].

Çizelge 2.1. Örnek aktivasyon fonksiyonları

Fonksiyon ismi	Eşitlik
Birim basamak	$f(x) = \begin{cases} x < 0 \text{ için } 0 \\ x \geq 0 \text{ için } 1 \end{cases}$
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$
Tanh	$\tanh(x) = 2 * \sigma(2x) - 1 = \frac{2}{1 + e^{-2x}} - 1$
ArcTan	$f(x) = \tan^{-1}(x)$
ReLU	$f(x) = \begin{cases} x < 0 \text{ için } 0 \\ x \geq 0 \text{ için } x \end{cases}$
Leaky ReLU	$f(x) = \begin{cases} x < 0 \text{ için } \lambda * x \\ x \geq 0 \text{ için } x \end{cases}$
Parametric ReLU	$f(x) = \begin{cases} x < 0 \text{ için } \lambda_k * x \\ x \geq 0 \text{ için } x \end{cases}$
Randomized ReLU	$f(x^{(n)}) = \begin{cases} x^{(n)} < 0 \text{ için } \lambda_k^{(n)} * x^{(n)} \\ x^{(n)} \geq 0 \text{ için } x^{(n)} \end{cases}$
Exponential LU	$f(x) = \begin{cases} x < 0 \text{ için } \lambda * (e^x - 1) \\ x \geq 0 \text{ için } x \end{cases}$
SoftPlus	$f(x) = \ln(1 + e^x)$
Softmax	$S_j = \frac{e^{a_j}}{\sum_{k=1}^N e^{a_k}}$

2.2.5. Yığın normalizasyonu katmanı

Yığın normalizasyonu katmanı, ağ eğitimi hızlandırmak ve ağ parametrelerinin ilk değer atama işlemine karşı hassasiyetini azaltmak için tercih edilebilmektedir. Daha çok evrişim katmanı ile aktivasyon katmanı arasında kullanılmaktadır. Yığın normalizasyonu işleminde ilk olarak Eşitlik (2.3)'te verildiği gibi, girdi x_i 'yi yığın boyunca hesaplanmış ortalama değer μ_B ve varyans σ_B^2 ile normalize etmektedir.

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (2.3)$$

Burada ϵ (Epsilon), varyans değeri çok küçük olduğunda sayısal kararlılığı artırmak için kullanılmaktadır. Girdiyi sıfır ortalama değer ve birim varyans olarak bir sonraki katmana aktarmak ideal olmadığı için ofset faktörü β ve ölçek faktörü γ Eşitlik (2.4)'te verildiği gibi girdiyi kaydırır ve ölçeklendirir. Ofset faktörü β ve ölçek faktörü γ , ağ eğitimi sırasında güncellenen eğitilebilir parametrelerdir [24].

$$y_i = \gamma \hat{x}_i + \beta \quad (2.4)$$

2.2.6. Tam bağlaşımlı katman

Tam bağlaşımlı katman, yapay sinir ağlarından oluşmaktadır. Bu katmandaki nöronlar önceki katmandaki tüm aktivasyonlarla tam bağlantılara sahiptir. Önceki katmalardan elde edilen değerler bu katmana girdi olarak verilir ve bu katmanın çıkış sayısı ise sınıf sayısına göre belirlenmektedir [17].

2.2.7. Çıkış katmanı

Çıkış katmanı, sınıflandırmanın yapıldığı katmandır. Bu katmanda genellikle softmax sınıflandırma fonksiyonu kullanılmaktadır. Softmax fonksiyonu, sınıf çıkış değerlerinin toplamı 1 olacak şekilde, çıkış değerlerini 0 ile 1 arasında limitlemektedir. Bu çıkışın olasılıksal olarak yorumlanmasını sağlamaktadır [19].

2.3. Hiper Parametreler

ESA eğitiminden önce ayarlanan tüm parametrelere hiper parametre denilmektedir. Ağ eniyileme çalışmalarında bu parametrelerin ideal değerlerinin bulunması üzerine çalışılmaktadır.

Evrişim katmanında, P miktarında dolgulama yapılan $W_g \times H_g \times D_g$ boyutlu girdiye F boyutlu ve K derinlikli filtre S adım sayısı ile uygulandığında elde edilen çıktı boyutu Eşitlik (2.5)'te verilmiştir [23].

$$W_{\zeta} = \frac{W_g - F + 2 * P}{S} + 1 \quad (2.5)$$

$$H_{\zeta} = \frac{H_g - F + 2 * P}{S} + 1$$

$$D_{\zeta} = K$$

Eğitilebilir parametrelerden, evrişim katmanında $F^2 * D_g * K$ tane ağırlık ve K tane yanlılık parametresi bulunmaktadır.

2	0	1
0	1	0
1	0	2

Şekil 2.6. Evrişim katmanında kullanılan 3x3 boyutlu örnek filtre

0	0	0	0	0	0
0	0	4	0	2	0
0	1	3	2	3	0
0	0	2	4	0	0
0	1	4	0	3	0
0	0	0	0	0	0

Şekil 2.7. $P = 1$ olmak üzere sıfır dolgulama

Havuzlama katmanında, $W_g \times H_g \times D_g$ boyutlu girdiye S adım sayısı ile F boyutlu havuzlama uygulandığında elde edilen çıktı boyutu Eşitlik (2.6)'da verilmiştir [23].


$$W_{\zeta} = \frac{W_g - F}{S} + 1 \quad (2.6)$$

$$H_{\zeta} = \frac{W_g - F}{S} + 1$$

$$D_{\zeta} = K$$

2.4. Kullanılan Ağ Mimarisi

Önerilen modelde kullanılan ESA mimarisi Şekil 2.8’de verilmiştir.



Şekil 2.8. Kullanılan ESA mimarisi


3. ÖZNİTELİK ÇIKARIM YÖNTEMLERİ

3.1. Akustik Sinyal Kaydı ve Ön İşleme

Mavic [16] ve Phantom [15] olmak üzere İHA'lara ve ortamsal gürültüye ait akustik sinyaller GRAS 46AE [25] mikrofonu kullanılarak kaydedilmiştir. Kayıtlar, örnekleme frekansını 256kHz olmak üzere dış ortamdan alınmıştır. Sınıflara ait kayıt süreleri Çizelge 3.1'de verilmiştir. 256 kHz örnekleme frekansıyla kayıt alınan bu akustik sinyaller ilgilenilen frekans aralığına göre alçak geçiren filtreden geçirilmiş ve örnekleme sayısı azaltılarak 5120 Hz'e düşürülmüştür. Kayıt mikrofonun konum bilgisi ve İHA'lardan alınan konum bilgisi kullanılarak İHA ile kayıt mikrofonu arası mesafenin 1-100 metre, 1-300 metre ve 1-500 metre arasında olduğunda alınan İHA akustik sinyal kayıtları olmak üzere üç ayrı veri kümesi oluşturulmuştur. Bu veri kümelerine ortamsal gürültüye ait akustik sinyal kayıtları da eklenmiştir. İHA'lara ait SNR bilgisi Çizelge 3.2'de verilmiştir.

Çizelge 3.1 Kayıt Süreleri

Sınıf	Kayıt Süresi (sn)
Ortamsal Gürültü	3263
Mavic	1114
Phantom	4793



Şekil 3.1. Ön işleme


Çizelge 3.2. İHA'ların mesafeye göre SNR bilgisi.

İHA \ Mesafe	1 m	100 m	300 m	500 m
Mavic	35 dB	11 dB	2 dB	-1 dB
Phantom	46 dB	21 dB	10 dB	5 dB

3.2. Kısa Zamanlı Fourier Dönüşümü

Sinyallerin frekans alanına dönüşümü, sinyal işleme alanında yaygın olarak kullanılmaktadır. Çoğu durumda, bu tür dönüşümler, zaman alanında işlemeye kıyasla daha etkili bir gösterim ve sinyallerin analiz ve hesaplama açısından daha verimli bir şekilde işlenmesini sağlamaktadır. Örneğin, zaman alanındaki evrişim işleminin frekans alanında çarpma ile eşdeğerliği nedeniyle, bir giriş sinyalinin Fourier dönüşümünü sistem transfer fonksiyonu ile çarpmak suretiyle doğrusal bir sistemin çıktısı bulunabilir [26]. Kısa zamanlı Fourier dönüşümü (KZFD), pencere fonksiyonundan geçirilmiş bir sinyalin Fourier dönüşümlerinin dizisidir. KZFD, bir sinyalin frekans bileşenlerinin zaman içinde değiştiği durumlar için belirlenmiş zaman aralıklarına göre frekans bilgisi sağlarken, standart Fourier dönüşümü, sinyali tüm zaman aralığı boyunca ortalama alınan frekans bilgisi sağlar. Kısaca, KZFD bir sinyalin frekans bilgisinin zaman içerisinde değişimini analiz etmek için kullanılan bir sinyal işleme yöntemidir. Analiz edilecek sinyal, durağan hale getirmek amacıyla segmentlere bölünür. Her bir segmentin ayrı ayrı frekans karakteristiği çıkarılır ve KZFD matrisi oluşturulur. Burada özellikle frekans çözünürlüğü ve analiz edilen frekans aralığına dikkat edilmektedir. Bununla birlikte uygulama alanına göre pencereleme fonksiyonu değişebilmektedir. Bu çalışmada kullanılan Hamming penceresinin formülü Eşitlik (3.1)'de verilmiştir [27].

$$w(n) = 0.54 - 0.46 \cos\left(2\pi \frac{n}{N}\right), 0 \leq n \leq N \quad (3.1)$$



Şekil 3.2. 128 noktalı bir Hamming penceresi

Bir sinyalin KZFD matrisinin hesaplanması için ilk olarak, seçilen pencere fonksiyonuyla belirlenmiş adım uzunluğuna göre sinyal boyunca kaydırılarak pencereleme işlemi uygulanır ve sinyal segmentlere ayrılmış olur. Sırasıyla bu segmentlerin hızlı Fourier dönüşümü (Fast Fourier Transform - FFT) alınarak KZFD matrisinin ilgili satırına atanır [28]. Segment sayısı, Eşitlik (3.2)'deki gibi bulunabilir.


$$k = \frac{N_x - L}{M - L} \quad (3.2)$$

Burada k segment sayısı, N_x orjinal sinyalin uzunluğu, L segmentlerin birbiriyle örtüşme uzunluğu ve M pencere uzunluğudur. Bir segmentin hızlı Fourier dönüşümü ise Eşitlik (3.3)'teki gibi hesaplanır. Ardışık segmentlerin hızlı Fourier dönüşümlerinden oluşturulan matris ise Eşitlik (3.4)'te ifade edildiği gibidir.

$$X_m(f) = \sum_{n=-\infty}^{\infty} x(n)g(n - mR)e^{-j2\pi fn} \quad (3.3)$$


$$STFT(m, f) = \begin{bmatrix} X_1(f) \\ X_2(f) \\ X_3(f) \\ \vdots \\ X_k(f) \end{bmatrix} \quad (3.4)$$

Burada $g(n)$ pencere fonksiyonu, $X_m(f)$, m . segmentin hızlı Fourier dönüşümü ve R pencerenin adım uzunluğudur.




Şekil 3.3. Şakıma (Chirp) sinyalinin zaman alanı görüntüsü

Örnek olarak, 1 saniyede 0 Hz'den 2 kHz'e çıkan sinüzoidal bir sinyal olarak oluşturulan şakıma sinyalinin zaman alanı görüntüsü Şekil 3.3'te gösterilmiştir. Bu değişim yine Şekil 3.4'de gösterilen ilgili sinyalin KZFD görüntüsüyle de gözlenebilmektedir.




Şekil 3.4. Şakıma (Chirp) sinyalin KZFD görüntüsü


Ortamsal gürültü, Mavic ve Phantom'a ait akustik sinyallerden elde edilen KZFD görüntüleri sırasıyla Şekil 3.5, Şekil 3.6 ve Şekil 3.7'de verilmiştir.



Şekil 3.5. Ortamsal gürültünün KZFD görüntüsü




Şekil 3.6. Mavic'in KZFD görüntüsü



Şekil 3.7. Phantom'un KZFD görüntüsü

Sınıflara ait öznelilik görüntülerin oluşturulması için kaydedilen akustik sinyaller, 250 ms uzunluğunda parçalara bölünmüştür. Her parça için bir öznelilik görüntüsü elde edilmiştir. KZFD matrisi oluşturulması aşamasında 25 ms uzunluğunda Hamming penceresi kullanılmıştır. Pencere adım uzunluğu 12.5 ms olmak üzere parçaların sırasıyla hızlı Fourier dönüşümü alınmıştır. Frekans aralığı olarak diğer frekanslarda kayda değer bir bilgi olmadığı deneylerle gözlemlenerek 200-2000Hz arası seçilmiştir. 19x46 boyutlu KZFD matrisi oluşturulmuş ve bu matris elemanlarının mutlak değeri alınmıştır. Son olarak, matris normalize edilmiş ve gri tonlamalı görüntüye dönüştürülmüştür. Şekil 3.8'de KZFD kullanılarak oluşturulan öznelilik görüntüleri sırasıyla ortamsal gürültü, Mavic ve Phantom olarak verilmiştir.




Şekil 3.8. Örnek KZFD öznelilik görüntüleri

3.3. Mel Frekans Kepstral Katsayıları

Mel frekans kepsral katsayıları (MFKK), frekanslara göre insan duyma algısının hassasiyetini dikkate alan ve akustik sinyallerin öznitelik çıkarımı için sıklıkla kullanılan bir sinyal işleme yöntemidir. 1980’lerde Davic ve Mermelstein tarafından ortaya atılmıştır. Akustik bir sinyalin kompakt bir gösteriminin veya temsiline bir dizi MFKK ile sağlanacağını göstermişlerdir. Bu katsayılar, Mel filtre bankasıyla filtrelenmiş enerji spektrumunun gerçek logaritmasına kosinüs dönüşümü uygulanarak elde edilmektedir [29]. Doğrusal frekans skalasını Mel frekans skalasına çevrimi, F_{mel} Mel frekansı ve F_{Hz} doğrusal frekans olmak üzere Eşitlik (3.5)’te verilmiştir.

$$F_{mel} = 2595 * \log_{10} \left(1 + \frac{F_{Hz}}{700} \right) \quad (3.5)$$



Şekil 3.9. Mel filtre bankası

Bir sinyalin $y(n)$ ve pencere fonksiyonunun $w(n)$ olarak ifade edildiği Eşitlik (3.6)’da sinyalin hızlı Fourier dönüşümü (Fast Fourier Transform - FFT), $Y(m)$ hesaplanmaktadır. Daha sonra güç spektrumunun formülü Eşitlik (3.7)’de verilmiştir.

$$Y(m) = \sum_{n=0}^{F-1} y(n) * w(n) * e^{-j2\pi m \frac{n}{F}} \quad (3.6)$$


$$X(m) = |Y(m)|^2 \quad (3.7)$$

$$S[k] = \sum_{j=0}^{\frac{F}{2}-1} W_k(j) * X(j), 1 \leq k \leq M \quad (3.8)$$

$$C[n] = \sum_{k=1}^M \log(S[k]) * \cos \left[n * (k - 0.5) * \frac{\pi}{M} \right], 1 \leq n \leq L \quad (3.9)$$


$W_k(j)$, Mel skalasında oluşturulmuş Şekil 3.9’da gösterilen üçgen filtre bankalarıdır ve M filtre bankası sayısıdır. Eşitlik (3.9)’de ayrık cosinüs dönüşümü uygulanarak Mel frekans kestral katsayıları, C elde edilmektedir. Burada L katsayı sayısıdır.

Örnek olarak, 1 saniyede 0 Hz’den 2 kHz’e çıkan sinüzoidal bir sinyal olarak oluşturulan şakıma sinyalinin MFKK görüntüsü Şekil 3.10’da verilmiştir.




Şekil 3.10. Şakıma (Chirp) sinyalin MFKK görüntüsü


Ortamsal gürültü, Mavic ve Phantom’a ait akustik sinyallerden elde edilen MFKK görüntüleri sırasıyla Şekil 3.11, Şekil 3.12 ve Şekil 3.13’de verilmiştir.



Şekil 3.11. Ortamsal gürültünün MFKK görüntüsü




Şekil 3.12. Mavic'in MFKK görüntüsü



Şekil 3.13. Phantom'un MFKK görüntüsü

KZFD yöntemine benzer olarak, sınıflara ait öznitelik görüntülerinin oluşturulması için kaydedilen akustik sinyaller, 250 ms uzunluğunda her biri öznitelik görüntüsüne dönüştürülecek parçalara bölünmüştür. Her parça sinyal, 25 ms uzunluğunda Hamming penceresiyle segmentlere ayrılmış ve her segmentin ayrı ayrı Mel frekans kepsstral katsayıları hesaplanmıştır. Pencere adım uzunluğu 12.5 ms olmak üzere parçaların sırasıyla hızlı Fourier dönüşümü alınmıştır. Bu şekilde MFKK matrisinin oluşturulması amaçlanmıştır. Katsayı sayısı 28 olarak belirlenmiştir. 19x28 boyutlu MFKK matrisi oluşturulmuş, son olarak matris normalize edilmiş ve gri tonlamalı görüntüye dönüştürülmüştür. Şekil 3.14'de MFCC kullanılarak oluşturulan öznitelik görüntüleri sırasıyla ortamsal gürültü, Mavic, Phantom olarak verilmiştir.



Şekil 3.14. Örnek MFKK öznitelik görüntüleri

3.4. Gramian Açısal Alan Dönüşümü

Gramian açısal alan dönüşümüyle (GAAD) bir vektör, vektör elemanlarının arasındaki trigonometrik toplam ile oluşturulan Gramian matrisi olarak polar koordinat sisteminde temsil edilir. Gramian matrisinde, her eleman açı toplamalarının kosinüsüdür [30].


$$\tilde{x}_i = \frac{x_i - \min(X)}{\max(X) - \min(X)}; i = 1, 2, \dots, n \quad (3.10)$$

$$\theta_i = \arccos(\tilde{x}_i), \tilde{x}_i \in X; i = 1, 2, \dots, n \quad (3.11)$$

$$G = \begin{bmatrix} \cos(\theta_1 + \theta_1) & \cdots & \cos(\theta_1 + \theta_n) \\ \cos(\theta_2 + \theta_1) & \cdots & \cos(\theta_2 + \theta_n) \\ \vdots & \ddots & \vdots \\ \cos(\theta_n + \theta_1) & \cdots & \cos(\theta_n + \theta_n) \end{bmatrix} \quad (3.12)$$


Burada, $X = [x_1, x_2 \dots x_n]$ n uzunluğunda bir vektör ve $\tilde{x}_i$ ölçeklenmiş bir değerdir. Eşitlik (3.10)'da gösterildiği gibi normalize edilen X vektörü, Eşitlik (3.11) uygulanarak polar koordinat düzleminde gösterilmiştir. θ_i ise dönüştürülmüş açısal değerlerdir. Eşitlik (3.12)'de gösterildiği gibi açısal değerlerle X vektörünün Gramian açısal alan matrisi G elde edilmektedir.

Örnek olarak, Şekil 3.15'te bir vektörün Gramian açısal alan dönüşümü gösterilmiştir.




Şekil 3.15. GAAD örneği


Ortamsal gürültü, Mavic ve Phantom'a ait akustik sinyallerden elde edilen GAAD görüntüleri sırasıyla Şekil 3.16, Şekil 3.17 ve Şekil 3.18'de verilmiştir.



Şekil 3.16. Ortamsal gürültünün GAAD görüntüsü




Şekil 3.17. Mavic'in GAAD görüntüsü



Şekil 3.18. Phantom'un GAAD görüntüsü

GAAD yönteminde, öznitelik görüntülerinin oluşturulması için sinyaller, 25 ms uzunluğunda her biri öznitelik görüntüsüne dönüştürülecek parçalara bölünmüştür. Her parça, 25 ms uzunluğunda Hamming penceresinden geçirilerek hızlı Fourier dönüşümü (Fast Fourier Transform - FFT) alınır. İlgilenilen frekans bandına göre kırıldıktan sonra 1x46 boyutlu vektör oluşturulmuştur. Bu vektörlerden GAAD metoduyla 46x46 boyutlu GAAD matrisi oluşturulmuştur. Matrisler normalize edilmiş ve gri tonlamalı görüntüye dönüştürülmüştür. Şekil 3.19'de GAAD kullanılarak oluşturulan öznitelik görüntüleri sırasıyla ortamsal gürültü, Mavic, Phantom olarak verilmiştir.



Şekil 3.19. Örnek GAAD öznitelik görüntüleri

4. DENEYSEL SONUÇLAR

Ortam gürültüsü, Mavic ve Phantom sınıfları sırasıyla Sınıf-1, Sınıf-2 ve Sınıf-3 olarak temsil edilmektedirler. Veri kümesi-1 (1-100m), Veri kümesi-2 (1-300m) ve Veri kümesi-3 (1-500m)'e sırasıyla KZFD öznitelik çıkarım yöntemi uygulanarak elde edilen öznitelik görüntü sayıları sınıflara göre ayrı ayrı Çizelge 4.1'de verilmiştir. Benzer şekilde veri kümelerine, MFKK öznitelik çıkarım yöntemi uygulanarak elde edilen görüntü sayıları Çizelge 4.2'de ve GAAD öznitelik çıkarım yöntemi uygulanarak elde edilen görüntü sayıları Çizelge 4.3'te verilmiştir. Önerilen model Matlab Deep Learning Toolbox [31] kullanılarak, 12 core 2.67 GHz CPU, 24 GB RAM ve NVIDIA GeForce GTX 1080 Ti GPU donanımsal bileşenlerine sahip bir bilgisayar ortamında gerçekleştirilmiş ve test edilmiştir. Deneylerde toplam öznitelik görüntüsü sayısının %80'i ağ eğitiminde, %10'u ağ eğitim doğrulamasında ve %10'u test için kullanılmıştır. Her ağ eğitimi, momentumlu stokastik eğim inişi (Stochastic Gradient Descent with Momentum) [32] algoritmasıyla 50 tur yapılmıştır.

Çizelge 4.1. KZFD yöntemiyle oluşturulan öznitelik görüntüsü sayısı

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
Veri kümesi-1 (1-100m)	11420	110	882
Veri kümesi-2 (1-300m)	11420	1385	6883
Veri kümesi-3 (1-500m)	11420	3821	11521

Çizelge 4.2. MFKK yöntemiyle oluşturulan öznitelik görüntüsü sayısı

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
Veri kümesi-1 (1-100m)	11420	110	882
Veri kümesi-2 (1-300m)	11420	1385	6883
Veri kümesi-3 (1-500m)	11420	3821	11521

Çizelge 4.3. GAAD yöntemiyle oluşturulan öznelik görüntüsü sayısı

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
Veri kümesi-1 (1-100m)	81800	1094	5906
Veri kümesi-2 (1-300m)	81800	13796	43310
Veri kümesi-3 (1-500m)	81800	38092	72956

Sonuç değerlendirmesi için sınıflandırma çalışmalarında sıklıkla kullanılan hata matrisi diğer adıyla karmaşıklık matrisi (confusion matrix) kullanılmıştır. Hata matrisi, test verilerine göre bir sınıflandırıcının sınıflandırma performansını özetlemektedir. Bir boyutu, örneklerin gerçek sınıfları, diğer boyutu, örneklerin sınıflandırıcı tarafından atandığı sınıfları olmak üzere iki boyutlu bir matristir. Ayrıca hata matrisinde, gerçek sınıf ve tahmin edilen sınıf olacak şekilde örnek sayılarını her bir sınıf için verilmektedir [35]. Bu matris aracılığıyla genel doğruluk (overall-accuracy), kesinlik (precision), duyarlılık (recall) ve f-ölçüm (f-score) metrikleri hesaplanmıştır. Bu metriklerin hesaplanabilmesi için doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) parametrelerinin bilinmesi ve hata matrisi aracılığıyla hesaplanması gerekmektedir. Bu parametreler her bir sınıf için ayrı ayrı hesaplanmaktadır. Bir sınıfın DP değeri, o sınıfın doğru tahmin edilen örnek sayısıdır. Bir sınıfın DN değeri ise sınıflandırıcı tarafından o sınıf olarak tahmin edilmeyen ve aynı zamanda doğru sınıfa atanan örnek sayısıdır. DP ve DN, sınıflandırıcının doğru tahmin sayılarıdır. Bunların aksine, bir sınıfın YP değeri, o sınıfa hatalı atanan örnek sayısıdır. Bir sınıfın YN değeri ise o sınıfa ait olup farklı sınıflara atanan örnek sayısıdır [33]. Bu parametrelerin hesaplanması örnek olarak Çizelge 4.4’te verilmiştir.

Tahmin Edilen Sınıf	1	A	B	C	
	2	D	E	F	
	3	G	H	I	
		1	2	3	
		Gerçek Sınıf			

Şekil 4.1 Üç sınıflı örnek hata matrisi

Çizelge 4.4 Örnek hata matrisi parametre değerleri

	DP	DN	YP	YN
1.sınıf	A	E+I	B+C	D+G
2.sınıf	E	A+I	D+F	B+H
3.sınıf	I	A+E	G+H	C+F

Üç veri kümesine ayrı ayrı uygulanan üç öznitelik görüntüsü çıkarım yöntemi aracılığıyla üretilen öznitelik görüntüleriyle dokuz farklı durumda ESA eğitilmiş ve test edilmiştir. Veri kümesi-1'e KZFD, MFKK ve GAAD yöntemleri uygulanarak oluşturulan öznitelik görüntüleriyle yapılan testler sırasıyla Test-1, Test-2 ve Test-3 olarak adlandırılmıştır. Benzer sırayla veri kümesi-2 ile Test-4, Test-5 ve Test-6 ve veri kümesi-3 ile Test-7, Test-8 ve Test-9 adlı testler yapılmıştır. Bu testlerin sonuçlarına göre oluşturulan hata matrisleri Şekil 4.2 ile Şekil 4.10 arasındaki şekillerde verilmiştir.

Tahmin Edilen Sınıf	1	1132 91.2%	0 0.0%	8 0.6%	99.3% 0.7%
	2	0 0.0%	11 0.9%	0 0.0%	100% 0.0%
	3	10 0.8%	0 0.0%	80 6.4%	88.9% 11.1%
		99.1% 0.9%	100% 0.0%	90.9% 9.1%	98.5% 1.5%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.2. Test-1 (Veri kümesi-1, KZFD) sonuçlarına göre hata matrisi

Test-1'in sonuçlarına göre oluşturulan hata matrisi Şekil 4.2'de verilmiştir. Matrise göre 1142 adet ortamsal gürültü (Sınıf-1) öznitelik görüntüsü, 11 adet Mavic (Sınıf-2) öznitelik görüntüsü ve 88 adet Phantom (Sınıf-3) öznitelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %99.1 ve kesinlik değerinin %99.3, Sınıf-2'in duyarlılık değerinin %100 ve kesinlik değerinin %100 ve Sınıf-3'in duyarlılık değerinin %90.9 ve kesinlik değerinin %88.9 olduğu görülmüştür. Bununla birlikte Test-1 genel doğruluk değerinin %98.5 olduğu görülmüştür.

Çizelge 4.5. Test-1 hata matrisi parametreleri.

	DP	DN	YP	YN
1.sınıf	1132	91	8	10
2.sınıf	11	1212	0	0
3.sınıf	80	1143	10	8

Tahmin Edilen Sınıf	1	1138 91.7%	0 0.0%	16 1.3%	98.6% 1.4%
	2	0 0.0%	10 0.8%	0 0.0%	100% 0.0%
	3	4 0.3%	1 0.1%	72 5.8%	93.5% 6.5%
		99.6% 0.4%	90.9% 9.1%	81.8% 18.2%	98.3% 1.7%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.3. Test-2 (Veri kümesi-1, MFKK) sonuçlarına göre hata matrisi

Test-2'nin sonuçlarına göre oluşturulan hata matrisi Şekil 4.3'te verilmiştir. Matrise göre 1142 adet ortamsal gürültü (Sınıf-1) öznitelik görüntüsü, 11 adet Mavic (Sınıf-2) öznitelik görüntüsü ve 88 adet Phantom (Sınıf-3) öznitelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %99.6 ve kesinlik değerinin %98.6, Sınıf-2'in duyarlılık değerinin %90.9 ve kesinlik değerinin %100 ve Sınıf-3'in duyarlılık değerinin %81.8 ve kesinlik değerinin %93.5 olduğu görülmüştür. Bununla birlikte Test-2 genel doğruluk değerinin %98.3 olduğu görülmüştür.

Çizelge 4.6. Test-2 hata matrisi parametreleri.

	DP	DN	YP	YN
1.sınıf	1138	82	16	4
2.sınıf	10	1210	0	1
3.sınıf	72	1148	5	16

Tahmin Edilen Sınıf	1	8008 90.2%	13 0.1%	224 2.5%	97.1% 2.9%
	2	5 0.1%	92 1.0%	6 0.1%	89.3% 10.7%
	3	167 1.9%	4 0.0%	361 4.1%	67.9% 32.1%
		97.9% 2.1%	84.4% 15.6%	61.1% 38.9%	95.3% 4.7%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.4. Test-3 (Veri kümesi-1, GAAD) sonuçlarına göre hata matrisi

Test-3'ün sonuçlarına göre oluşturulan hata matrisi Şekil 4.4'te verilmiştir. Matrise göre 8180 adet ortamsal gürültü (Sınıf-1) öznitelik görüntüsü, 109 adet Mavic (Sınıf-2) öznitelik görüntüsü ve 591 adet Phantom (Sınıf-3) öznitelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %97.9 ve kesinlik değerinin %97.1, Sınıf-2'in duyarlılık değerinin %84.4 ve kesinlik değerinin %89.3 ve Sınıf-3'in duyarlılık değerinin %61.1 ve kesinlik değerinin %67.9 olduğu görülmüştür. Bununla birlikte Test-3 genel doğruluk değerinin %95.3 olduğu görülmüştür.

Çizelge 4.7. Test-3 hata matrisi parametreleri.

	DP	DN	YP	YN
1.sınıf	8008	453	237	172
2.sınıf	92	8369	11	17
3.sınıf	361	8100	171	230

Tahmin Edilen Sınıf	1	1065 54.1%	14 0.7%	91 4.6%	91.0% 9.0%
	2	8 0.4%	109 5.5%	10 0.5%	85.8% 14.2%
	3	69 3.5%	15 0.8%	587 29.8%	87.5% 12.5%
		93.3% 6.7%	79.0% 21.0%	85.3% 14.7%	89.5% 10.5%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.5. Test-4 (Veri kümesi-2, KZFD) sonuçlarına göre hata matrisi

Test-4'ün sonuçlarına göre oluşturulan hata matrisi Şekil 4.5'te verilmiştir. Matrise göre 1142 adet ortamsal gürültü (Sınıf-1) öznitelik görüntüsü, 138 adet Mavic (Sınıf-2) öznitelik görüntüsü ve 688 adet Phantom (Sınıf-3) öznitelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %93.3 ve kesinlik değerinin %91.0, Sınıf-2'in duyarlılık değerinin %79.0 ve kesinlik değerinin %85.8 ve Sınıf-3'in duyarlılık değerinin %85.3 ve kesinlik değerinin %87.5 olduğu görülmüştür. Bununla birlikte Test-4 genel doğruluk değerinin %89.5 olduğu görülmüştür.

Çizelge 4.8. Test-4 hata matrisi parametreleri.

	DP	DN	YP	YN
1.sınıf	1065	696	105	77
2.sınıf	109	1652	18	29
3.sınıf	587	1174	84	101

Tahmin Edilen Sınıf	1	2	3	
	1027 52.2%	33 1.7%	121 6.1%	87.0% 13.0%
	15 0.8%	79 4.0%	15 0.8%	72.5% 27.5%
	100 5.1%	26 1.3%	552 28.0%	81.4% 18.6%
				89.9% 10.1%
				57.2% 42.8%
				80.2% 19.8%
				84.2% 15.8%
				Gerçek Sınıf
				1 2 3

Şekil 4.6. Test-5 (Veri kümesi-2, MFKK) sonuçlarına göre hata matrisi

Test-5'in sonuçlarına göre oluşturulan hata matrisi Şekil 4.6'da verilmiştir. Matrise göre 1142 adet ortamsal gürültü (Sınıf-1) öznelik görüntüsü, 138 adet Mavic (Sınıf-2) öznelik görüntüsü ve 688 adet Phantom (Sınıf-3) öznelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %89.9 ve kesinlik değerinin %87.0, Sınıf-2'in duyarlılık değerinin %57.2 ve kesinlik değerinin %72.5 ve Sınıf-3'in duyarlılık değerinin %80.2 ve kesinlik değerinin %81.4 olduğu görülmüştür. Bununla birlikte Test-5 genel doğruluk değerinin %84.2 olduğu görülmüştür.

Çizelge 4.9. Test-5 hata matrisi parametreleri

	DP	DN	YP	YN
1.sınıf	1027	631	154	115
2.sınıf	79	1579	30	59
3.sınıf	552	1106	126	136

Tahmin Edilen Sınıf	1	7408 53.3%	566 4.1%	1803 13.0%	75.8% 24.2%
	2	406 2.9%	719 5.2%	277 2.0%	51.3% 48.7%
	3	366 2.6%	95 0.7%	2251 16.2%	83.0% 17.0%
		90.6% 9.4%	52.1% 47.9%	52.0% 48.0%	74.7% 25.3%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.7. Test-6 (Veri kümesi-2, GAAD) sonuçlarına göre hata matrisi

Test-6'nın sonuçlarına göre oluşturulan hata matrisi Şekil 4.7'de verilmiştir. Matrise göre 8180 adet ortamsal gürültü (Sınıf-1) öznelik görüntüsü, 1380 adet Mavic (Sınıf-2) öznelik görüntüsü ve 4331 adet Phantom (Sınıf-3) öznelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %90.6 ve kesinlik değerinin %75.8, Sınıf-2'in duyarlılık değerinin %52.1 ve kesinlik değerinin %51.3 ve Sınıf-3'in duyarlılık değerinin %52.0 ve kesinlik değerinin %83.0 olduğu görülmüştür. Bununla birlikte Test-6 genel doğruluk değerinin %74.7 olduğu görülmüştür.

Çizelge 4.10. Test-6 hata matrisi parametreleri

	DP	DN	YP	YN
1.sınıf	7408	2970	2369	772
2.sınıf	719	9659	683	661
3.sınıf	2251	8127	461	2080

Tahmin Edilen Sınıf	1	1000 37.4%	27 1.0%	207 7.7%	81.0% 19.0%
	2	16 0.6%	331 12.4%	15 0.6%	91.4% 8.6%
	3	126 4.7%	24 0.9%	930 34.8%	86.1% 13.9%
		87.6% 12.4%	86.6% 13.4%	80.7% 19.3%	84.5% 15.5%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.8. Test-7 (Veri kümesi-3, KZFD) sonuçlarına göre hata matrisi

Test-7'nin sonuçlarına göre oluşturulan hata matrisi Şekil 4.8'de verilmiştir. Matrise göre 1142 adet ortamsal gürültü (Sınıf-1) öznelik görüntüsü, 382 adet Mavic (Sınıf-2) öznelik görüntüsü ve 1152 adet Phantom (Sınıf-3) öznelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %87.6 ve kesinlik değerinin %81.0, Sınıf-2'in duyarlılık değerinin %86.6 ve kesinlik değerinin %91.4 ve Sınıf-3'in duyarlılık değerinin %80.7 ve kesinlik değerinin %86.1 olduğu görülmüştür. Bununla birlikte Test-7 genel doğruluk değerinin %84.5 olduğu görülmüştür.

Çizelge 4.11. Test-7 hata matrisi parametreleri

	DP	DN	YP	YN
1.sınıf	1000	1261	234	142
2.sınıf	331	1930	31	51
3.sınıf	930	1331	150	222

Tahmin Edilen Sınıf	1	958 35.8%	56 2.1%	235 8.8%	76.7% 23.3%
	2	43 1.6%	277 10.4%	36 1.3%	77.8% 22.2%
	3	141 5.3%	49 1.8%	881 32.9%	82.3% 17.7%
		83.9% 16.1%	72.5% 27.5%	76.5% 23.5%	79.1% 20.9%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.9. Test-8 (Veri kümesi-3, MFKK) sonuçlarına göre hata matrisi

Test-8'in sonuçlarına göre oluşturulan hata matrisi Şekil 4.9'da verilmiştir. Matrise göre 1142 adet ortamsal gürültü (Sınıf-1) öznitelik görüntüsü, 382 adet Mavic (Sınıf-2) öznitelik görüntüsü ve 1152 adet Phantom (Sınıf-3) öznitelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %83.9 ve kesinlik değerinin %76.7, Sınıf-2'in duyarlılık değerinin %72.5 ve kesinlik değerinin %77.8 ve Sınıf-3'in duyarlılık değerinin %76.5 ve kesinlik değerinin %82.3 olduğu görülmüştür. Bununla birlikte Test-8 genel doğruluk değerinin %79.1 olduğu görülmüştür.

Çizelge 4.12. Test-8 hata matrisi parametreleri

	DP	DN	YP	YN
1.sınıf	958	1158	291	184
2.sınıf	277	1839	79	105
3.sınıf	881	1235	190	271

Tahmin Edilen Sınıf	1	3876 20.1%	464 2.4%	1148 6.0%	70.6% 29.4%
	2	1503 7.8%	2761 14.3%	657 3.4%	56.1% 43.9%
	3	2801 14.5%	584 3.0%	5491 28.5%	61.9% 38.1%
		47.4% 52.6%	72.5% 27.5%	75.3% 24.7%	62.9% 37.1%
		1	2	3	
		Gerçek Sınıf			

Şekil 4.10. Test-9 (Veri kümesi-3, GAAD) sonuçlarına göre hata matrisi

Test-9'un sonuçlarına göre oluşturulan hata matrisi Şekil 4.10'da verilmiştir. Matrise göre 8180 adet ortamsal gürültü (Sınıf-1) öznelik görüntüsü, 3809 adet Mavic (Sınıf-2) öznelik görüntüsü ve 7296 adet Phantom (Sınıf-3) öznelik görüntüsü test edilmiştir. Sınıf-1'in duyarlılık değerinin %47.4 ve kesinlik değerinin %70.6, Sınıf-2'in duyarlılık değerinin %72.5 ve kesinlik değerinin %56.1 ve Sınıf-3'in duyarlılık değerinin %75.3 ve kesinlik değerinin %61.9 olduğu görülmüştür. Bununla birlikte Test-9 genel doğruluk değerinin %62.9 olduğu görülmüştür.

Çizelge 4.13. Test-9 hata matrisi parametreleri

	DP	DN	YP	YN
1.sınıf	3876	8252	1612	4304
2.sınıf	2761	9367	2160	1048
3.sınıf	5491	6637	3385	1805


Genel doğruluk (overall-accuracy), genel olarak doğru tahmin sayısının değerlendirilen toplam örnek sayısına oranıdır. Kesinlik, sınıflandırıcı tarafından bir sınıf olarak doğru tahmin edilen örnek sayısının ilgili sınıf olarak tahmin edilen toplam örnek sayısına oranıdır. Örneğin; “İHA olarak tahmin edilen öznitelik görüntülerinden yüzde kaç İHA’dır?” sorusu kesinlik metriği ile yanıtlanmaktadır. Duyarlılık, bir sınıfa ait örneklerden doğru tahmin edilen örnek sayısının o sınıfa ait toplam örnek sayısına oranı olarak belirtilmektedir. Örneğin; “İHA öznitelik görüntülerinden yüzde kaç İHA olarak tahmin edildi?” sorusu duyarlılık metriği ile yanıtlanmaktadır. F-ölçüm, kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır [33].

$$\text{Genel Doğruluk} = \frac{\text{Doğru tahmin yapılan örnek sayısı}}{\text{Tahmin yapılan toplam örnek sayısı}} \quad (4.1)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (4.2)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (4.3)$$

$$F - \text{ölçüm} = \frac{2 * \text{kesinlik} * \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (4.4)$$



Şekil 4.11. Sınıflandırma genel doğruluk metriği değerleri

Şekil 4.11’de tüm testlerin genel doğruluk değerleri verilmiştir. Ancak sınıflandırma çalışmalarında, sınıflara ait test edilen örnek sayılarının birbirinden önemli derecede farklı olması durumunda performans değerlendirmesi için doğruluk metriği yerine f-ölçüm metriği kullanılmaktadır [34]. Bu durumdan dolayı test sonuçlarını f-ölçüm metriği de hesaplanarak değerlendirilmiştir. Veri kümelerine göre test sonuçlarından hesaplanan kesinlik ve duyarlılık metriği değerleri Çizelge 4.14-Çizelge 4.19 arasındaki çizelgelerde verilmiştir.

Çizelge 4.14. Test-1, Test-2 ve Test-3 için kesinlik değerleri

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
KZFD	%99.3	%100	%88.9
MFKK	%98.6	%100	%93.5
GAAD	%97.1	%89.3	%67.9

Çizelge 4.15. Test-4, Test-5 ve Test-6 için kesinlik değerleri

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
KZFD	%91.0	%85.8	%87.5
MFKK	%87.0	%72.5	%81.4
GAAD	%75.8	%51.3	%83.0

Çizelge 4.16. Test-7, Test-8 ve Test-9 için kesinlik değerleri

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
KZFD	%81.0	%91.4	%86.1
MFKK	%76.7	%77.8	%82.3
GAAD	%70.6	%56.1	%61.9

Çizelge 4.17. Test-1, Test-2 ve Test-3 için duyarlılık değerleri

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
KZFD	%99.1	%100	%90.9
MFKK	%99.6	%90.9	%81.8
GAAD	%97.9	%84.4	%61.1

Çizelge 4.18. Test-4, Test-5 ve Test-6 için duyarlılık değerleri

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
KZFD	%93.3	%79.0	%85.3
MFKK	%89.9	%57.2	%80.2
GAAD	%90.6	%52.1	%52.0

Çizelge 4.19. Test-7, Test-8 ve Test-9 için duyarlılık değerleri

	Ortam gürültüsü (Sınıf-1)	Mavic (Sınıf-2)	Phantom (Sınıf-3)
KZFD	%87.6	%86.6	%80.7
MFKK	%83.9	%72.5	%76.5
GAAD	%47.4	%72.5	%75.3

Sınıflara ait kesinlik ve duyarlılık metrikleri kullanılarak sınıflandırıcıya ait makro kesinlik ve makro duyarlılık metrikleri hesaplanmıştır. Ayrıca makro kesinlik ve makro duyarlılık metriklerinin harmonik ortalaması alınarak makro f-ölçüm metriği hesaplanmıştır [34].

$$Kesinlik_M = \frac{\sum_{i=1}^l \frac{DP_i}{DP_i + YP_i}}{l} \quad (4.5)$$

$$Duyarlılık_M = \frac{\sum_{i=1}^l \frac{DP_i}{DP_i + YN_i}}{l} \quad (4.6)$$


$$F - \text{ölçüm}_M = \frac{2 * kesinlik_M * duyarlılık_M}{kesinlik_M + duyarlılık_M} \quad (4.7)$$

Çizelge 4.20 Tüm testleri için makro kesinlik değerleri

	Veri kümesi-1 (1-100m)	Veri kümesi-2 (1-300m)	Veri kümesi-3 (1-500m)
KZFD	%96.1 (Test-1)	%88.1 (Test-4)	%86.2 (Test-7)
MFKK	%97.4 (Test-2)	%80.3 (Test-5)	%78.9 (Test-8)
GAAD	%84.8 (Test-3)	%70.0 (Test-6)	%62.9 (Test-9)

Çizelge 4.21 Tüm testler için makro duyarlılık değerleri.


	Veri kümesi-1 (1-100m)	Veri kümesi-2 (1-300m)	Veri kümesi-3 (1-500m)
KZFD	%96.7 (Test-1)	%85.9 (Test-4)	%85.0 (Test-7)
MFKK	%90.8 (Test-2)	%75.8 (Test-5)	%77.6 (Test-8)
GAAD	%81.1 (Test-3)	%64.9 (Test-6)	%65.0 (Test-9)




Şekil 4.12. Sınıflandırma makro f-ölçüm metriği değerleri

Şekil 4.12’de tüm testlerin makro f-ölçüm değerleri verilmiştir. KZFD, MFKK ve GAAD yöntemlerinin, yüksek SNR’a sahip akustik sinyalleri içeren veri kümesi-1 kullanılarak oluşturulan öznitelik görüntüleriyle yapılan testlerde yüksek f-ölçüm seviyelerine ulaştığı görülmüştür. Beklendiği gibi daha düşük SNR içeren akustik sinyallerin eklendiği veri kümesi-2 kullanıldığında bu değerlerin düştüğü ve veri kümesi-3 kullanıldığında biraz daha düştüğü görülmektedir. Sonuçlara göre, KZFD yönteminin öznitelik çıkarımı için diğer yöntemlere göre daha güçlü olduğu değerlendirilmiştir. Buna ek olarak, MFKK yönteminin de GAAD yöntemine göre daha güçlü olduğu görülmektedir.

Ortamsal gürültü sınıf “İHA değil”, Mavic ve Phantom sınıfları “İHA” etiketli olacak şekilde tespit değerlendirmesi yapılmıştır. Sınıflandırma performans değerlendirmesine paralel olarak genel doğruluk ve makro f-ölçüm metriği değerleri hesaplanmış ve sırasıyla Şekil 4.13’te ve Şekil 4.14’te verilmiştir. Önerilen modelin tespit başarısında yüksek SNR’a sahip sinyallerle yapılan testlerde yüksek performans sergilediği gösterilmiştir. Beklendiği gibi SNR düştüğünde tespit başarısı da düşmektedir. Bununla birlikte, KZFD öznetelik çıkarım yönteminin MFKK’dan ve MFKK’nın da GAAD yönteminden daha güçlü öznetelik çıkarımı yapıldığı sonuçlara göre değerlendirilmiştir.



Şekil 4.13. Tespit genel doğruluk metriği değerleri



Şekil 4.14. Tespit makro f-ölçüm metriği değerleri

5. SONUÇ

Bu tez çalışmasında, güvenli bölgelerin tehditlerden korunması amacıyla insansız hava araçlarının tespiti ve sınıflandırılması için bir model önerilmiştir. Bu model sırasıyla, insansız hava araçlarının ve ortamsal gürültünün akustik sinyal kaydı ve önilem, akustik kayıtlar kullanılarak insansız hava araçlarına ve ortamsal gürültüye ait öznelik görüntülerinin oluşturulması ve öznelik görüntülerinin sınıflandırılması olmak üzere üç ana bloktan oluşmaktadır. Öznelik görüntülerinin oluşturulması için kısa zamanlı Fourier dönüşümü, Mel frekans kepsral katsayıları ve Gramian açısai alan dönüşümü kullanılarak üç yöntem önerilmiştir. Öznelik görüntülerinin sınıflandırılması için derin öğrenme algoritması olan evrişimsel sinir ağıları araştırılmıştır.

Önerilen modeli gerçeklemek için dış ortamda insansız hava araçlarına ve ortamsal gürültüye ait akustik sinyaller kaydedilmiştir. İnsansız hava aracı olarak Mavic ve Phantom kullanılmıştır. Modelin mesafe göre başarısını değerlendirmek için insansız hava araçlarına ait akustik sinyaller kayıt mikrofonuyla insansız hava aracı arasındaki mesafeye üç veri kümesi oluşturulmuştur. Bu mesafe 1-100 metre arasındayken alınan akustik sinyal kayıtları veri kümesi-1, 1-300 metre arasındayken alınan akustik sinyal kayıtları veri kümesi-2 ve 1-500 metre arasındayken alınan akustik sinyal kayıtları veri kümesi-3 olarak belirlenmiştir. Ayrıca bu veri kümelerine ortamsal gürültünün akustik sinyal kayıtları da eklenmiştir. Veri kümeleri kullanılarak üç öznelik görüntüsü çıkarım yöntemiyle ortamsal gürültü, Mavic ve Phantom olmak üzere üç sınıfa ait öznelik görüntüleri oluşturulmuştur. Böylece önerilen modeli, üç öznelik görüntüsü çıkarım yöntemi ve mesafe karşısında performans değerlendirmesi yapılmıştır. Sonuç değerlendirmesinde, sınıflandırma çalışmalarında sıklıkla kullanılan hata matrisi kullanılmıştır. Sınıflara ait örnek sayıları arasındaki önemli farklılık durumunda genel değerlendirme ölçütü olarak kullanılan makro f-ölçüm metriği hata matrisine göre hesaplanmıştır. Sonuç olarak, önerilen model, kısa zamanlı Fourier dönüşümü kullanılarak uygulanan öznelik görüntüsü çıkarım yöntemiyle, veri kümesi-1’de %96.4, veri kümesi-2’de %87.0 ve veri kümesi-3’de %85.6, Mel frekansı kepsral katsayıları kullanılarak uygulanan öznelik görüntüsü çıkarım yöntemiyle, veri kümesi-1’de %94.0, veri kümesi-2’de %78.0 ve veri kümesi-3’de %78.3 ve Gramian açısai alan dönüşümü kullanılarak uygulanan öznelik görüntüsü çıkarım yöntemiyle, veri kümesi-1’de %82.9, veri kümesi-2’de %67.4 ve veri kümesi-3’de %63.9 sınıflandırma başarısı göstermiştir. Ortamsal gürültü “insansız hava aracı değil”, Mavic ve Phantom “insansız hava aracı”

etiketleriyle tespit performans deęerlendirmesi yapılmıřtır. Önerilen model, kısa zamanlı Fourier dönüşümü kullanılarak uygulanan öznitelik görüntüsü çıkarım yöntemiyle, veri kümesi-1’de %95.1, veri kümesi-2’de %90.5 ve veri kümesi-3’de %85.9, Mel frekansı kepsral katsayıları kullanılarak uygulanan öznitelik görüntüsü çıkarım yöntemiyle, veri kümesi-1’de %94.3, veri kümesi-2’de %85.9 ve veri kümesi-3’de %82.2 ve Gramian açısai alan dönüşümü kullanılarak uygulanan öznitelik görüntüsü çıkarım yöntemiyle, veri kümesi-1’de %83.5, veri kümesi-2’de %76.5 ve veri kümesi-3’de %68.0 tespit başarısı göstermiştir.

İleri çalışmalarda, $1 \times N$ boyutlu vektörden $N \times N$ boyutlu matris oluşturan Gramian açısai alan dönüşümünün boyut indirgemesi yapılarak verimlilięinin artırılabilceęi deęerlendirilmektedir. Önerilen modelin genel olarak başarısının artırılması için evriřimli sinir aęları ve hiper parametreler üzerinde eniyileme çalışmaları yapılabileceęi deęerlendirilmektedir. Çok çeřitli insansız hava araçlarının akustik sinyal kayıtlarının alınmasıyla geniş kapsamlı olacak řekilde tespit ve sınıflandırma çalışması yapılarak önerilen modelin bir ürün haline getirilebileceęi deęerlendirilmektedir.

KAYNAKLAR

1. Hassanalian M., Abdelkefi A. (2017). Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*. 91,99–131.
2. Shakhathreh H., Sawalmeh A. H., Al-Fuqaha A., Dou Z., Almaita E., Khalil I., Othman N.S., Khreishah A., Guizani M. (2019). *Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges*. IEEE Access 7, 48572–48634.
3. İnternet: Kelly T.(2017). The Booming Demand for Commercial Drone Pilots. URL: <https://www.theatlantic.com/technology/archive/2017/01/drone-pilot-school/515022/>, Son Erişim Tarihi: 30.11.2019.
4. İnternet: The Drone Market Report 2019. URL: <https://www.droneii.com/project/drone-market-report>, Son Erişim Tarihi: 18.11.2019.
5. Kaleem Z., Rehmani M. H., Ahmed E., Jamalipour A., Rodrigues J. JPC., Moustafa H., Guibene W. (2018). *Amateur Drone Surveillance: Applications, Architectures, Enabling Technologies, and Public Safety Issues: Part 1*. IEEE Communications Magazine 56:14–15.
6. İnternet: Heine F. (2013). Merkel Buzzed by Mini-Drone at Campaign Event. URL: <https://www.spiegel.de/international/germany/merkel-campaign-event-visited-by-mini-drone-a-922495.html>, Son Erişim Tarihi: 18.11.2019.
7. İnternet: Miller Z. J. (2015). Drone That Crashed at White House Was Quadcopter. URL: <https://time.com/3682307/white-house-drone-crash/>, Son Erişim Tarihi: 18.11.2019.
8. İnternet: Murai S. (2016). Man who landed drone on roof of Japanese prime minister's office gets suspended sentence URL: <https://www.japantimes.co.jp/news/2016/02/16/national/crime-legal/man-landed-drone-roof-japanese-prime-ministers-office-gets-suspended-sentence/#.XeIGsy1R2Uk>, Son Erişim Tarihi: 30.11.2019.
9. İnternet: Kaya D. (2018). Son Dakika: İşte Şırnak'taki hain saldırı girişiminin o anları! Teröristler drone ile... URL: <https://www.sabah.com.tr/gundem/2018/11/11/iste-sirnaktaki-hain-saldiri-girisiminin-o-anlari-teroristler-drone-ile>, Son Erişim Tarihi: 30.11.2019.
10. Guvenc I., Koohifar F., Singh S., Sichitiu M. L., Matolak D. (2018). *Detection, Tracking, and Interdiction for Amateur Drones*. IEEE Communications Magazine 56, 75–81.
11. 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), 1–6.

12. Anwar M. Z., Kaleem Z., Jamalipour A. (2019). Machine Learning Inspired Sound-Based Amateur Drone Detection for Public Safety Applications. *IEEE Transactions on Vehicular Technology* 68, 2526–2534.
13. Bernardini A., Mangiatordi F., Pallotti E., Capodiferro L. (2017). *Drone detection by acoustic signature identification*. *Electronic Imaging* 2017, 60–64.
14. Jeon S., Shin J-W., Lee Y-J., Kim W-H., Kwon Y., Yang H-Y. (2017). *Empirical study of drone sound detection in real-life environment with deep neural networks*, 1858–1862.
15. İnternet: DJI. (2017). Phantom 4 Pro V2.0. URL: <https://www.dji.com/Phantom-4-pro-v2>, Son Erişim Tarihi: 18.11.2019.
16. İnternet: DJI. (2017). Mavic Pro. URL: <https://www.dji.com/Mavic?site=brandsite&from=nav>, Son Erişim Tarihi: 18.11.2019.
17. Albawi S., Mohammed T. A., Al-Zawi S. (2017). *Understanding of a convolutional neural network*. 2017 International Conference on Engineering and Technology (ICET), 1–6.
18. İnternet: IMAGENET (2012). URL: <http://www.image-net.org/>, Son Erişim Tarihi: 18.11.2019.
19. Gu J., Wang Z., Kuen J., et al (2018) *Recent advances in convolutional neural networks*. *Pattern Recognition* 77, 354–377.
20. Lecun Y., Bottou L., Bengio Y., Haffner P. (1998). *Gradient-based learning applied to document recognition*. *Proceedings of the IEEE* 86, 2278–2324.
21. Krizhevsky A., Sutskever I., Hinton G. (2012). *ImageNet Classification with Deep Convolutional Neural Networks*. *Neural Information Processing Systems*.
22. Kurt F., (2018). *Analysis of the effects of hyperparameters in convolutional neural networks*. Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
23. İnternet: Karpathy A. (2019). CS231n Convolutional Neural Networks for Visual Recognition. URL: <http://cs231n.github.io/convolutional-networks/>, Son Erişim Tarihi: 18.11.2019.
24. İnternet: MathWorks. (2019). batchNormalizationLayer. URL: <https://www.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.batchnormalizationlayer.html>, Son Erişim Tarihi: 18.11.2019.
25. İnternet: GRAS Sound & Vibration. (2015). GRAS 46AE 1/2" CCP Free-field Standard Microphone Set URL: <https://www.gras.dk/products/measurement-microphone-sets/product/140-46ae>, Son Erişim Tarihi: 18.11.2019.
26. Kehtarnavaz N., Kim N. (2005). *Digital Signal Processing System-Level Design Using LabVIEW*, 139-145. URL: <https://doi.org/10.1016/B978-075067914-5/50014-3>.

27. İnternet: MathWorks. (2019). hamming. URL: <https://www.mathworks.com/help/signal/ref/hamming.html>, Son Erişim Tarihi: 30.11.2019.
28. İnternet: MathWorks. (2019). stft. URL: <https://www.mathworks.com/help/signal/ref/stft.html>, Son Erişim Tarihi: 18.11.2019.
29. Davis S., Mermelstein P. (1980). *Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences*. IEEE Transactions on Acoustics, Speech, and Signal Processing 28:357–366.
30. Wang Z., Oates T. (2015). *Encoding Time Series as Images for Visual Inspection and Classification Using Tiled Convolutional Neural Networks*.
31. İnternet: MathWorks. (2019). Deep Learning Toolbox. URL: <https://www.mathworks.com/products/deep-learning.html>, Son Erişim Tarihi: 30.11.2019.
32. İnternet: MathWorks. (2019). trainingOptions. https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html?searchHighlight=trainingoptions&s_tid=doc_srchtile, Son Erişim Tarihi: 30.11.2019.
33. Hossin M., Sulaiman M.N. (2015). *A Review on Evaluation Metrics for Data Classification Evaluations*. International Journal of Data Mining & Knowledge Management Process 5, 01–11.
34. Sokolova M., Lapalme G. (2009). *A systematic analysis of performance measures for classification tasks*. Information Processing & Management 45, 427–437.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : DEMİR, Ozan
 Uyruğu : T.C.
 Doğum tarihi ve yeri : 15.08.1993, Ağrı
 Medeni hali : Bekar
 Telefon : 0 (312) 592 23 42
 e-mail : ozandemir11014062@gmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	Gazi Üniversitesi / Elektrik-Elektronik Mühendisliği	Devam ediyor
Lisans	Yıldız Teknik Üniversitesi / Elektronik ve Haberleşme Mühendisliği	2016
Lise	Gazi Anadolu Lisesi	2011

İş Deneyimi

Yıl	Yer	Görev
2016-Halen	ASELSAN A.Ş.	Mühendis

Yabancı Dil

İngilizce

Yayınlar

- Demir, O. and Salor, Ö. (2019). *Convolutional Neural Network Based Detection And Classification Of Drones Using Gramian Angular Field Transformation*. Paper presented at the 2019 2nd International Conference on Technology and Science (Techno-Science), Burdur, Turkey.

Hobiler

Kitap okumak, yüzmek, seyahat etmek



GAZİ GELECEKTİR..