

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE KARA ASKERİ
ARAÇLARIN TESPİT VE SINIFLANDIRILMASI**

ANIL AKBALIK

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**DANIŞMAN
DOÇ. DR. FERZAN KATIRCIOĞLU**

DÜZCE, 2024

T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE KARA ASKERİ
ARAÇLARIN TESPİT VE SINIFLANDIRILMASI

Anıl AKBALIK tarafından hazırlanan tez çalışması aşağıdaki jüri tarafından Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. Ferzan KATIRCIOĞLU

Düzce Üniversitesi

Jüri Üyeleri

Prof. Dr. Uğur GÜVENÇ

Düzce Üniversitesi

Doç. Dr. Ferzan KATIRCIOĞLU

Düzce Üniversitesi

Doç. Dr. Ali ERDUMAN

Düzce Üniversitesi

Tez Savunma Tarihi: 12/07/2024

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

12 Temmuz 2024

Anıl AKBALIK

TEŐEKKÖR

Yüksek Lisans tez çalışmasının tamamlanmasında bana destek olan ve katkıda bulunan, öncelikle bana her zaman rehberlik eden, bilgi ve deneyimleriyle yol gösteren danışman hocam Doç. Dr. Ferzan KATIRCIOĞLU'na sonsuz teşekkürlerimi sunuyorum. Hocamın engin bilgisi ve sabrı sayesinde bu çalışmayı başarıyla tamamlayabildim.

Sevgili eşim Seda AYDIN AKBALIK'a ve canım kızım Nil Hüma AKBALIK'a, bu süreçte gösterdikleri sabır, anlayış ve destek için minnettarım. Onların varlığı, bu zorlu yolculukta bana güç verdi.

Sevgili kardeşim Gözde AKBALIK KORKMAZ, eşi Mert KORKMAZ ve yeğenim Mete KORKMAZ'a bana motivasyon vererek her zaman yanımda olduklarını göstermeleri bana büyük bir moral kaynağı oldu emekleri için çok teşekkür ederim.

Annem, Nurcan AKBALIK ve babam, Recep AKBALIK'a, her daim yanımda oldukları ve bana verdikleri destek için minnettarım. Onların sevgisi ve duaları, bu süreçte en büyük dayanağım kaynağım oldu.

Ayrıca Sakarya'daki aileme Sevgili Sedat AYDIN, Nedime AYDIN ve Serhat AYDIN'a da teşekkürü borç bilirim. Destekleri ve anlayışları, bu süreci daha kolay hale getirdi.

Bu çalışmanın tamamlanmasında emeği geçen ve destek veren herkese sonsuz teşekkürler. Her birinizin katkısı, bu başarının bir parçasıdır.

12 Temmuz 2024

Anıl AKBALIK

İÇİNDEKİLER

Sayfa No

ŞEKİL LİSTESİ.....	vii
KISALTMALAR.....	viii
SİMGELER	ix
ÖZET	x
ABSTRACT	xi
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI.....	5
3. MATERYAL VE YÖNTEMLER.....	7
3.1. VERİ SETİ	7
3.1.1. M113 Zırhlı Personel Araç.....	8
3.1.2. Leopard 1 Tankı.....	9
3.1.3. Land Rover Defender	10
3.1.4. BMC 6x6	10
3.2. VERİ ÖN İŞLEME	12
3.2.1. Gürültü Azaltma	13
3.2.2. Kontrastı Artırma	14
3.2.3. Veri Etiketleme.....	17
3.3. ÖZNİTELİK ÜRETME	18
3.3.1. Yönlü Gradyanlar Histogramı (HOG).....	19
3.3.2. İki Boyutlu Dalgacık Dönüşümü (2DWT)	23
3.4. ÖZNİTELİK SEÇİMİ	27
3.4.1. ReliefF (RF)	27
3.4.2. Ana Bileşen Analizi (PCA)	28
3.5. MAKİNE ÖĞRENMESİ.....	30
3.5.1. K En Yakın Komşu (K-NN)	30
3.5.2. Naive Bayes (NB).....	32
3.5.3. Karar Ağacı (DT)	33
3.5.4. Kaskat İleri Sinir Ağları (CFNN)	35
4. SONUÇLARIN ANALİZ VE DEĞERLENDİRİLMESİ.....	39
4.1. KARARLILIK MATRİSİ.....	43
4.2. DOĞRULUK ANALİZİ.....	47
4.3. DUYARLILIK ANALİZİ	49
4.4. HASSASİYET ANALİZİ	51
4.5. F-SKOR ANALİZİ	53
4.6. GEOMETRİK ORTALAMA	55
5. BULGULAR VE TARTIŞMA	59
6. SONUÇ	61
7. KAYNAKLAR.....	62



ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 1. M113A4 [15].	8
Şekil 2. Leopard 1 [21].	9
Şekil 3. Land Rover Defender [24].	10
Şekil 4. BMC 6x6 [26].	11
Şekil 5. Görüntü Alma Düzenegi.	12
Şekil 6. Veri Seti Örnek Görselleri	13
Şekil 7. Kümülatif Yoğunluk Fonksiyonu [29].	15
Şekil 8. (i, j) Konumunda Boyutlandırma. [31].	16
Şekil 9. İçerik Duyarlı Yeniden Boyutlandırma. [32].	17
Şekil 10. Görüntü Ön İşleme Akış Şeması	18
Şekil 11. HOG ve Makine Öğrenmesi Algoritmaları Akış Şeması	20
Şekil 12. HOG Öznitelik Üretme Örnek Kod Parçası	21
Şekil 13. HOG [40].	21
Şekil 14. HOG [41].	23
Şekil 15. 2DWT ve Makine Öğrenmesi Algoritmaları Akış Şeması.	24
Şekil 16. 2DWT Öznitelik Üretme Örnek Kod Parçası.	25
Şekil 17. Tek boyutlu dalgacık dönüşümü filtrelemesi. [43].	26
Şekil 18. İki boyutlu dalgacık dönüşümü filtreleme. [44].	27
Şekil 19. ReliefF Öznitelik Seçimi Örnek Kod Parçası.	28
Şekil 20. K-NN Makine Öğrenmesi Algoritması Örnek Kod Parçası.	31
Şekil 21. K-NN [51].	31
Şekil 22. NB Makine Öğrenmesi Algoritması Örnek Kod Parçası	32
Şekil 23. DT Makine Öğrenmesi Algoritması Örnek Kod Parçası.	34
Şekil 24. CFNN Ağ Mimarisi [62].	36
Şekil 25. CFNN Makine Öğrenmesi Algoritması Örnek Kod Parçası	37
Şekil 26. ReliefF, PCA ve HOG Öznitelik Analizlerinin Grafiksel Gösterimi	40
Şekil 27. ReliefF, PCA ve 2DWT Öznitelik Analizlerinin Grafiksel Gösterimi.	42
Şekil 28. Sınıflandırma sonuçlarının değerlendirilmesi Karmaşıklık Matrisi	43
Şekil 29. RF-HOG ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları	44
Şekil 30. PCA-HOG ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları	45
Şekil 31. RF-2DWT ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları	46
Şekil 32. RF-HOG ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları	47
Şekil 33. Doğruluk Analizi Grafiksel Gösterimi	48
Şekil 34. Duyarlılık Analizi Grafiksel Gösterimi	50
Şekil 35. Hassasiyet Analizi Grafiksel Gösterimi	52
Şekil 36. F-Skor Analizi Grafiksel Gösterimi	54
Şekil 37. Geometrik Ortalama Analizi Grafiksel Gösterimi.	57

KISALTMALAR

DT	Karar Ağacı
K-NN	K-En Yakın Komşu Kenar
NB	Navie Bayes
CFNN	Kaskat İleri Sinir Ağları
İHA	İnsansız Hava Aracı
ZPT	Zırhlı Personel Taşıma Aracı
H	Hit
HE	Histogram Eşitleme
HOG	Yönlü Gradyanlar Histogramı
2DWT	2 Boyutlu Dalgacık Dönüşümü
RF	Relieff
PCA	Ana Bileşen Analizi
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif

SİMGELER

ω	Omega
π	Pi
θ	Theta
λ	Lambda
Δ	Delta



ÖZET

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE KARA ASKERİ ARAÇLARIN TESPİT VE SINIFLANDIRILMASI

Anıl AKBALIK

Düzce Üniversitesi

Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik ve Bilgisayar Mühendisliği Anabilim
Dalı

Yüksek Lisans Tezi

Danışman: Doc. Dr. Ferzan KATIRCIOĞLU

Temmuz 2024, 66 sayfa

Bu çalışmada, askeri araçların görüntü işleme ve makine öğrenmesi algoritmaları kullanılarak tespit edilmesi üzerine odaklanılmıştır. Askeri araç olarak, BMC 6x6 kamyon, M113 Zırhlı Personel Aracı, Land Rover Defender ve Tank olmak üzere dört farklı kategori tercih edilmiştir. Her araç türüne ait 50 görsel olmak üzere toplamda 200 görselden oluşan bir veri seti hazırlanmıştır. Çalışmanın ilk adımında, görüntü işleme teknikleri uygulanarak görseller üzerinde ön görüntü işleme gerçekleştirilmiştir. Ön görüntü işleme safhası, arka planın çıkartılması, keskinleştirme filtresi ve görüntü boyutlarını küçültme işlemlerini kapsamaktadır. Bu adımın ardından, Yönlendirilmiş Eğimler Histogramı (HOG) ve İki Boyutlu Dalgacık Dönüşümü (2D-WT) yöntemleri kullanılarak özellik çıkarımı yapılmaktadır. Elde edilen özellikler, ReliefF (RF) ve Ana Bileşen Analizi (PCA) ile özellik seçimi yapılarak özellik matrisinin boyutlarının azaltılması sağlanmaktadır. Boyut azaltımı yapılarak gerçekleştirilen özellikler ve etiketler sırasıyla Karar Ağacı (DT), K-en Yakın Komşu (K-NN), Naive Bayes (NB) ve Kaskat İleri Sinir Ağları (CFNN) algoritmalarına uygulanmıştır. Bu sınıflandırıcıların performansını değerlendirmek için kararlılık matrisi, doğruluk, F1 skoru ve kesinlik gibi metrikler kullanılmıştır. Sonuçlarda, her bir sınıflandırıcı için özellik çıkarım ve özellik seçim yöntemleri ile performansları ayrı ayrı uygulanmış ve incelenmiştir. Özellikle CFNN algoritmasının, görsel verilerin karmaşıklığı ve detaylarını en iyi şekilde yakalayarak yüksek doğruluk ve F1 skorları elde ettiği gözlemlenmiştir. HOG özellik çıkarım yöntemi ve RF özellik seçim yöntemlerinde en iyi sonuçlar elde edilmiştir. Bu çalışma sonucunda, askeri araçların tespiti konusunda görüntü işleme ve makine öğrenmesi algoritmalarının etkinliği gösterilmiş ve bu alanda gelecekteki araştırmalara önemli bir temel oluşturmuştur.

Anahtar Kelimeler: Görüntü İşleme, Makine Öğrenmesi, Askeri Araç Tespiti.

ABSTRACT

DETECTION AND CLASSIFICATION OF LAND MILITARY VEHICLES WITH MACHINE LEARNING METHODS

Anıl AKBALIK

Düzce University

Graduate School, Department of Electrical-Electronics and Computer Engineering

Master's Thesis

Supervisor: Assoc. Prof. Dr. Ferzan KATIRCIOĞLU

July 2024, 66 pages

This study focuses on the detection of military vehicles using image processing and machine learning algorithms. Four different categories were selected as military vehicles: BMC 6x6 truck, M113 Armored Personnel Carrier, Land Rover Defender, and Tank. A dataset consisting of a total of 200 images, with 50 images for each type of vehicle, was prepared. In the first step of the study, pre-processing was performed on the images using image processing techniques. The pre-processing phase includes background removal, sharpening filter, and image resizing. Following this step, feature extraction was conducted using Histogram of Oriented Gradients (HOG) and Two-Dimensional Wavelet Transform (2D-WT) methods. The extracted features were subjected to feature selection using ReliefF (RF) and Principal Component Analysis (PCA) to reduce the dimensions of the feature matrix. The obtained features and labels were then applied to Decision Trees (DT), K-Nearest Neighbors (K-NN), Naive Bayes (NB), and Cascade Forward Neural Networks (CFNN) algorithms. Metrics such as confusion matrix, accuracy, F1 score, and precision were used to evaluate the performance of these classifiers. The results showed that the performance of each classifier was separately applied and examined with feature extraction and feature selection methods. It was observed that the CFNN algorithm achieved high accuracy and F1 scores by capturing the complexity and details of the visual data in the best way. The best results were obtained in the HOG feature extraction method and RF feature selection methods. As a result of this study, the effectiveness of image processing and machine learning algorithms in the detection of military vehicles was demonstrated, providing a significant foundation for future research in this field.

Keywords: Image Processing, Machine Learning, Military Vehicle Detection.

1. GİRİŞ

Görüntü işleme ve makine öğrenmesi, son yıllarda birçok alanda olduğu gibi askeri uygulamalarda da büyük ilgi görmektedir. Özellikle askeri araçların tespiti ve sınıflandırılması, savunma sistemlerinin etkinliğinin artırılması ve güvenlik önlemlerinin optimize edilmesi açısından büyük önem taşımaktadır. Bu bağlamda, bu çalışmada askeri araçların görüntü işleme ve makine öğrenmesi algoritmaları kullanılarak tespit edilmesi üzerine odaklanılmıştır. Askeri stratejilerin etkinliği, düşman araçlarının doğru ve hızlı bir şekilde tespit edilmesi ve sınıflandırılması kapasitesine büyük ölçüde bağlıdır. Bu sürecin önemi, askeri operasyonların planlanmasından güvenlik önlemlerinin alınmasına, savunma sistemlerinin geliştirilmesine kadar geniş bir yelpazede hissedilmektedir. Ancak, geleneksel tespit yöntemleri, artan karmaşıklık ve dinamizm karşısında sıkça yetersiz kalmakta, bu da modern görüntü işleme ve makine öğrenimi tekniklerinin kullanımının önemini artırmaktadır. Bu teknolojik ilerlemeler, askeri araçların dinamik ve zorlu koşullar altında etkin bir şekilde tespit edilmesi ve sınıflandırılmasında kritik bir role sahiptir. Gelişen teknoloji ve savaş koşullarının değişkenliği, askeri araçların doğru bir şekilde tespit edilmesi ve sınıflandırılmasını daha karmaşık hale getirmekte, çeşitlenen araç tipleri, farklı hava koşulları ve çeşitli ortam şartları gibi faktörlerle dinamik ve zorlu koşulların etkili bir şekilde ele alınmasını zorunlu kılmaktadır. Bu, geleneksel tespit yöntemlerinin bu karmaşık senaryoları ele almakta yetersiz kalabileceği anlamına gelir, bu da askeri hedef tespit teknolojilerinin geliştirilmesinin önemini artırır.

Askeri hedef tespit teknolojisi, keşif, gözetleme ve komuta karar verme süreçlerini iyileştirmenin ve modern savaş kazanmanın anahtarıdır. Savaş alanındaki hedeflerin gerçek zamanlı ve doğru bir şekilde tespiti, savaş alanı ortamının hızlı bir şekilde anlaşılmasını, düşman birimlerinin etkili bir şekilde aranıp takip edilmesini ve düşmanın dinamiklerinin çözülmesini sağlayarak üstünlük kurma imkânı sunar [1]. Bu bağlamda, otomatik hedef sınıflandırma, uzun yıllardır devam eden zorlu bir problem olup, çeşitli istatistiksel filtreleme ve örnekleme teknikleri kullanılarak görüntülerden bilgi çıkarılmasını içermektedir. Bu süreç, öğrenme algoritmasına girdi olarak hizmet eden boyutu azaltılmış özellik vektörlerinin üretilmesini sağlar, bu da tespit ve sınıflandırma süreçlerinin etkinliğini artıran önemli bir adımdır [2].

Bu çalışmada, BMC 6x6 kamyon, M113 Zırhlı Personel Aracı, Land Rover Defender ve Tank olmak üzere dört farklı askeri araç kategorisi belirlenmiştir. Her bir araç türüne ait 50 görsel olmak üzere toplamda 200 görselden oluşan bir veri seti hazırlanarak, bu zorlukların üstesinden gelinmesi hedeflenmiştir. Çalışmanın ilk adımında, görüntü işleme teknikleri kullanılarak ön görüntü işleme gerçekleştirilmiştir. Bu aşamada, arka planın çıkarılması, keskinleştirme filtresi uygulanması ve görüntü boyutlarının küçültülmesi gibi işlemler gerçekleştirilmiştir. Bu adımı takiben, Yönlendirilmiş Eğimler Histogramı (HOG) ve İki Boyutlu Dalgacık Dönüşümü (2D-WT) yöntemleri kullanılarak özellik çıkarımı yapılmıştır. Çıkarılan özelliklerin boyutlarının azaltılması için ise ReliefF (RF) ve Ana Bileşen Analizi (PCA) yöntemleri kullanılmıştır. Elde edilen özellikler ve etiketler, Karar Ağaçları (DT), K-en Yakın Komşu (K-NN), Naive Bayes (NB) ve Kaskat İleri Sinir Ağları (CFNN) algoritmalarına uygulanarak sınıflandırma işlemi gerçekleştirilmiştir. Bu sınıflandırıcıların performansını değerlendirmek amacıyla kararlılık matrisi, doğruluk, F1 skoru ve kesinlik gibi metrikler kullanılmıştır. Sonuçlar, her bir sınıflandırıcı için özellik çıkarım ve seçim yöntemlerinin performans üzerindeki etkilerini ayrıntılı olarak incelemiştir. Bu çalışmanın amacı, askeri araçların tespitinde görüntü işleme ve makine öğrenmesi tekniklerinin etkinliğini göstermek ve bu alanda gelecekte yapılacak araştırmalara katkı sağlamaktır. Özellikle CFNN algoritmasının, görsel verilerin karmaşıklığını ve detaylarını en iyi şekilde yakalayarak yüksek doğruluk ve F1 skorları elde ettiği gözlemlenmiştir. HOG ve 2D-WT özellik çıkarım yöntemlerinin farklı sınıflandırıcılar üzerindeki etkileri incelenmiş ve en uygun sonuçlar detaylandırılmıştır. Bu çalışma, askeri araçların tespiti konusunda önemli bir temel oluşturarak, ileriye dönük araştırmalara ışık tutmayı hedeflemektedir. Askeri araçların tespit ve sınıflandırılmasında görüntü işleme ve makine öğrenmesi tekniklerinin etkinliğini araştırarak literatüre önemli katkılar sağlamaktadır. Yenilikçi özellik çıkarım ve seçim yöntemleri çalışmada, yönlendirilmiş eğimler histogramı (HOG) ve Naive Bayes (2D-WT) gibi modern özellik çıkarım teknikleri kullanılarak, askeri araçların görsel özellikleri etkili bir şekilde analiz edilmiştir. Bu yöntemlerin askeri araçların tespitindeki başarısını değerlendirerek, literatürdeki diğer özellik çıkarım teknikleri ile karşılaştırmalı analizler sunulmuştur. ReliefF (RF) ve ana bileşen analizi (PCA) gibi özellik seçimi yöntemleri kullanılarak, özellik matrislerinin boyutları azaltılmış ve bu sayede sınıflandırma algoritmalarının performansının artırılması sağlanmıştır. Bu bağlamda, yüksek boyutlu veri setlerinin işlenmesinde kullanılan yöntemlerin etkinliği üzerine yeni bulgular sunulmuştur.

Farklı makine öğrenmesi algoritmalarının performans karşılaştırması çalışmada, karar ağaçları (DT), K-en yakın Komşu (K-NN), naive bayes (NB) ve Kaskat İleri Sinir Ağları (CFNN) gibi çeşitli makine öğrenmesi algoritmalarının askeri araç tespitinde nasıl performans gösterdiği incelenmiştir. Bu algoritmaların performans metrikleri (doğruluk, F1 skoru, kesinlik, kararlılık matrisi) açısından karşılaştırılması literatüre önemli bir katkı sağlamaktadır. Özellikle CFNN algoritmasının, görsel verilerin karmaşıklığını ve detaylarını en iyi şekilde yakalayarak yüksek doğruluk ve F1 skorları elde ettiği gösterilmiştir. Bu bulgu, CFNN'nin askeri araç tespitinde kullanılabileceğine dair literatüre yeni bir bakış açısı kazandırmaktadır. Zorlu koşullar altında tespit ve sınıflandırma askeri araçların tespiti, değişen çevre koşulları, arka plan karmaşıklığı ve görsel benzerlikler gibi faktörler nedeniyle zorlu bir süreçtir. Bu tez, bu tür zorlukların üstesinden gelmek için geliştirilen yöntemlerin etkinliğini göstererek literatüre önemli bir katkı sunmaktadır. Çalışmanın sonuçları, düşük kontrastlı ve karmaşık ortamlarda bile etkin bir şekilde çalışabilen sistemlerin geliştirilmesine yönelik yeni stratejiler sunmaktadır. Bu bağlamda, askeri operasyonların daha etkili bir şekilde planlanması ve savunma stratejilerinin evriminin hızlandırılması konusunda literatüre katkı sağlanmaktadır.

Gelecekteki araştırmalara yön vermesi açısından bu çalışma, mevcut bilimsel literatürdeki boşlukları belirleyerek, askeri araç tespiti ve sınıflandırma alanında gelecekte yapılacak araştırmalara önemli bir temel oluşturmaktadır. Özellikle makine öğrenimi temelli tespit ve sınıflandırma tekniklerinin potansiyelini ortaya koyarak, bu alandaki eksiklikleri ve zayıf yönleri analiz etmektedir. Geliştirilen metodoloji ve algoritmaların, değişen çevresel koşullar, düşük görüntü kalitesi ve diğer beklenmeyen değişkenlerle başa çıkabilme yeteneği sayesinde, savunma sistemlerinin her türlü senaryoya daha etkili bir şekilde adapte olabilmesini sağlamaktadır. Bu da gelecekteki araştırmalar için yenilikçi yaklaşımların geliştirilmesine olanak tanımaktadır.

Sadece teorik bir katkı sağlamakla kalmayıp, aynı zamanda pratik uygulamalarda da etkili bir şekilde kullanılabilir ve uyarlanabilir çözümler sunmayı hedeflemektedir. Geliştirilen sistemler, askeri operasyonlarda gerçek zamanlı ve doğru tespit ve sınıflandırma yapabilme kapasitesiyle, savunma sistemlerinin etkinliğini artırma potansiyeline sahiptir. Çalışmanın bulguları, askeri araç tespit teknolojilerinin geliştirilmesi ve uygulanması konusunda pratik yönergeler ve stratejiler sunarak, savunma sektöründe doğrudan kullanılabilecek bilgi ve teknikler sağlamaktadır.

Bu tez, askeri araçların tespiti ve sınıflandırılmasında yeni yaklaşımlar ve metodolojiler sunarak, literatüre hem teorik hem de pratik açıdan değerli katkılar sağlamaktadır. Bu katkılar, askeri teknoloji ve güvenlik konularında önemli ilerlemelere olanak tanımaktadır.



2. LİTERATÜR ARAŞTIRMASI

Askeri araçların tespiti ve sınıflandırılmasında makine öğrenimi tekniklerinin kullanımına odaklanan benzer çalışmaların daha detaylı açıklamalarından ve çeşitliliklerinden bahsetmek gerekirse;

Bir çalışmada, bu araştırma, askeri araçların yüksek doğrulukla tespit edilmesi için hem araç içeren hem de araç içermeyen görüntüleri kullanır. Araştırmacılar, çeşitli senaryolar altında askeri araçların tespiti için derin öğrenme modellerinin etkinliğini analiz ederken, bu modellerin askeri araçları yüksek hassasiyetle tanımlayabildiğini bulmuşlardır [3].

Başka bir çalışmada, şüpheli faaliyetlerin izlenmesini iyileştirmek için yapay zekâ canlı ve büyük veri füzyonuna odaklanmaktadır. Çalışma, Tayland'ın askeri kaynaklarından elde edilen eğitim verileri kullanılarak derin öğrenme tekniklerini kullanarak güvenli taramada tehdit nesnelerinin tespitini geliştirmeyi amaçlamaktadır. Bu, güvenlik sistemlerinin tehdit algılama yeteneklerini artırarak daha etkili bir şekilde şüpheli aktiviteleri izlemelerine olanak tanır [4].

D. Agrawal, G. Singh, H. Singh, K. Singh, P. Jha tarafından yürütülen çalışmada, İHA'lardan elde edilen görüntüler üzerinden askeri araç tespiti ve sınıflandırması için geliştirdi. Sistem, model iyileştirmesi için hafif makin öğrenme modelinin eğitimini içerir. Araştırma, kenar cihazları kullanarak gerçekleştirilen askeri araç tespitinin ve sınıflandırmasının etkinliğini artırmayı hedeflemektedir [5].

Mayın ve mayın tarlası tespit görevlerinde İnsansız hava araçları (İHA) ile sinir ağlarının entegrasyonunu inceleyen bir çalışma mevcuttur. Araştırma, makine öğrenimi teknolojileri ile donatılmış İHA'ların kullanımının, hem insani hem de askeri mayın temizleme işlemlerinde sorunların tespit edilmesi ve çözülmesi açısından etkinliğini artırabileceğini öne sürmektedir. Bu yaklaşım, mayın tespiti ve temizleme süreçlerini otomatize etmeyi ve daha güvenli hale getirmeyi amaçlamaktadır [6].

Bir makalede ise, drone tespiti ve sınıflandırma tekniklerindeki ilerlemeleri ve zorlukları ele alınmaktadır. Araştırmacılar, drone kullanımının hızla artmasının, hem askeri hem de akıllı şehir uygulamaları için yeni fırsatlar sunduğunu belirtmektedir. Çalışma, derin öğrenme canlı yenilikçi bir drone sınıflandırma yaklaşımını sunar ve bu teknolojinin sivil ve askeri hedeflere yönelik terör ve suç uygulamaları için kullanımının önlenmesinde önemli bir rol oynayabileceğini öne sürmektedir [7].

Makine öğrenimi ile geliştirilmiş artırılmış Doppler filtre bankası kullanarak hedef tespiti için iyileştirilmesine odaklanan bir çalışma mevcuttur. Hem sivil hem de askeri alanlarda yaygın olarak kullanılan radar sistemlerinde, gerçek ve sahte hedeflerin tespit edilmesi, ayrılması ve sınıflandırılması için makine öğrenmesi ve geleneksel yöntemler bir arada kullanılmıştır. Araştırma, radar hedef tespiti için doğruluğunu ve güvenilirliğini artırma potansiyelini vurgulamaktadır [8] .

Makine öğrenmesi algoritmaları, radar verilerini kullanarak sahte hedeflerin ayrılmasında ve gerçek hedeflerin tespitinde etkili bir şekilde kullanılmıştır. Çalışma, özellikle Doppler radar sistemlerinde doğruluğu artırmayı hedeflemektedir [9].

Bu çalışmada, K-en yakın komşu (K-NN) algoritması kullanılarak askeri hedeflerin tespiti ve sınıflandırılması yapılmıştır. Uydu görüntülerinden elde edilen veriler üzerinde K-NN algoritması başarılı sonuçlar vermiştir [10].

Karar ağaçları algoritması kullanılarak askeri araçların tespiti ve sınıflandırılması yapılmıştır. Bu çalışmada, farklı açılardan ve ortamlardan alınan araç görüntüleri üzerinde karar ağaçları kullanılarak yüksek doğruluk oranları elde edilmiştir [11].

Naive Bayes algoritması kullanılarak patlayıcı maddelerin tespiti ve sınıflandırılması yapılmıştır. Çalışmada, görüntü işleme teknikleri ile birlikte Naive Bayes algoritması kullanılarak yüksek doğrulukla patlayıcı maddelerin tespiti sağlanmıştır [12].

3. MATERYAL VE YÖNTEMLER

3.1. VERİ SETİ

Bu araştırmanın temelini oluşturan veri seti seçimi, askeri araçların tespiti ve sınıflandırılması modelinin başarısını büyük ölçüde etkileyen stratejik bir adımdır. İkinci bölüm, araştırmanın temel dayanak noktalarını oluşturan veri setlerinin seçimi, temizlenmesi ve ön işleme adımlarını detaylandırmaktadır. Veri setlerinin nitelikleri, kullanılan ön işleme teknikleri ve bu adımların veri setlerinin kalitesini nasıl etkilediği ayrıntılı bir şekilde ele alınarak, makine öğrenimi modellerinin güvenilir bir şekilde eğitilmesi sağlanacaktır. Makine öğrenme alanında sunulan yöntemleri incelemek için, derin öğrenme alanındaki birkaç makale seçilmiş ve incelenen makalelerden bazıları nesneleri tanıma için yeni çözümler ve yöntemler sunmuştur [13]. Bu bölüm, tezin teknik çerçevesini oluşturan özellik çıkarımı süreçlerini ve makine öğrenme modelinin nasıl kurulacağını inceler. Bu aşamada, özellik çıkarımının önemi vurgulanarak, makine öğrenme modellerinin adım adım kurulumu açıklanacak ve bu modellerin daha etkili hale getirilmesi için kullanılan stratejiler detaylı bir şekilde anlatılacaktır.

İlk olarak, M113 zırhlı personel taşıyıcı, askeri operasyonlarda yaygın olarak kullanılan ve çeşitli amaçlar için adapte edilebilen bir araçtır. Bu araç, personel taşıma, komuta kontrol ve lojistik destek gibi çeşitli görevlerde kullanılabilir. Dolayısıyla, bu aracın tanınması ve teşhisi, askeri operasyonlarda önemli bir rol oynar. İkinci olarak, Leopard tankı modern tank teknolojisinin önemli bir örneğidir ve çeşitli ülkelerin ordularında yaygın olarak kullanılmaktadır. Yüksek ateş gücü, manevra kabiliyeti ve zırh koruması ile tanınan bu tank, askeri operasyonlarda kritik bir rol oynar. Bu nedenle, Leopard tankının doğru bir şekilde tanınması ve teşhisi, askeri strateji ve taktiklerin etkin bir şekilde uygulanmasını sağlar. Üçüncü olarak, BMC 6x6 kamyon, askeri lojistik destek operasyonlarında yaygın olarak kullanılan bir araçtır. Büyük yük kapasitesi ve dayanıklılığıyla bilinen bu kamyonlar, malzeme taşıma, askeri ekipman nakliyesi ve saha destek görevlerinde kullanılır. Bu nedenle, BMC 6x6 kamyonlarının tanınması ve teşhisi, askeri lojistik operasyonların etkinliğini artırır. Son olarak, Land Rover Defender, hafif arazi taşıtları arasında önemli bir yere sahiptir ve çeşitli askeri operasyonlarda kullanılır. Hızlı ve manevra kabiliyeti yüksek olan bu araçlar, keşif, devriye ve hızlı müdahale gibi görevlerde kullanılır. Dolayısıyla, Land Rover Defender'lerinin doğru bir şekilde

tanınması ve teşhisi, askeri operasyonlarda hareketliliği ve reaksiyon kabiliyetini artırır.

Bu dört askeri aracı seçmemin temel amacı, çeşitli askeri operasyonlarda önemli rolleri olan ve farklı görevleri yerine getiren araçları temsil etmektir. Bu araçların doğru bir şekilde tanınması ve teşhisi, askeri operasyonların planlanması ve yürütülmesi açısından kritik öneme sahiptir. Bu sebeplerle, çalışmada bu dört askeri araçların ele almayı uygun buldunmuştur.

3.1.1. M113 Zırhlı Personel Aracı

M113, FMC Corporation tarafından üretilen ve geliştirilen bir tam izlenen zırhlı personel taşıyıcıdır (ZPT). M113, Amerika Birleşik Devletleri Ordusu tarafından 1961 yılında Avrupa'ya gönderilen mekanize piyade M59 ZPT'lerinin yerini almıştır. Vietnam Savaşı sırasında ABD Ordusu tarafından en yaygın kullanılan zırhlı araç olan M113, orman alanlarında ağır çalılıkları kırarak düşman mevzilerine saldırmak ve onları aşmak için kullanılmıştır. M113, seri üretime giren ilk alüminyum gövdeli savaş aracıdır. M113, zırhlı ambulans, havan taşıyıcı, mühendislik aracı ve komuta aracı gibi destek rollerinde kullanılan çeşitli uyarlamalarla dünya genelinde çok yönlü bir şekilde üretilmiştir. M113 üretimi 2007 yılında sona ermiştir [14].



Şekil 1. M113A4 [15].

M113 Orijinal versiyonda 209 beygir gücünde (156 kW) Chrysler 75M V8 benzinli motor kullanılmaktadır. M113A1 1964 yılından itibaren, daha iyi yakıt tüketimi ve daha az yangın riski nedeniyle 215 beygir gücünde (160 kW) 6V-53 Detroit Diesel motor benzinli

motordan daha iyi bir seçenek olarak kullanılmaya başlanmıştır. A1 ek kelimesi, tüm varyantlarda bir dizel motoru belirtmek için kullanılmıştır. M113A2 1979 yılında iyileştirmeler yapılmıştır. Motor soğutması için fan ve radyatörün yerleri değiştirilerek iyileştirme sağlanmıştır. Daha yüksek mukavemetli burulma çubukları, aracın yere daha yüksek bir konumda olmasını sağlamış ve amortisörler zemin çarpmalarının etkisini azaltmıştır. M113A2'ye dört tüplü sis bombası fırlatıcıları eklenerek ağırlığı 11.740 kilograma (25.880 lb) yükseltilmiştir. A2 ek kelimesi, tüm varyantlarda A2 standardına yükseltildiğini belirtmek için kullanılmıştır. M113A3 1987 yılında "gelişmiş hayatta kalma" için daha fazla iyileştirme yapılmıştır [14].

3.1.2. Leopard 1 Tankı

Leopard 1, Almanya tarafından üretilmiş olan 2. nesil bir ana muharebe tankıdır. İlk olarak 1965 yılında Alman Federal Ordusu'nun hizmetine girmiştir. Leopard 1'in seri üretimi, Alman Krauss-Maffei Wegmann firması tarafından 1965 yılında başlatılmış ve 1984 yılına kadar sürdürülmüştür. Ayrıca, İtalya'da da Leopard 1 tankının üretimi gerçekleştirilmiştir [16]. Leopard 1 tankı, Porsche, Rheinmetall ve Borgward şirketlerinin sunduğu prototipler arasından Porsche'nin prototibi seçilerek üretime geçirilmiştir. Tankın geliştirilmesi ve üretimi sürecinde bu şirketlerin katkısı büyük olmuştur [17]. Leopard 1, toplamda 4000'den fazla üretimi gerçekleştirilen bir tanktır.



Şekil 2. Leopard 1 [18].

Almanya'da üretilen Leopard 1 tankları, Alman Ordusu yanı sıra Brezilya, Şili, Ekvador, Yunanistan, Lübnan ve Türk orduları tarafından da kullanılmıştır [19]. Tankın üretimi sırasında çeşitli değişiklikler ve geliştirmeler yapılmıştır. Örneğin, 1964 ve 1984 yılları

arasında toplamda 4.744 adet Leopard 1 tankı üretilmiştir. Leopard 1 tankının bazı varyantlarında daha güçlü motorlar, iyileştirilmiş soğutma sistemleri ve ek zırh takviyeleri gibi yenilikler bulunmaktadır [20]. Leopard 1, Leopard 2'nin üretimine başlanmasıyla birlikte birçok ordu tarafından ikincil bir tank olarak kullanılmış ve zamanla hizmet dışına çıkarılmıştır [21].

3.1.3. Land Rover Defender

Land Rover Defender, Land Rover tarafından üretilen ve askeri operasyonlarda kullanılan bir araçtır. İlk olarak 1948 yılında tanıtılan Land Rover serisi, savunma ve keşif amaçlı kullanılmak üzere tasarlanmıştır. Land Rover Defender, dayanıklı yapısı, yüksek off-road performansı ve çeşitli modifikasyon seçenekleriyle tanınır [22]. Land Rover Defender, çeşitli askeri görevler için uyarlanmış bir platform sunar. Bu araçlar genellikle askeri personel, malzeme ve ekipman taşıma, keşif ve gözetleme, sınır güvenliği ve kurtarma gibi görevlerde kullanılır. Land Rover Defender'ın arazi yetenekleri ve üstün çekiş gücü, zorlu arazi koşullarında bile etkili bir şekilde hareket etme kabiliyeti sağlar [23].



Şekil 3. Land Rover Defender [24].


3.1.4. BMC 6x6

BMC 6x6 kamyon, Türk otomotiv şirketi BMC tarafından üretilen bir askeri araçtır. Bu kamyon, yüksek taşıma kapasitesi ve dayanıklı yapısıyla öne çıkar. İşlevsel tasarımı ve üstün off-road performansı sayesinde zorlu arazi koşullarında güvenilir bir şekilde kullanılabilir [25]. BMC 6x6 kamyon, askeri lojistik, personel taşımacılığı ve malzeme

nakli gibi çeşitli askeri görevlerde kullanılmaktadır. Güçlü motoru ve geniş yük alanı sayesinde ağır yükleri taşıma kapasitesine sahiptir. Aynı zamanda arazi koşullarına uyum sağlamak için güçlü bir şasi ve süspansiyon sistemi ile donatılmıştır.

BMC'nin 6x6 kamyonları, Türk Silahlı Kuvvetleri ve diğer uluslararası askeri birimler tarafından tercih edilmektedir. Bu kamyonlar, dayanıklılık, performans ve kullanım kolaylığı gibi özellikleriyle askeri operasyonlarda güvenilir bir şekilde kullanılmaktadır.

Kullanılan veri seti, çeşitli kaynaklardan elde edilen uydu görüntüleri, termal kameralar, hava fotoğrafları ve diğer sensör verilerini içermektedir. Bu heterojen veri seti, askeri araçların farklı ışık koşulları, hava durumu ve arazi şartları altında etkili bir şekilde tespit edilebilmesi için özenle seçilmiştir. Bu sayede elde edilen model, gerçek dünya koşullarında maksimum performans sergileme yeteneği kazanmıştır.




Şekil 4. BMC 6x6 [26].

Veri seti seçimi, yalnızca çeşitlilikle sınırlı değildir; aynı zamanda doğruluk, güvenilirlik ve genelleme yeteneği açısından da dikkatlice ele alınmalıdır. Bu bağlamda, kullanılan veri setinin askeri araçları doğru bir şekilde temsil etmesi ve gerçek dünya senaryolarını yansıtmayı sağlamıştır. Bu önemli adım, elde edilecek sonuçların güvenilir ve uygulanabilir olmasını temin etmektedir.

BMC'nin 6x6 kamyonları, Türk Silahlı Kuvvetleri ve diğer uluslararası askeri birimler tarafından tercih edilmektedir. Bu kamyonlar, dayanıklılık, performans ve kullanım kolaylığı gibi özellikleriyle askeri operasyonlarda güvenilir bir şekilde kullanılmaktadır.

3.2. VERİ ÖN İŞLEME

Veri ön işleme, veri kalitesi veya verinin bütünlüğü açısından kritik bir aşamadır. Bu sürecin önemini vurgulamak için ham verinin gürültü, eksik değerler ve tutarsızlık gibi sorunları olabilir. Verilerin kalitesi, sonuçları doğrudan etkiler ve bu nedenle ham verinin veri ön işleme adımlarıyla işlenmesi gereklidir.



Şekil 5. Görüntü Alma Düzenliği

Bu adımlar, veri setinin hazırlanması ve dönüştürülmesiyle ilgilenir ve genellikle dört kategoriye ayrılır [27]. Elde edilen veriler, makine öğrenimi modelinin etkili bir şekilde öğrenme yapabilmesi için önceden işleminden geçirilmelidir. Bu aşama, elde edilen verilerin kalitesini artırmak, gürültüyü azaltmak ve modelin daha hızlı ve doğru öğrenme yapabilmesini sağlamak adına hayati öneme sahiptir.

Şekil 5’ deki blok diyagramda görüldüğü gibi askeri araçlardan görüntü alma bölümünde kullanılan dört askeri aracın, belirlenmesi için 5 metre uzaklıktan ve 1,5 metre kamera yüksekliğinde fotoğraflarının çekilmesi, veri toplama sürecinin önemli bir adımdır.

Araçların özelliklerini belirginleştirmek ve tanımlamak için gerekli ayrıntı düzeyini sağlamaktadır.



Şekil 6. Veri Seti Örnek Görselleri

Şekil 6’da elde edilen veri setinden her bir sınıf için birer örnek verilmiştir, askeri araçların tanımlanması ve teşhis edilmesi için geliştirilen algoritmaların eğitimi ve doğruluğunun değerlendirilmesinde kritik bir rol oynamaktadır.

Araç görsellerindeki farklılıkları artırmak için bazı görsellerde açısal farklar oluşturuldu, simetrik görseller konuldu ve farklı uzaklıkta, renklerde görseller ile doğruluğu kontrol edildi.

3.2.1. Gürültü Azaltma

Görüntü gürültüsünü azaltmak için farklı filtreleme teknikleri kullanılabilir. Görüntüyü filtrelemeye sokmadan önce görüntü üzerinde, Salt and pepper, Poisson ve Gaussian gibi farklı gürültü türleri suni olarak oluşturulmaktadır. Salt and pepper gürültüsü, piksellerde belirgin kara ve beyaz noktaların oluşmasına neden olurken, Poisson gürültüsü ışık ve elektrik akımı gibi süreçlerin ayırık paketlerden oluşmasıyla meydana gelir. Öte yandan, Gaussian gürültüsü, piksel değerlerinin rastgele dağılımıyla karakterizedir. Bu gürültüler Median, Mean, Gaussian ve Laplacian gürültü azaltma teknikleri kullanılarak verinin temizlenmesini sağlar. Böylece sınıflandırma modelinin daha net ve güvenilir öğrenme yapmasını desteklemiştir. Bu nedenle, bu teknikler veri analizi ve model eğitimi

süreçlerinde önemli bir rol oynamaktadır.

Salt an Pepper Noise: Tuz ve biber gürültüsü, bir tür impulssal gürültüdür. Aslında, bu yoğunluk sıçramalarını ifade eder. Bu tür gürültü, veri iletimindeki hatalardan kaynaklanmaktadır. Bu gürültü, görüntü sinyalinin keskin ve ani değişikliklerinden dolayı ortaya çıkar. Tuz ve biber gürültüsüyle bozulmuş görüntülerde, gürültülü pikseller genellikle dinamik aralıktaki maksimum ve minimum değerleri alabilir. Örneğin, bir 8-bitlik görüntüde biber gürültüsü için tipik değer 0 iken tuz gürültüsü için 255'tir. Tuz ve biber gürültüsü genellikle kamera sensörlerindeki piksel öğelerinin arızalanmasından, hatalı bellek konumlarından veya sayısallaştırma sürecinde zamanlama hatalarından kaynaklanır.


Poisson Noise: Poisson veya atış foton gürültüsü, sensör tarafından algılanan foton sayısının belirgin istatistiksel bilgi sağlamak için yeterli olmadığında ortaya çıkan gürültüdür. Atış gürültüsü, ışık ve elektrik akımı gibi bir fenomenin, ayrık paketlerin hareketinden oluşması nedeniyle meydana gelir. Atış gürültüsü, enerji taşıyan parçacıkların sonlu sayısı yeterince küçük olduğunda, bağımsız rastgele olayların meydana gelme durumunu tanımlayan Poisson dağılımına bağlı belirsizliklerin önemli hale gelmesi durumunda baskın olabilir. Bu gürültünün büyüklüğü, akımın ortalama büyüklüğü veya ışığın yoğunluğu ile artar.

Gaussian Noise: Gaussian gürültü, sinyal üzerinde eşit olarak dağılmıştır. Bu, gürültülü görüntüdeki her pikselin gerçek piksel değerinin ve rastgele bir Gaussian dağılımlı gürültü değerinin toplamı olduğu anlamına gelir. Gürültü, her noktadaki piksel değerinin yoğunluğundan bağımsızdır. Özel bir durum beyaz Gaussian gürültüdür, burada herhangi bir zamandaki değerler aynı dağılıma sahiptir ve istatistiksel olarak bağımsızdır. Beyaz gürültü adını beyaz ışıktan alır. Dijital görüntülerdeki Gaussian gürültünün başlıca kaynakları, edinim sırasında ortaya çıkar, örneğin düşük aydınlatma veya yüksek sıcaklık tarafından neden olan sensör gürültüsü veya iletim kaynaklıdır [28].

3.2.2. Kontrastı Artırma

Kontrast artırma, yaygın olarak kullanılan görüntü iyileştirme yöntemlerinden biridir. Görüntü kontrast artırma için birçok yöntem önerilmiştir ve bunlar genellikle doğrudan yöntemler ve dolaylı yöntemler olmak üzere iki geniş kategoriye ayrılabilir. Dolaylı yöntemler arasında, histogram değiştirme teknikleri basitliği ve açıklığı nedeniyle yaygın olarak kullanılmaktadır ve bu teknikler arasında histogram eşitleme (HE) en sık

kullanılanlardan biridir. HE'nin temel prensibi, iyileştirilmiş görüntünün histogramını mümkün olduğunca homojen bir dağılıma yaklaştırmaktır, böylece görüntünün dinamik aralığı tam olarak kullanılabilir hale gelir. Görüntü standartlaştırma, veri setindeki farklı görüntülerin benzer özelliklere sahip olması, modelin daha tutarlı bir şekilde öğrenme yapmasını sağlar. Bu amaçla, görüntüler standartlaştırılabilir. Standartlaştırma işlemi, görüntülerin ortalama ve standart sapma değerlerini kullanarak birbirine benzer hale getirir. Histogram Eşitleme (HE), basit işlevi ve etkililiği nedeniyle çeşitli uygulamalarda kontrast artırma için yaygın olarak kullanılmaktadır. Görüntünün kümülatif yoğunluk fonksiyonunu kullanarak histogramı düzleştirir ve gri seviyelerin dinamik aralığını genişletir ancak, histogram eşitlemenin bir sorunu, görüntünün parlaklığının eşitleme işleminden sonra değişmesidir; bu nedenle, orijinal parlaklığın korunması ve kontrastın artırılması, sanal görüntüleri önlemek için önemlidir [29].




Şekil 7. Kümülatif Yoğunluk Fonksiyonu [29].

Yukarıdaki Şekil 7’de kümülatif yoğunluk fonksiyonunu bir dönüşüm fonksiyonu olarak kullanarak giriş görüntüsünün tüm gri renk dinamik aralığındaki ($X_0 - X_{L-1} \rightarrow 0 - 255$) ve $P(X)$ piksel sayısı olarak eşitleme işleminin kullanıldığını göstermektedir. Histogram eşitlemenin, görüntünün yoğunluk dağılımını düzleştirerek belirli bir histogramın dinamik aralığını genişletme etkisi vardır.

Boyutlandırma, modelin eğitimi için kullanılan görüntülerin boyutları genellikle standartlaştırılmalıdır. Bu, modelin her bir görüntüyü aynı boyutta işlemesini sağlar. Görüntülerin yeniden boyutlandırılması, işlem süresini azaltabilir ve modelin daha hızlı öğrenmesini sağlayabilir. Bikübik boyutlandırması, bir görüntünün yeniden boyutlandırılması veya yeniden örneklendirilmesi sırasında kullanılan bir interpolasyon yöntemidir. Bu yöntem, bir pikselin değerini hesaplamak için dört komşu pikselin değerini kullanır. Bikübik interpolasyon, dört komşu piksel arasındaki ilişkileri modellemek için bir bikübik polinom kullanır. Bu polinom, komşu piksellerin yoğunluklarına dayalı olarak hesaplanır ve ardından hedeflenen pikselin değeri bu polinom kullanılarak tahmin edilir. Bikübik interpolasyon, yüksek kaliteli görüntü

yeniden boyutlandırma işlemlerinde yaygın olarak kullanılan bir yöntemdir [30] .



Şekil 8. (i, j) Konumunda Boyutlandırma. [31].

Görüntü boyutlandırma sürecinde, geleneksel otomatik boyutlandırma operatörleri veya sabit kaldırma pencereleri gibi basit yöntemler sıklıkla kullanılır. Blokların oluşturulması ve önemli nesnelerin belirgin hale gelmesine sağlayabilir olabilir. Bu tür değişiklikler, özellikle boyut değişikliğine bağlı olarak belirlenebilir. Önemli bölgelerin korunmasına ve görüntünün estetiğinin korunmasına odaklanan bilinçli görüntü düzenleme teknikleri, önemli parçaların korunması ve görüntünün güzelliğinin sürdürülmesi gibi önemli özelliklere sahiptir.

Seam Carving yöntemi, içerik duyarlı görüntülerin boyutlandırılması için popüler bir yöntemdir. Bu yöntem, görüntünün genişliğini veya yüksekliğini azaltmak için bir dikişin bir piksel uzunluğunda kaldırılmasını sağlar. Çoklu operatör yöntemi, her birinin avantajlarını ve dezavantajlarını sunmayı amaçlayan yeniden boyutlandırma operatörlerini birleştirerek en iyi sonuçları elde etmeyi amaçlar. Çok katmanlı görüntü hedefleme yöntemi, net görüntülerdeki önemli nesnelerin bozulmasını önlemeye yönelik yöntem sunar [32]. Araçların özelliklerini belirginleştirmek ve tanımlamak için gerekli ayrıntı düzeyini sağlamaktadır.




Şekil 9. İçerik Duyarlı Yeniden Boyutlandırma. [32].

Sınıf dengesizlikleri, bir veri setinde farklı sınıfların temsil edilme oranlarının dengesiz olduğu durumları ifade eder. Bu dengesizlikler, bir sınıfın diğerine göre daha fazla örnek içermesi veya bazı sınıfların nadir görülmesi şeklinde olabilir. Sınıf dengesizlikleri, modelin eğitilmesini etkileyebilir çünkü nadir sınıfların öğrenilmesi zorlaşabilir ve nadir sınıflara karşı modelin duyarlılığı azalabilir. Artırma veya azaltma teknikleri, sınıf dengesizliklerini dengelemek için yaygın olarak kullanılan yöntemlerdir. Artırma, nadir sınıflara ait örneklerin çoğaltılması veya sentetik verilerin oluşturulmasıyla gerçekleştirilir, böylece her sınıfın temsil edilme oranı daha dengeli hale gelir. Azaltma ise fazla temsil edilen sınıflardan örneklerin kaldırılmasıyla gerçekleştirilir, bu da sınıflar arasındaki dengesizliği azaltır. Dengeli bir veri seti, modelin daha standart ve genelleme yeteneği daha yüksek bir şekilde öğrenme yapmasına yardımcı olabilir. Bu nedenle, sınıf dengesizlikleri üzerinde çalışmak ve uygun dengeleme tekniklerini uygulamak, modelin performansını artırabilir ve doğruluğunu artırabilir. Bu ön işleme adımları, elde edilen verilerin kalitesini artırarak modelin daha etkili bir şekilde eğitilmesini hedefler [33].

3.2.3. Veri Etiketleme

Veri etiketleme aşaması, askeri araçları tespit ve sınıflandırma modelinin doğruluğunu önemli ölçüde etkileyen bir aşamadır. Bu aşama, modelin güvenilir öğrenme sağlaması amacıyla doğru etiketlemeyle ilgilidir.

Uzman etiketleme, her bir görüntünün deneyimli uzmanlar tarafından dikkatle incelenip sınıflandırılması sürecini içerir. Uzmanlar, askeri araçların çeşitli türleri, konumları ve farklı açılardan görüntüleri üzerinde uzmanlaşmış olmalıdır. Bu detaylı yaklaşım, veri setinin kalitesini artırarak modelin daha doğru ve güvenilir öğrenme yapmasını sağlar. Otomatik etiketleme yöntemleri ise veri setini hızlı bir şekilde etiketlemenin avantajını sunar.



Şekil 10. Görüntü Ön İşleme Akış Şeması

Bu yöntemler genellikle önceden belirlenmiş kurallar veya öğrenilmiş modeller kullanarak etiketleme işlemini gerçekleştirir. Ancak, otomatik etiketleme yöntemlerinin doğruluğu genellikle uzman etiketlemeye göre daha düşüktür. Bu nedenle, otomatik etiketleme sonuçları dikkatlice incelenmeli ve model eğitimi sürecinde uygun şekilde kullanılmalıdır. Etiketleme sürecinin yönetimi, veri setinin güvenilirliği açısından kritiktir. Her bir görüntünün doğru sınıf etiketleriyle etiketlenmesi, modelin yanlış öğrenmeleri önler. Etiketleme sürecinin belgelendirilmesi, elde edilen sonuçların doğruluğunu değerlendirmek ve gelecekteki çalışmalara rehberlik etmek için önemlidir.

Bu aşama, modelin eğitim verilerinin kalitesini ve tutarlılığını sağlamak adına özenle tasarlanmıştır.

3.3. ÖZNİTELİK ÜRETME

Makine öğrenimi, veri bilimi ve yapay zekâ alanlarında hızla büyüyen bir disiplindir ve

özellikle veri madenciliği, tahminleme ve sınıflandırma problemlerinin çözümünde önemli bir rol oynamaktadır. [34] İstatistiksel yöntemlerin kullanımıyla, makine öğrenimi algoritmaları, büyük veri setlerinden karmaşık örüntüleri tanımlayarak önemli bilgileri ortaya çıkarabilir ve geniş bir yelpazedeki uygulamalar için karar verme süreçlerini etkileyebilir. Derin öğrenme, özellikle görüntü ve ses işleme gibi alanlarda, verilerdeki temsil edici özellikleri otomatik olarak çıkararak benzersiz desenleri tanımlama kapasitesiyle dikkat çekmektedir.


Özellik çıkarımı, askeri araçların tespiti ve sınıflandırılması alanında yürütülen makine öğrenimi modellerinin temel aşamalarından biridir. Bu aşama, veri setinde bulunan karmaşık özellikleri analiz ederek modelin genelleme yeteneğini artırmayı ve doğru sınıflandırma yapmayı hedefler. Bu süreçte, askeri araçları karakterize eden geometrik şekiller, renk özellikleri ve yapısal unsurlar gibi çeşitli özellikler incelenir ve modelin daha doğru sınıflandırmalar yapabilmesi için kullanılır.

Askeri araçların tespit edilmesi, çeşitli çevresel koşullar ve değişkenlerin etkisi altında gerçekleşen karmaşık bir görevdir. Bu koşullar arasında, farklı hava durumları, çeşitli aydınlatma şartları ve araçların kısmen gizlenmiş olması gibi faktörler bulunur. Bu nedenle, özellik çıkarımı sürecinin başarılı bir şekilde gerçekleştirilmesi, modelin bu tür zorlu senaryolarda bile yüksek performans göstermesini sağlar. Bu bölümde, askeri araçların tespiti için kullanılan özellik çıkarım yöntemlerinin teorik temelleri ve pratik uygulamaları derinlemesine incelenmiştir. Çalışmada HOG ve 2DWT teknikleri tercih edilmiştir.

3.3.1. Yönlü Gradyanlar Histogramı (HOG)

HOG , Navneet Dalal ve Bill Triggs tarafından 2005 yılında yayınlanan "Histograms of Oriented Gradients for Human Detection" başlıklı makalede tanıtılmıştır [35]. Araç tespitindeki temel bileşen, araçları diğer nesnelerden ayırt etme yeteneğine sahip iyi bir özellik tanımlaması seçmektir. HOG özelliği, nesne şeklini ve görünümünü daha iyi karakterize etmekte ve aydınlatma değişikliklerine duyarlı değildir. Bununla birlikte, HOG özelliklerinin yüksek boyutluluğu, eğitim ve sınıflandırmayı yavaşlatabilir. Bu nedenle, tespit sürecini hızlandırmak için önerimiz farklı algoritmalar ve sınıflandırmalar kullanılarak HOG özelliklerini güçlendirmektir [36]. HOG'un askeri araçların tespiti ve sınıflandırılmasındaki kapsamlı rolü detaylı bir şekilde incelenecek ve bu özellik çıkarım yönteminin genelleme yeteneğini artırmada nasıl katkı sağladığı ayrıntılı bir şekilde ele

alınacaktır [37].



Şekil 11. HOG ve Makine Öğrenmesi Algoritmaları Akış Şeması

Askeri araçların tespiti ve sınıflandırılmasında, özellikle HOG ile birlikte kullanılarak, daha karmaşık özelliklerin öğrenilmesine ve nesne tanıma görevlerinin etkili bir şekilde gerçekleştirilmesine olanak tanır [38]. HOG, bilgisayarlı görüş ve nesne tespiti alanında yaygın olarak kullanılan bir özellik çıkarım yöntemidir. Görüntülerdeki kenar ve köşe bilgilerini vurgulamak amacıyla tasarlanan bu yöntem, özellikle nesne tanıma görevlerinde etkin bir rol oynamaktadır. HOG'un temel prensibi, bir görüntüyü belirli boyutlardaki hücrelere bölmek ve her hücre içindeki piksellerin gradient bilgilerini bir histogramda toplamaktır. Bu histogramlar, görüntünün genel yapısını temsil eden vektörler olarak ortaya çıkar [39].

```
% Görüntüyü yükle
image = imread('ornek_goruntu.jpg');
image = rgb2gray(image); % Görüntüyü gri tonlamalı hale getir


% HOG özniteliklerini çıkar
[hogFeatures, visualization] = extractHOGFeatures(image);

% Original görüntüyü ve HOG görselleştirmesini göster
figure;
subplot(1,2,1);
imshow(image);
title('Original Görüntü');

subplot(1,2,2);
plot(visualization);
title('HOG Görselleştirme');
```

Şekil 12. HOG Öznitelik Üretme Örnek Kod Parçası

Askeri araçların tespiti için bu yöntem, araçların kenarları, şekli ve genel yapısını anlamak açısından kritik öneme sahiptir. HOG, özellikle düşük seviyeli özellikleri vurgulayarak nesne tanıma algoritmalarına sağlam bir temel oluşturur. Askeri araçların karmaşık yapıları ve değişen çevresel koşullara adaptasyonu göz önüne alındığında, HOG'un bu özellikleri tanımlamada sağladığı esneklik önemlidir [40].



Şekil 13. HOG [41].

Görüntü gradyanları, HOG, görüntünün gradyan ağırlığını ve yönünü hesaplayarak başlar. Gradyan, bir görüntünün parlaklık değerlerindeki değişimin bir ölçüsüdür ve kenarlar gibi önemli görüntü özelliklerini vurgular.

Hücreler ve bloklar, görüntü, küçük hücrelere bölünür ve her hücre için bir gradyan yönü histogramı hesaplanır. Bu histogramlar, hücre içindeki piksellerin gradyan yönlerinin dağılımını özetler. Daha sonra, birkaç hücre bir araya getirilerek bloklar oluşturulur ve bu blokların histogramları normalize edilir. Normalizasyon, aydınlatma değişikliklerine

karşı dayanıklılığı artırır. Özellik vektörü, her bir blok için hesaplanan normalize edilmiş histogramlar, büyük bir özellik vektörü oluşturmak üzere birleştirilir. Bu vektör, görüntünün temsildir ve sınıflandırma için kullanılır.

HOG, yüksek boyutlu verilerde işleme sürecinin uzun olması nedeniyle bazen hesaplama açısından yavaş sonuçlar verebilir. Ancak, boyutluluk azaltma teknikleri, etkili özellik seçimi yöntemleri ve güçlü sınıflandırıcılar ile birlikte kullanıldığında, HOG temelli sistemler yüksek doğruluk oranları elde edebilir.

Yazılım tabanlı araç sınıflandırma sistemleri, görüntü akışlarından araçları tespit etmek ve sınıflandırmak için HOG gibi algoritmaları kullanır. Bu sistemler, esneklikleri ve kurulum kolaylıkları nedeniyle donanım tabanlı sistemlere tercih edilen bir alternatif sunar. HOG'un araç tespitindeki uygulanabilirliği, bu tür sistemlerin geliştirilmesinde ve optimize edilmesinde önemli bir rol oynar.

$h = [-1, 0, 1]$ olarak verilen bir I imgesinin x ve y doğrultusundaki gradyanı:

$$G_x = I * h, y \quad (3.3.1.1)$$


$$G_y = I * (-h)^T \quad (33.3.1.2)$$

Bu denklemler sonucu aşağıdaki eşitlik ortaya çıkar. Bir pikselin gradyan şiddeti aşağıda verilmiştir.

$$p(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (3.3.1.3)$$

Bulunan gradyanlar ile x ve y noktasındaki piksele ait açı değeri de aşağıdaki denklem ile elde edilir.

$$\theta(x, y) = \tan^{-1} \left(\frac{G_y(x, y)}{G_x(x, y)} \right) \quad (3.3.1.4)$$




Şekil 14. HOG [42].

HOG algoritmaları sırayla özellik tanımlama, görüntü ön işleme, gradyan hesaplama, gradyanların histogramını çıkarma, normalizasyon, görüntüyü görselleştirme adımları ile çalışır. Şekil 11’de HOG’un çalışmasını gösteren sembolik görsel verilmiştir.

3.3.2. İki Boyutlu Dalgacık Dönüşümü (2DWT)

2DWT, görüntü işleme ve analizde yaygın olarak kullanılan güçlü bir tekniktir. Temel olarak, bir görüntüyü çeşitli frekans bileşenlerine ayırarak hem zaman hem de frekans bilgisi sağlar. Bu özellik, özellikle görüntü sıkıştırma, gürültü giderme ve özellik çıkarımı gibi uygulamalarda oldukça faydalıdır.

Dalgacık dönüşümü, tekrarlamalı bir filtreleme sürecidir. İki ilişkili filtre (yüksek geçiş ve alçak geçiş) kullanılarak veri filtrelenir ve çıktıları ikiye bölünerek alt örnekleme yapılır. Bu süreç, istenen dönüşüm derinliğine ulaşılan veya her bir filtrenin alt örneklenmiş sonucu tek bir veri noktası elde edene kadar devam eder. Tek boyutlu dalgacık dönüşümü (1DWT), orijinal sinyalin çeşitli filtreleme aşamalarının sonuçlarına ayrışmasını sağlar.



Şekil 15. 2DWT ve Makine Öğrenmesi Algoritmaları Akış Şeması

2DWT ise ayrılabilir bir görüntü dönüşümüdür. 1DWT'nin ilk aşaması, görüntünün yatay tarama çizgilerine ve ardından dikey tarama çizgilerine uygulanır. Bu, yüksek-yüksek, yüksek-alçak, alçak-yüksek ve alçak-alçak olmak üzere dört daha küçük filtrelenmiş görüntü üretir. Alçak-alçak sonucu, 1DWT'de olduğu gibi aynı süreçle tekrar filtrelenir. Bu işlem, görüntünün frekans detaylarının belirli bir döşemesini üretir ve çeşitli filtreleme aşamalarında tüm ayrışmayı sağlar.

1D/2D alan, hem uzayda hem de ölçek/frekans boyutunda, güçteki yerel değişimlerin analizine, etkili bir ölçek ayrıştırmasına ve en uygun gürültü giderme, filtreleme ve temizleme işlemlerine olanak tanır. 1DWT değişkenliği incelemek ve karakterize etmek

için kullanılabilir. [43].

```
% Görüntüyü yükle
image = imread('ornek_goruntu.jpg');
image = rgb2gray(image); % Görüntüyü gri tonlamalı hale getir

% Dalgacık Dönüşüm seviyesini seç (örnek olarak 2 seviye)
level = 2;

% Kullanılacak dalgacığı seç (örnek olarak 'haar' dalgacığı)
waveletType = 'haar';

% 2D Dalgacık Dönüşümünü uygula
[C, S] = wavedec2(image, level, waveletType);

% Detay katsayılarını çıkar
[H, V, D] = detcoef2('all', C, S, level);

% Approximation katsayısını çıkar
A = appcoef2(C, S, waveletType, level);

% Detay ve Approximation katsayılarının görselleştirilmesi
figure;

% Original görüntü
subplot(2, 3, 1);
imshow(image);
title('Original Görüntü');

% Approximation
subplot(2, 3, 2);
imagesc(A);
colormap gray;
title('Approximation');

% Horizontal
subplot(2, 3, 3);
imagesc(H);
colormap gray;
title('Horizontal Detay');

% Vertical
subplot(2, 3, 4);
imagesc(V);
colormap gray;
title('Vertical Detay');

% Diagonal
subplot(2, 3, 5);
imagesc(D);
colormap gray;
title('Diagonal Detay');
```

Şekil 16. 2DWT Öznitelik Üretme Örnek Kod Parçası

Yatay Yönlü Filtreleme (Satır Dönüşümü): Görüntünün her satırına 1DWT uygulanır. Yüksek geçiş ve düşük geçiş filtreleri kullanılarak her satır iki ayrı bileşene ayrılır. Bu

bileşenler, her iki örnekte bir veri noktası bırakılarak alt örneklenir.

Dikey Yönlü Filtreleme (Sütun Dönüşümü): Elde edilen satır bileşenlerine benzer şekilde, her sütuna 1DWT uygulanır. Yine yüksek geçiş ve düşük geçiş filtreleri kullanılarak her sütun iki bileşene ayrılır ve alt örneklenir.

Bu iki aşamalı filtreleme sonucunda dört alt görüntü elde edilir:


LL (Düşük-Düşük): Hem satır hem de sütun düşük geçiş filtresi uygulanmış bileşen.

LH (Düşük-Yüksek): Satır düşük geçiş ve sütun yüksek geçiş filtresi uygulanmış bileşen.

HL (Yüksek-Düşük): Satır yüksek geçiş ve sütun düşük geçiş filtresi uygulanmış bileşen.

HH (Yüksek-Yüksek): Hem satır hem de sütun yüksek geçiş filtresi uygulanmış bileşen.

Tekrarlamalı filtreleme ile elde edilen LL bileşeni, daha fazla detay seviyesine inmek amacıyla tekrar aynı süreçle filtrelendir. Bu tekrarlamalı işlem, istenen dönüşüm derinliğine ulaşılan kadar devam eder. Şekil 12’de ve Şekil 13’te 2DWT yönteminin aşamalarını göstermektedir.



Şekil 17. Tek boyutlu dalgacık dönüşümü filtrelemesi. [44].

$$W[A] = W[A] - \frac{1}{m} \sum_{i=1}^m \Delta(R, H_i, A) + \frac{1}{m} \sum_{j=1}^m \Delta(R, H_j, A) \quad (3.4.1.1)$$

$\Delta(R, H_i, A)$: R ve komşu H arasındaki A özelliği farkı. Bu fark, sürekli özellikler için genellikle özellik değerlerinin mutlak farkı, kategorik özellikler için ise genellikle bir delta fonksiyonu (aynı ise 0, farklı ise 1) olarak hesaplanır. $W[A]$, A özelliğinin ağırlığıdır. m, seçilen örnek sayısını belirtir. H_i , i'inci hit komşuyu, H_j ise j'inci miss komşuyu ifade eder [45].

```
% Örnek veri kümesi ve etiketler oluştur (bu, kendi veri kümenizle değiştirilmelidir)
data = rand(100, 5); % 100 gözlem ve 5 özellik
labels = randi([0, 1], 100, 1); % Binary class

% ReliefF algoritmasını uygulama
[idx, weights] = reliefF(data, labels, 10); % 10 en yakındaki komşu değerlendirilir

% Önem sırasına göre özellikleri sıralama ve görselleştirme
figure;
bar(weights(idx));
xlabel('Özellik Dizini');
ylabel('Özellik Önemi Ağırlığı');
title('ReliefF ile Özellik Önem Ağırlıkları');
```

Şekil 19. ReliefF Öznitelik Seçimi Örnek Kod Parçası

Özelliklerin seçilmesi ağırlıklandırma süreci tamamlandığında, en yüksek ağırlığa sahip özellikler seçilir. Bu özellikler, veri setindeki sınıflandırma performansına en çok katkı sağlayan özellikler olarak değerlendirilir.

Avantajları, korelasyonları yakalama, özellikler arasındaki bağımlılıkları ve etkileşimleri yakalayabilir. Özelliklerin sınıflandırma performansına etkisini dikkate alarak daha doğru bir seçme yapar. Gürültüye dayanıklılık verilerde dahi iyi performans gösterir, çünkü örneklerin komşuları arasındaki farklara odaklanır. Çok sınıflı problemler veri setlerinde etkili bir şekilde çalışabilir ve farklı sınıflar arasındaki ayrımları değerlendirebilir [46].

Dezavantajları, hesaplama süresi yüksek boyutlu ve büyük veri setlerinde hesaplama süresi yüksek olabilir. Özellikle komşu arama işlemleri zaman alıcıdır. Sınırlı özellik seçimi sınıflandırma problemleri için uygundur ve regresyon problemlerinde doğrudan kullanılmaz [47].

3.4.2. Ana Bileşen Analizi (PCA)

Tarihsel olarak PCA'nın kökleri, 1901 yılında İngiliz matematikçi Karl Pearson'ın çalışmalarıyla başlar. Pearson, PCA'yı "Principal Axes" yöntemi olarak tanımlamış ve

doğrusal bir dönüşüm olarak verilerin boyutunu azaltma amacıyla kullanmıştır. Pearson, bu yöntemi istatistiksel analizlerde veri setlerinin temel yapısını anlamak için geliştirmiştir. PCA, büyük veri setlerinin boyutunu azaltmak için yaygın olarak kullanılan güçlü bir istatistiksel tekniktir. PCA'nın temel amacı, büyük ve karmaşık veri setlerindeki değişkenler arasındaki korelasyonları azaltarak, daha küçük ve birbirinden bağımsız ana bileşenler oluşturmak ve böylece veri setinin çoğu değişkenliğini korumaktır. PCA uygulanmadan önce, değişkenler farklı ölçeklerde ölçülüyorsa verilerin standardize edilmesi kritik öneme sahiptir. Standardizasyon, her bir değişkenin ortalamasının sıfır ve standart sapmasının bir olacak şekilde yeniden ölçeklendirilmesini içerir [48].

```
% Örnek veri kümesi oluştur
data = rand(100, 5); % 100 gözlem ve 5 özellik

% PCA uygulama
[coeff, score, latent, tsquared, explained] = pca(data);

% İlk iki ana bileşeni görselleştirme
figure;
scatter(score(:,1), score(:,2));
xlabel('PC 1');
ylabel('PC 2');
title('İlk İki Ana Bileşenin Saçılım Grafiği');
```

Şekil 20. PCA Öznetelik Seçimi Örnek Kod Parçası

Standardize edilmiş verilerin konveryans matrisinin hesaplanması yapılır ve konveryans matrisi, değişkenler arasındaki ikili konveryansları yakalar ve bu da onların birlikte nasıl değiştiği hakkında bilgi sağlar.

$$C = \frac{1}{n-1} X^T X \quad (3.4.2.1)$$

burada X standardize edilmiş veri matrisidir ve n gözlem sayısıdır.

Özdeğer ayrışımı, PCA, konveryans matrisi C'nin özdeğer ayrışımını içerir. Bu ayrışım, özdeğerler ve karşılık gelen özvektörler verir.

$$C v_i = \lambda_i v_i \quad (3.4.2.2)$$

burada λ_i özdeğerler ve v_i C'nin özvektörleridir.

Özvektörler veri uzayında verinin en çok değiştiği yönleri temsil eder. Karşılık gelen özdeğerler ise her bir ana bileşenin açıkladığı değişkenlik miktarını gösterir. İlk ana

bileşen maksimum varyansı yakalar, ikincisi birinciye dik olarak ikinci en yüksek varyansı yakalar ve bu süreç bu şekilde devam eder. En yüksek özdeğerlere sahip ilk k ana bileşeni seçerek, PCA veri setinin boyutunu azaltır ve çoğu varyansını korur. Azaltılmış veri seti şu şekilde ifade edilebilir:

$$Z = XV_k \quad (3.4.2.3)$$

Burada V_k ilk k özvektörü içeren matristir.

Ana bileşenler birbirinden bağımsız olup, verideki farklı desenleri yakalar. Çıkan sonuçtaki varyans her bir ana bileşenin açıkladığı varyans oranı, özdeğerinin tüm özdeğerlerin toplamına oranıyla verilir. Bu, kaç ana bileşenin tutulacağına karar vermede yardımcı olur. Çizgi grafiği, özdeğerlerin grafiksel bir temsidir. Açıklanan varyansın azalmaya başladığı noktayı görselleştirerek, kaç ana bileşen seçileceğine karar vermeye yardımcı olur. Ana Bileşen Analizi (PCA), veri bilimi ve istatistikte boyut azaltma, yorumlanabilirliği artırma ve karmaşık veri setlerinin yapısını basitleştirme konusunda temel bir araçtır [49].

3.5. MAKİNE ÖĞRENMESİ

3.5.1. K En Yakın Komşu (K-NN)

K-NN algoritması, 1950'lerin başında Evelyn Fix ve Joseph L. Hodges Jr. tarafından geliştirilmiş ve 1965 yılında N.J. Nilsson'ın minimum mesafe sınıflayıcı çalışmalarıyla gelişimi hızlanmıştır. 1967 yılında Thomas M. Cover ve Peter E. Hart tarafından genişletilerek istatistiksel analizler (regresyon) için kullanımı önerilmiştir. 1968'de Cover ve Hart, K-NN algoritmasını tanıtmış ve algoritma kısa süre sonra tamamlanmıştır. K-NN, Öklid mesafe hesaplanarak uygulanabilir, ancak diğer ölçütler de kullanılabilir. Yine de Öklid mesafe, kolaylık, verimlilik ve üretkenliğin mükemmel bir birleşimini sunar. K-NN etiketlerinin çoğunluğuna göre sınıflandırılır. Başka bir deyişle, bu yöntem oldukça kolay uygulanabilir; örneğin, "x" örneği, özellik uzayında K-NN'ye sahipse ve bunların çoğunluğu aynı "y" etiketine sahipse, o zaman "x" "y" etiketine ait olur. K-NN yöntemi, teori göz önünde bulundurulduğunda, en çok öne çıkan teoreme dayanır. Karar sürecinde, az sayıda en yakın komşu dikkate alınmalıdır. Bu nedenle, bu yöntem kullanıldığında, örnek orantısızlık problemi çözülebilir. K-NN tarafından sınırlı sayıda en yakın komşu dikkate alınırken, bir karar sınırı oluşturulmaz. Bu nedenle, K-NN'nin sınırların kesiştiği

örnek kümesini sınıflandırmak için uygun olduğunu söylemek mümkündür ve bu durumda örnekler örtüşebilir [50].

```
% Örnek veri kümesi oluştur
data = rand(100, 5); % 100 gözlem ve 5 özellik
labels = randi([0, 1], 100, 1); % Binary class

% Veri kümesini eğitim ve test olarak bölme
cv = cvpartition(labels, 'HoldOut', 0.3);
trainData = data(training(cv), :);
trainLabels = labels(training(cv));
testData = data(test(cv), :);
testLabels = labels(test(cv));


% k-NN sınıflandırıcısı
k = 5;
Mdl = fitcknn(trainData, trainLabels, 'NumNeighbors', k);

% Test veri kümesinde sınıflandırma yapma
predictions = predict(Mdl, testData);

% Başarı oranını hesapla
accuracy = sum(predictions == testLabels) / length(testLabels);
fprintf('k-NN Accuracy: %.2f%%\n', accuracy * 100);
```

Şekil 21. K-NN Makine Öğrenmesi Algoritması Örnek Kod Parçası

X, Y ve Z olmak üzere üç sınıfın bulunduğunu gösterir Şekil 14'te gösterildiği şimdi, P veri örneği için sınıf etiketini bulmak gerekmektedir. Burada, K=5 değeri kullanılır ve her örnek çifti için Öklid mesafe hesaplanır ve en yakın dört komşu örneğinin X sınıf etiketine, bir örneğin ise Z sınıf etiketine ait olduğu bulunur. Bu nedenle, P örneği, bu örnek için baskın sınıf olduğu için X sınıfına atanır [51].



Şekil 22. K-NN [51].

3.5.2. Naive Bayes (NB)

Naive Bayes algoritması, Thomas Bayes'in 18. yüzyılda geliştirdiği Bayes teoremine dayanmaktadır. Bayes teoremi, bir olayın olasılığını, önceki bilgi veya kanıtlar ışığında güncelleyerek hesaplamak için kullanılan bir istatistiksel yöntemdir. NB algoritması, bu teoremi kullanarak veri sınıflandırma problemlerine çözüm sunar. İlk olarak 1950'lerde metin sınıflandırma alanında kullanılmıştır ve o zamandan beri birçok uygulama alanında yaygın olarak kullanılmaktadır.

```
% Örnek veri kümesi oluştur
data = rand(100, 5); % 100 gözlem ve 5 özellik
labels = randi([0, 1], 100, 1); % Binary class

% Veri kümesini eğitim ve test olarak bölme
cv = cvpartition(labels, 'HoldOut', 0.3);
trainData = data(training(cv), :);
trainLabels = labels(training(cv));
testData = data(test(cv), :);
testLabels = labels(test(cv));

% Naive Bayes sınıflandırıcısı
Mdl = fitcnb(trainData, trainLabels);

% Test veri kümesinde sınıflandırma yapma
predictions = predict(Mdl, testData);

% Başarı oranını hesapla
accuracy = sum(predictions == testLabels) / length(testLabels);
fprintf('Naive Bayes Accuracy: %.2f%%\n', accuracy * 100);
```

Şekil 23.NB Makine Öğrenmesi Algoritması Örnek Kod Parçası

NB, sınıflandırma problemlerinde kullanılan bir olasılık tabanlı modeldir. Temel varsayımı, özelliklerin birbirinden bağımsız olduğu ve her bir özelliğin sınıfa katkısının eşit olduğu "naive" (saf) varsayımdır. Bu varsayım genellikle gerçekte geçerli olmasa da, pratikte oldukça iyi sonuçlar verir. NB'nin matematiksel temeli şu şekildedir:

$$P(C|X) = \frac{P(X|C) * P(C)}{P(X)} \quad (3.5.2.1)$$

Naive Bayes sınıflandırıcısı, verilen bir veri örneği X için her sınıf C'nin olasılığını ($P(C|X)$: X özellik vektörü verildiğinde C sınıfının olasılığı) hesaplar ve en yüksek olasılığa sahip sınıfı seçer. Bu hesaplamada $P(X|C)$ (C sınıfı verildiğinde X özellik vektörünün olasılığı), $P(C)$ (C sınıfının öncelikli olasılığı) ve $P(X)$ (X özellik vektörünün

toplam olasılığı) kullanılır. Naive Bayes algoritması, basit bir yapıya sahip olması ve hesaplama açısından verimli olması nedeniyle hızlı çalışır; eğitim ve tahmin süreleri genellikle oldukça kısadır. [52] Özellikle bağımsızlık varsayımının geçerli olmadığı durumlarda tahmin gücü azalır ve performansı düşer [53].

3.5.3. Karar Ağacı (DT)

Karar ağacı, makine öğrenmesi alanında yaygın olarak kullanılan bir sınıflandırma ve regresyon yöntemidir. Karar ağacı, verileri kullanarak bir dizi karar yapısını temsil eden bir ağaç yapısı oluşturur. Her iç düğüm, bir özellik veya öznitelikle ilişkili bir karar noktasını temsil ederken, yaprak düğümleri ise sonuçları veya sınıfları temsil eder. [54] Karar ağaçları, özellikle anlaşılabilirliği ve yorumlanabilirliği yüksek olması nedeniyle tercih edilir. Bir karar ağacı modeli oluşturulurken, veri setindeki özniteliklerin ve hedef sınıfların ilişkileri dikkate alınır. Veri setindeki her özellik, bir ağaçta bir düğüm olarak temsil edilir ve veri setinin ayrıştırılması için en iyi karar noktası belirlenir. Bu süreç, bilgi kazancı, Gini indeksi veya diğer benzer ölçütler kullanılarak gerçekleştirilir. [55] Entropi, veri setindeki belirsizliği ölçer ve bir veri seti tek bir sınıfa sahipse (örneğin, tüm örnekler aynı sınıfa aitse), entropisi düşük olur. Karar ağaçları, entropiyi minimize edecek şekilde veri setini bölerek daha kesin tahminler yapar. Bilgi kazancı, bir özniteliğin bölünmesi sonucu elde edilen entropi azalmasını ölçer; yani orijinal veri setinin entropisi ile bölünmüş her bir alt kümenin entropisi arasındaki farktır. Bu yaklaşım, en bilgilendirici bölünmeleri belirleyerek karar ağacının veri setini etkin bir şekilde sınıflandırmasını sağlar.

$$H = -\sum p(x) \log p(x) \quad (3.5.3.1)$$

Burada, $p(x)$ belirli bir sınıfa ait grubun yüzdesini ve H ise entropiyi belirtmektedir. En iyi bölünmeyi belirlemek içinde bilgi kazancı kullanılır. Bilgi kazancı aşağıdaki eşitlik ile hesaplanır.

$$Gain(S, D) = H(S) - \sum_{V \in D} \frac{|V|}{|S|} H(V) \quad (3.5.3.2)$$

Burada, S orijinal veri kümesidir ve D ise kümenin bölünmüş bir parçasıdır. Her V , S 'nin bir alt kümesidir. V 'nin tümü ayrıktır ve S 'yi oluşturmaktadır. Bu durumda bilgi kazancı,

bölünmeden önceki orijinal veri setinin entropisi ile her bir özneliğin entropi değeri arasındaki fark olarak tanımlanmaktadır.

Öznitelik seçimi, Karar ağacını oluştururken, ilk adım her düğümde hangi özneliklerin kullanılacağını belirlemektir. Bu seçim, veri setini en iyi şekilde ayırabilen özneliklerin belirlenmesiyle yapılır. Bilgi kazancı, gini indeksi gibi ölçütler, hangi özneliğin seçileceğine karar vermede kullanılır.

Düğüm oluşturma, seçilen özneliğe göre veri seti, alt kümelerine ayrılır. Her bir alt küme, ağacın bir sonraki düzeyinde bir düğüme karşılık gelir. Bu süreç, tüm veriler homojen bir şekilde sınıflandırılana kadar veya belirlenen bir derinlik seviyesine ulaşana kadar devam eder.

```
% Örnek veri kümesi oluştur
data = rand(100, 5); % 100 gözlem ve 5 özellik
labels = randi([0, 1], 100, 1); % Binary class

% Veri kümesini eğitim ve test olarak bölme
cv = cvpartition(labels, 'HoldOut', 0.3);
trainData = data(training(cv), :);
trainLabels = labels(training(cv));
testData = data(test(cv), :);
testLabels = labels(test(cv));

% Decision Tree sınıflandırıcısı
Mdl = fitctree(trainData, trainLabels);

% Test veri kümesinde sınıflandırma yapma
predictions = predict(Mdl, testData);

% Başarı oranını hesapla
accuracy = sum(predictions == testLabels) / length(testLabels);
fprintf('Decision Tree Accuracy: %.2f%%\n', accuracy * 100);

% Decision Tree'yi görselleştirme
view(Mdl, 'Mode', 'graph');
```

Şekil 24. DT Makine Öğrenmesi Algoritması Örnek Kod Parçası


Yaprak düğümleri ve kararlar, süreç sonunda, daha fazla bölünemeyen düğümlere ulaşılır. Bu düğümler, yaprak düğümleri olarak adlandırılır ve verilerin sınıflandırılması veya bir tahmin değeri üretilmesi gibi kararları temsil eder.

Dikkat edilmesi gerekenler, aşırı uyum karar ağacı çok derinleşirse, model aşırı uyuma eğiliminde olabilir. Bu, modelin eğitim verilerine mükemmel uyum sağlaması ancak yeni veriler üzerinde iyi genelleme yapamaması durumudur. Bu sorunu çözmek için, ağaç derinliğinin sınırlandırılması veya budama tekniklerinin kullanılması önerilir. Karar

ağaçları, eksik verilerle iyi başa çıkamayabilir ve kategorik özniteliklerin sayısal değerlere dönüştürülmesi gerekebilir. Bu, modelin daha etkili bir şekilde öğrenmesini sağlamak için önemli bir adımdır. Karar ağaçları, basitliği, yüksek yorumlanabilirliği ve esnek kullanım alanlarıyla makine öğrenmesi alanında popüler bir yöntemdir. Bu özellikler, özellikle karmaşık ve yüksek boyutlu veri setlerinde önemli avantajlar sunar.

3.5.4. Kaskat İleri Sinir Ağları (CFNN)

Kaskat ileri sinir ağları (Cascade Forward Neural Networks, CFNN), klasik ileri beslemeli sinir ağlarının bir çeşididir. Bu ağlar, 1990'ların başında geliştirilen ve çok katmanlı algılayıcıların (MLP) eksikliklerini gidermeyi amaçlayan bir yapı olarak ortaya çıkmıştır. CFNN'lerin kökenleri, sinir ağlarının mimarisini daha verimli hale getirme çabalarına dayanır. Bu mimarinin temel amacı, ağın öğrenme kapasitesini artırmak ve eğitim süresini azaltmaktır. CFNN, geleneksel ileri beslemeli ağlardan farklı olarak, her katmanda önceki tüm katmanlardan gelen çıktıları girdi olarak kullanır. Bu yapı, ilk olarak 1990 ve 1994 yıllarında Fritzke ve Fahlman & Lebiere tarafından önerilen Cascade-Correlation Learning Architecture ile benzerlikler taşır [56]. CFNN, daha karmaşık ve derin yapılar oluşturmak için katmanların ardışık olarak eklenmesi fikrine dayanır.



Şekil 25. CFNN Ağ Mimarisi [57] .

CFNN, klasik ileri beslemeli ağlara benzer şekilde çalışır ancak yapısal olarak daha karmaşıktır. Temel fark, her yeni katmanın yalnızca önceki katmandan değil, ağın tüm önceki katmanlarından girdi almasıdır. Bu yapı, daha derin öğrenme ve karmaşık veri desenlerinin daha iyi öğrenilmesini sağlar. CFNN'lerin eğitimi, genellikle gradyan iniş veya benzeri optimizasyon algoritmaları kullanılarak gerçekleştirilir. Eğitim sırasında, ağırlıklar ve bias değerleri, hatayı minimize etmek için interaktif olarak ayarlanır. Her yeni katman eklendiğinde, önceki katmanların çıktıları da dikkate alınarak ağırlıklar güncellenir.

```

Örnek veri kümesi oluştur
data = rand(100, 5); % 100 gözlem ve 5 özellik
labels = randi([0, 1], 100, 1); % Binary class

% Veri kümesini eğitim ve test olarak bölme
cv = cvpartition(labels, 'HoldOut', 0.3);
trainData = data(training(cv), :);
trainLabels = labels(training(cv));
testData = data(test(cv), :);
testLabels = labels(test(cv));

% Cascade Forward Neural Network (CFNN) sınıflandırıcısı
hiddenLayerSize = 10;
net = cascadeforwardnet(hiddenLayerSize);

% Ağı eğit
net = train(net, trainData', trainLabels');

% Test veri kümesinde sınıflandırma yapma
predictions = net(testData');
predictions = round(predictions);

% Başarı oranını hesapla
accuracy = sum(predictions' == testLabels) / length(testLabels);
fprintf('CFNN Accuracy: %.2f%%\n', accuracy * 100);

```

Şekil 26. CFNN Makine Öğrenmesi Algoritması Örnek Kod Parçası

Her bir nöronun çıktısı, aktivasyon fonksiyonu ile hesaplanır. Katmanlar arasındaki bağlantılar, ağırlık matrisleri ile temsil edilir ve her bir katmanın girdi vektörü, önceki katmanların çıktılarıyla birlikte hesaplanır.

$$y_i = f\left(\sum_{j=2}^n w_{ij}x_j + b_i\right) \quad (3.5.4.1)$$

CFNN'ler önceki tüm katmanlardan gelen bilgiyi kullanarak daha derin öğrenme sağlar ve karmaşık veri desenlerini daha iyi yakalar. Bu mimari, her katman arasındaki doğrudan bağlantılar sayesinde, öğrenme sürecinde daha fazla bilgi akışına izin verir. Örneğin, bir i nöronun çıktısı 3.5.4 formülüyle hesaplanır. Burada w_{ij} i nöron ile j nöron arasındaki ağırlığı, x_j j nöronun girdi değerini ve b_i i nöronun değerini temsil eder. Aktivasyon fonksiyonu f , bu birleşimi kullanarak i nöronun çıktısını belirler. CFNN'ler, genelleme yetenekleri sayesinde çeşitli problem türlerinde yüksek performans gösterir. Bu sayede, görüntü işleme, doğal dil işleme, zaman serisi analizi gibi farklı alanlarda başarıyla uygulanabilirler. Ayrıca, katmanlar arasındaki bu doğrudan bağlantılar, eğitim sürecini

hızlandırarak daha verimli bir öğrenme sağlar. Bu özellikler, CFNN'leri, geleneksel ileri beslemeli sinir ağlarına göre daha güçlü ve esnek bir araç haline getirir [58]. Şekil 15'te basit bir CFNN modeli ve ağ mimarisi örneği sunulmuştur. Çok sayıda katman ve nöron eklenmesi, modelin aşırı uyum yapma riskini artırabilir [59].



4. SONUÇLARIN ANALİZ VE DEĞERLENDİRİLMESİ

Sistemde sınıflandırma durumları için DT, K-NN, NB ve CFNN sınıflandırıcıları özellik çıkarım yöntemleri olarak HOG ve 2DWT son olarak özellik seçim yöntemleri olarak RF ve PCA elde edilen veri setlerine uygulanmıştır. Önerilen bu çalışmada intel Core i7-6700HQ @ 2.60GHz 16GB Ram 512 GB HardDisk özelliklerine sahip bilgisayarda MATLAB 2021a versiyonu kullanılarak uygulanmıştır.

Performans değerlendirmesi için Özellik Çıkarımı-Özellik Seçimi sınıflandırıcılara göre ayrı ayrı tablolar halinde sunulmuştur. Ayrıca her bir tablonun değerlendirilmesinin arkasından grafiklerle görsel olarak verilmiştir. Bu genel değerlendirmeyi yaptıktan sonra çalışmada kullanılan ölçüm metrikleri alt başlıklar halinde ayrıca verilmiştir.


Makine öğrenmesi algoritmalarının karşılaştırılması ve değerlendirilmesi, için Tablo 1 ve Tablo 2 HOG’u Tablo 3 ve Tablo 4 2DWT özellik çıkarım yönteminin performans sonuçlarını içermektedir.

Tablo 1. ReliefF ve HOG Öznitelik Analizlerinin Makine Öğrenmesi Algoritmaları Sonuçları

HOG- RF	K-NN	NB	DT	CFNN
Doğruluk	97,00%	98,00%	92,00%	99,00%
Duyarlılık	94,00%	94,00%	92,00%	96,00%
Hassasiyet	94,00%	97,92%	79,31%	100,00%
F-Skor	94,00%	95,92%	85,19%	97,96%
G-ortalaması	95,97%	96,63%	92,00%	97,98%

Tablo 2. PCA ve HOG Öznitelik Analizlerinin Makine Öğrenmesi Algoritmaları Sonuçları

HOG- PCA	K-NN	NB	DT	CFNN
Doğruluk	55,50%	92,00%	96,50%	94,50%
Duyarlılık	76,00%	86,00%	92,00%	92,00%
Hassasiyet	33,04%	82,69%	93,88%	86,79%
F-Skor	46,06%	84,31%	92,93%	89,32%
G-ortalaması	60,82%	89,91%	94,95%	93,65%



Şekil 27. ReliefF, PCA ve HOG Öznitelik Analizlerinin Grafıksel Gösterimi

K-NN algoritması genel olarak en düşük performansı sergileyen algoritmadır. Özellikle PCA-HOG veri setinde çok düşük doğruluk (%55.50) (Şekil 26) ve hassasiyet (%33.04) değerleriyle dikkat çekmektedir. Bu, K-NN'nin yüksek boyutlu verilerde ve karmaşık veri yapılarında yetersiz kalabileceğini göstermektedir. RF-HOG ve RF-2DWT veri setlerinde

performansı nispeten daha iyi olsa da, yine de diğer algoritmaların gerisinde kalmaktadır. Şekil 26'nın ilk bölümü olan RF-HOG bölümünde gösterildiği gibi K-NN'nin en iyi performans gösterdiği RF-HOG tespit edilmiştir. Bu veri setinde doğruluk (%97.00) ve hassasiyet (%94.00) olarak görülmektedir.


Naive Bayes algoritması, genellikle ortalama bir performans sergilemiştir. Tüm veri setlerinde doğruluk ve hassasiyet değerleri dengeli olup, özellikle RF-HOG ve PCA-HOG veri setlerinde iyi performans göstermektedir. PCA-HOG veri setinde %92.00 doğruluk ve %86.00 hassasiyet değerleriyle, K-NN'den çok daha iyi performans sergilemiştir. Ancak, RF-2DWT ve PCA-2DWT veri setlerinde diğer algoritmalar kadar yüksek performans gösterememiştir. Naive Bayes, özellikle bağımsızlık varsayımının geçerli olduğu durumlarda etkili olsa da, bu varsayımın ihlal edildiği karmaşık veri setlerinde performansı düşebilmektedir.

Tablo 3. ReliefF ve 2DWT Öznitelik Analizlerinin Makine Öğrenmesi Algoritmaları Sonuçları

RF-2DWT	K-NN	NB	DT	CFNN
Doğruluk	93,50%	93,00%	90,50%	97,50%
Duyarlılık	90,00%	86,00%	88,00%	94,00%
Hassasiyet	84,91%	86,00%	77,19%	95,92%
F-Skor	87,38%	86,00%	82,24%	94,95%
G-ortalaması	92,30%	90,55%	89,65%	96,31%

Tablo 4. PCA ve 2DWT Öznitelik Analizlerinin Makine Öğrenmesi Algoritmaları Sonuçları

PCA-2DWT	K-NN	NB	DT	CFNN
Doğruluk	93,00%	93,00%	93,00%	97,50%
Duyarlılık	88,00%	86,00%	90,00%	92,00%
Hassasiyet	84,62%	86,00%	83,33%	97,87%
F-Skor	86,27%	86,00%	86,54%	94,85%
G-ortalaması	91,27%	90,55%	91,98%	95,60%



Şekil 28. ReliefF, PCA ve 2DWT Öznitelik Analizlerinin Grafikselsel Gösterimi

Karar Ağacı algoritması, özellikle PCA-HOG veri setinde en yüksek doğruluk (%96.50) ve yüksek hassasiyet (%93.88) değerlerine ulaşarak iyi performans göstermiştir (Şekil 26 ve Tablo 2). Bununla birlikte, Tablo 3 ve Şekil 27’de görüldüğü gibi RF-2DWT veri setinde doğruluk (%90.50) ve hassasiyet (%77.19) değerleri diğer algoritmalara kıyasla daha düşüktür. Karar Ağacı’nın performansı genellikle veri setine bağlı olarak değişiklik göstermektedir, ancak genel olarak duyarlılık ve F-Skor metriklerinde tutarlı bir

performans sergilemiştir. Bu algoritma, veri setinin özelliklerinin iyi anlaşılması durumunda güçlü performans gösterebilir.

CFNN algoritması, genel olarak en yüksek performansı gösteren algoritmadır. Tablo 1 ve Şekil 26’da görüldüğü gibi RF-HOG veri setinde doğruluk (%99.00) ve hassasiyet (%100.00) gibi çok yüksek değerlere ulaşmıştır. Aynı zamanda RF-2DWT ve PCA-2DWT veri setlerinde de yüksek doğruluk ve hassasiyet değerleriyle dikkat çekmiştir. Örneğin, RF-2DWT veri setinde %97.50 doğruluk ve %95.92 hassasiyet, PCA-2DWT veri setinde %97.00 doğruluk ve %94.85 hassasiyet değerlerine sahiptir. CFNN'nin yüksek doğruluğu ve hassasiyeti, onun karmaşık ve büyük veri setlerinde üstün performans gösterme kapasitesini yansıtmaktadır. Sinir ağları, veri setinin öğrenme kapasitesini maksimize ederek daha doğru sonuçlar elde edebilir.

4.1. KARARLILIK MATRİSİ

Kararlılık matrisi, sınıflandırma modelinin performansını değerlendirmek için kullanılan önemli bir araçtır. Ayrıca hata matrisi veya karmaşıklık matrisi olarak da adlandırılan bu matris, modelin gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi görselleştirir. Kararlılık matrisi, dört ana bileşeni içerir: doğru pozitifler (DP), yanlış pozitifler (YP), doğru negatifler (DN) ve yanlış negatifler (YN).





DP, modelin doğru bir şekilde pozitif olarak sınıflandırdığı örneklerin sayısını temsil ederken, DN modelin doğru bir şekilde negatif olarak sınıflandırdığı örneklerin sayısını ifade eder. YP ise modelin yanlış bir şekilde pozitif olarak sınıflandırdığı örneklerin sayısını, YN ise modelin yanlış bir şekilde negatif olarak sınıflandırdığı örneklerin sayısını belirtir.

Gerçek Sınıflar		Normal Durum		i. Arıza
	Normal Durum	n_{11}	...	n_{1j}
		⋮		
	i. Arıza	n_{i1}		n_{ij}
	Tahmin Edilen Sınıflar			

Şekil 29. Sınıflandırma sonuçlarının değerlendirilmesi Karmaşıklık Matrisi

Kararlılık matrisi, bu dört bileşenin bir araya getirilmesiyle oluşturulur ve genellikle bir kare matris şeklinde sunulur. Bu matris, modelin performansını analiz etmek için çeşitli metriklerin hesaplanmasına olanak tanır. Hassasiyet, duyarlılık, özgünlük ve F1 puanı gibi metrikler, kararlılık matrisinin değerlerinden türetilir.





Kararlılık matrisi, sınıflandırma modelinin performansını anlamak için kritik bir araç olmasına rağmen, dengesiz veri setleriyle çalışırken dikkatli bir şekilde yorumlanmalıdır. Özellikle nadir sınıfların olduğu durumlarda, kararlılık matrisinin sağladığı bilgilerin dikkatlice analiz edilmesi önemlidir. Bu sayede, modelin gerçek performansı hakkında daha doğru bir değerlendirme yapılabilir.

	K-NN	NB
RF-HOG		
	DT	CFNN
		

Şekil 30. RF-HOG ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları

Şekil 30'da ve Şekil 31'de HOG özellik çıkarımı kararlılık matris sonuçlarına yer verilmiştir.





Şekil 30 kararlılık matrisleri incelendiğinde CFNN'nin en iyi DT'nin ise diğerlerine göre daha yanlış sonuçlar elde edildiği tespit edilmiştir.

	K-NN	NB
PCA-HOG		
	DT	CFNN
		

Şekil 31. PCA-HOG ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları





Şekil 31'da görüldüğü gibi K-NN algoritması PCA ile uygulandığında sınıflandırma sonuçlarının çok bozulduğu tespit edilmiştir.

Şekil 32 ve Şekil 33'de HOG'un yerine 2DWT özellik çıkarım yöntemi üzerine çalışılmıştır. Buna göre Şekil 21'de K-NN, NB ve DT sınıflandırıcılarında sonuçların HOG'a göre daha fazla yanlış sonuç ürettiği görülmektedir. Şekil 32 ve Şekil 30 karşılaştırıldığında HOG'un özellik çıkarım yöntemi olarak 2DWT'den daha iyi tahminler yaptığı görülmüştür.

	K-NN	NB
RF-2DWT		
	DT	CFNN
		

Şekil 32. RF-2DWT ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları

Şekil 33 kararlılık matrisi görsellerinde K-NN ve DT için diğer durumlarda söylenenler PCA-2DWT için de tekrarlamıştır. Yani K-NN için BMC 6*6 için 6 yanlış, Land Rover Defener için 6 yanlış ve son olarak Leopard Tank için 1 yanlış oluşmuştur. Aynı şekilde DT için BMC 6*6 için 5 yanlış, Land Rover Defener için 4 yanlış, M113 ZPT için 5 yanlış oluşmuştur. Bu iki tablo göstergesi PCA-2DWT'nin yöntemsel olarak en kötü sonuçları verdiği tespitin yapılmasını sağlamıştır.

	K-NN	NB
PCA- 2DWT		
	DT	CFNN
		

Şekil 33. RF-HOG ve Makine Öğrenmesi Kararlılık Matrisi Sonuçları

4.2. DOĞRULUK ANALİZİ

Doğruluk analizi, bir sınıflandırma modelinin doğru tahmin etme yeteneğini değerlendiren önemli bir ölçüdür. Doğruluk, modelin doğru sınıflandırılmış örneklerin toplam örnek sayısına oranını ifade eder.


$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (4.1.2)$$

Doğruluk değeri, genellikle 0 ile 1 arasında bir değer alır. 1'e ne kadar yakınsa, modelin tahmin etme yeteneği o kadar yüksektir. Ancak, dengesiz veri setlerinde doğruluk yalnızca yeterli olmayabilir çünkü model, çoğunluk sınıfını tahmin ederek yüksek bir

doğruluk elde edebilir. Bu nedenle, doğruluk analizi genellikle diğer performans metrikleriyle birlikte kullanılır, özellikle hassasiyet, duyarlılık ve F1 skoru gibi metriklerle bir arada ele alınarak modelin performansı daha kapsamlı bir şekilde değerlendirilir.

Tablo 5. Doğruluk Analizi Sonuçları

Doğruluk	K-NN	NB	DT	CFNN
RF-HOG	97,00%	98,00%	92,00%	99,00%
HOG-PCA	55,50%	92,00%	96,50%	94,50%
RF-2DWT	93,50%	93,00%	90,50%	97,50%
PCA-2DWT	93,00%	93,00%	93,00%	97,50%



Şekil 34. Doğruluk Analizi Grafıksel Gösterimi

K-NN, NB, DT ve CFNN dört farklı nitelik çıkarma yöntemi RF-HOG , HOG-PCA, RF-2DWT, PCA-2DWT ile kombinasyon halinde değerlendirilmiştir. Elde edilen sonuçlar doğruluk açısından analiz edilmiş, her bir kombinasyonun performansı karşılaştırılmıştır.

Şekil 33'te görüldüğü gibi K-NN algoritması, HOG-RF öznelik çıkarma metodu ile kullanıldığında %97 gibi oldukça yüksek bir doğruluk oranına ulaşmıştır. Bu, algoritmanın belirli öznelik setleriyle uyumlu olduğunu ve veri dağılımının komşuluk ilişkilerini yansıttığını göstermektedir. Ancak, HOG-PCA öznelik çıkarma metodu ile kombinasyon halinde kullanıldığında %55,50 gibi oldukça düşük bir doğruluk elde edilmiştir. Bu durum, PCA yöntemiyle indirgenen boyutlarda verinin önemli

özelliklerinin kaybolmuş olabileceğine işaret eder.

Naive Bayes (NB) algoritması, genel olarak %90 üzerinde bir doğruluk ile stabil bir performans sergilemiştir. Özellikle, HOG-RF ve PCA-2DWT öznelik çıkarma metodları ile %92 üzerinde doğruluk elde etmişken, HOG-PCA ile %92,00 oranında biraz daha düşük bir doğruluk sağlamıştır. Bu, Naive Bayes modelinin farklı veri yapılarına karşı dayanıklı olduğunu, ancak belirli öznelik çıkarım metodlarındaki varyansların performans üzerindeki etkisinin sınırlı kaldığını göstermektedir.

Tablo 5'te görüldüğü gibi DT yöntemi, HOG-RF ve HOG-PCA ile kullanıldığında sırasıyla %92,00 ve %96,50 gibi yüksek doğruluk oranları elde etmiştir. Bu, Karar Ağaçlarının heterojen veri setlerinde ve farklı öznelik kombinasyonlarında iyi performans gösterebileceğini işaret eder.

CFNN, tüm öznelik çıkarma yöntemleri ile konsistent bir şekilde yüksek doğruluk oranları sağlamıştır (%94,50 ve üzeri). Bu sonuçlar, CFNN'nin karmaşık öznelik ilişkilerini modelleyebilme kapasitesine ve genel veri yapılarındaki öznelikler arası ilişkileri başarıyla yakalayabilme yeteneğine işaret eder.

4.3. DUYARLILIK ANALİZİ

Duyarlılık analizi, bir sınıflandırma modelinin gerçek pozitif oranını değerlendirmek için kullanılan bir yöntemdir. Duyarlılık, aynı zamanda duyarlılık, duyarlılık oranı veya recall olarak da adlandırılır. Duyarlılık, modelin ne kadarının gerçek pozitifleri doğru bir şekilde tanımladığını gösterir.


Duyarlılık, genellikle 0 ile 1 arasında bir değer alır. 1'e ne kadar yakınsa, model o kadar iyi gerçek pozitifleri yakalayabiliyor demektir. Duyarlılık, özellikle hassaslık gerektiren durumlarda modelin performansını değerlendirmede önemlidir. Yüksek duyarlılık, modelin gerçek pozitifleri kaçırma olasılığının düşük olduğunu gösterir.

$$Duyarlılık = \frac{DP}{DP + YN} \quad (4.1.3)$$

Duyarlılık analizi, kararlılık matrisiyle birlikte kullanılarak modelin performansını daha kapsamlı bir şekilde değerlendirmeye yardımcı olur.

Tablo 6. Duyarlılık Analiz Sonuçları

Duyarlılık	K-NN	NB	DT	CFNN
RF-HOG	94,00%	94,00%	92,00%	96,00%
HOG-PCA	76,00%	86,00%	92,00%	92,00%
RF-2DWT	90,00%	86,00%	88,00%	94,00%
PCA-2DWT	88,00%	86,00%	90,00%	92,00%



Şekil 35. Duyarlılık Analizi Grafiksel Gösterimi

Duyarlılık, sınıflandırma modelinin pozitif sınıfı ne kadar iyi tespit edebildiğini gösteren bir metriktir. Bu çalışmada, K-NN, NB, DT ve CFNN algoritmaları, farklı öznitelik çıkarma yöntemleriyle birleştirilerek duyarlılık açısından değerlendirilmiştir. Her bir algoritma ve öznitelik çıkarma yöntemi kombinasyonunun duyarlılık performansı, bu analizde mercek altına alınmıştır.

Şekil 24’te görüldüğü gibi K-NN algoritması, HOG-RF öznitelik çıkarma tekniği ile %94 duyarlılık oranı elde etmiş, bu değer algoritmanın pozitif örnekleri tespit etme yeteneğinin yüksek olduğunu göstermektedir. Bununla birlikte, HOG-PCA ile %76 oranında daha düşük bir duyarlılık sergilemiştir. Bu, PCA yöntemi ile boyut indirgemenin, K-NN algoritmasının pozitif örnekleri tanıma kabiliyetini olumsuz etkilediğini düşündürülebilir.

Tablo 6’da görüldüğü gibi NB, HOG-PCA ile kullanıldığında %86, HOG-RF ile %94 gibi oranlarla genel olarak iyi bir duyarlılık performansı göstermiştir. Bu, Naive Bayes algoritmasının olasılık temelli yaklaşımının farklı öznitelik setlerindeki bilgiyi yeterince iyi kullanabildiğini gösterir. Ancak, HOG-PCA ile elde edilen düşük duyarlılık oranı, bu

yöntemin veri setinden önemli bilgilerin kaybına yol açabileceğine işaret eder.

DT, RF-2DWT ve PCA-2DWT yöntemleriyle %88 ve %90 gibi oranlarla istikrarlı bir duyarlılık sergilemiştir. Bu, Karar Ağaçlarının farklı öznitelik çıkarma tekniklerine iyi uyum sağlayabildiğini ve pozitif sınıfları etkili bir şekilde tespit edebildiğini göstermektedir.

CFNN ise tüm öznitelik çıkarma yöntemleriyle yüksek duyarlılık değerleri elde etmiştir (%94 ve üzeri). Özellikle HOG-RF ile %96 oranında duyarlılık elde edilmiş, bu da CFNN'nin karmaşık öznitelik ilişkilerini başarılı bir şekilde işleyerek pozitif sınıfları yüksek doğrulukla tespit edebildiğini gösterir.

Bu analiz, farklı sınıflandırma algoritmalarının ve öznitelik çıkarma yöntemlerinin pozitif sınıfları tespit etme yeteneğinde nasıl farklılık gösterdiğini ortaya koymaktadır. Her bir algoritma ve öznitelik çıkarma yöntemi kombinasyonunun, belirli veri yapıları ve sınıf dağılımları üzerindeki etkileri, model seçimi ve ayarlaması sırasında dikkate alınmalıdır.

4.4. HASSASİYET ANALİZİ

Hassasiyet ile toplam pozitif olarak tahmin edilen örneklerin doğru tahmin edilme oranı ölçülmektedir. Dolayısıyla, hassasiyet oranı doğru sınıflandırılan pozitif örneklerin pozitif olarak tahmin edilen toplam örnek sayısına bölünmesiyle elde edilmektedir.. Hassasiyet, genellikle 0 ile 1 arasında bir değer alır. Hassasiyet ne kadar yüksek olursa, modelin yanlış pozitifleri azaltma yeteneği o kadar iyidir. Yani, model gerçekten pozitif olan örnekleri yanlışlıkla negatif olarak sınıflandırmaz. Hassasiyet hesaplama formülünü aşağıda yer verilmektedir


$$Hassasiyet = \frac{DP}{DP + YP} \quad (4.1.4)$$

Hassasiyet analizi, özellikle maliyetli yanlış pozitif tahminlerin önemli olduğu durumlarda (örneğin, sahte alarmların azaltılması gereken güvenlik uygulamalarında) modelin performansını değerlendirmede önemlidir. Hassasiyet, duyarlılık ile birlikte kullanılarak modelin performansının tamamlayıcı bir ölçüsünü sağlar.

Hassasiyet, sınıflandırma modelinin pozitif olarak tahmin ettiği durumların, gerçekten pozitif olma oranını ifade eder. K-NN, NB, DT, CFNN farklı öznitelik çıkarma yöntemleriyle kombinasyon halinde hassasiyet açısından değerlendirilmiştir.

Tablo 7. Hassasiyet Analiz Sonuçları

Hassasiyet	K-NN	NB	DT	CFNN
RF-HOG	94,00%	97,92%	79,31%	100,00%
HOG-PCA	33,04%	82,69%	93,88%	86,79%
RF-2DWT	84,91%	86,00%	77,19%	95,92%
PCA-2DWT	84,62%	86,00%	83,33%	97,87%



Şekil 36. Hassasiyet Analizi Grafiksel Gösterimi

K-NN algoritması, HOG-RF öznitelik çıkarma yöntemiyle %94,00 (Tablo 7) gibi yüksek bir hassasiyet değerine ulaşmıştır. Bu, algoritmanın pozitif tahminlerinin yüksek oranda doğru olduğunu göstermektedir. Ancak HOG-PCA ile %33,04 gibi daha düşük bir hassasiyet değeri elde edilmiştir, bu da boyut indirgemenin algoritmanın pozitif tahmin kabiliyetini olumsuz etkileyebileceğini düşündürülebilir.

NB, HOG-RF ile kullanıldığında %97,92 (Tablo 7) ile en yüksek hassasiyet oranlarından birini sergilemiştir, bu da Naive Bayes algoritmasının bu öznitelik çıkarma yöntemi ile etkili bir şekilde çalıştığını gösterir. Bununla birlikte, HOG-PCA ile %86,00 gibi daha düşük bir hassasiyet değeri elde edilmiş olup, bu durum da pca yönteminin Naive Bayes için optimal olmayabileceğini gösterir.

Şekil 25'te DT, HOG-RF ile %100,00 gibi mükemmel bir hassasiyet değeri elde etmiştir. Bu, Karar Ağaçlarının bu öznitelik çıkarma yöntemi ile çok kesin pozitif tahminler yapabildiğini gösterir. Ancak, HOG-PCA ile %92,00 gibi biraz daha düşük bir değer

gözlemlenmiştir.

CFNN tüm öznitelik çıkarma teknikleri ile yüksek hassasiyet değerleri sağlamıştır (%85,00 ve üzeri). Özellikle HOG-RF ile %100,00 gibi mükemmel bir hassasiyet elde edilmiştir, bu da CFNN'nin bu öznitelik çıkarma yöntemi ile pozitif tahminlerde çok yüksek doğruluk sağladığını gösterir.

Genel olarak, bu analiz farklı sınıflandırma algoritmalarının ve öznitelik çıkarma yöntemlerinin, pozitif olarak tahmin edilen durumların gerçekten pozitif olma oranlarında nasıl farklılık gösterdiğini ortaya koymaktadır. Hassasiyet değerleri, özellikle pozitif tahminlerin maliyetli olduğu uygulamalar için kritik öneme sahiptir. Algoritmaların ve öznitelik çıkarma yöntemlerinin kombinasyonlarının bu metrik üzerindeki etkileri, modelin uygulanacağı alan ve özel durumlar göz önünde bulundurularak değerlendirilmelidir.

4.5. F-SKOR ANALİZİ

F skoru (F1 skoru olarak da bilinir), bir sınıflandırma modelinin performansını değerlendirmek için kullanılan önemli bir ölçüdür. F skoru, hassasiyet (precision) ve duyarlılık (recall) arasında bir denge sağlayarak, modelin genel performansını tek bir değerle ifade eder. Özellikle dengesiz veri setlerinde, sınıflandırma performansını değerlendirmede etkili bir metriktir.

$$F - \text{Skor} = 2 * \frac{\text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4.1.5)$$

F1 skoru, 0 ile 1 arasında bir değer alır. 1'e ne kadar yakınsa, modelin performansı o kadar iyidir. F1 skoru, hem hassasiyetin hem de duyarlılığın önemli olduğu durumlarda kullanışlıdır, çünkü bu iki metrik arasında bir denge sağlar. Yüksek bir F1 skoru, modelin hem doğru pozitifleri yüksek bir oranda yakaladığını hem de yanlış pozitiflerin sayısını düşük tuttuğunu gösterir.


F1 skoru, özellikle dengesiz veri setlerinde önemli bir performans ölçütüdür. Örneğin, nadir olayları (örneğin, hastalık teşhisi gibi) tespit eden bir modelde, yüksek bir F1 skoru, modelin bu nadir olayları tespit etme yeteneğini doğru bir şekilde yansıtır.

Sonuç olarak, F1 skoru, sınıflandırma modelinin performansını değerlendirmek için hassasiyet ve duyarlılığı dengeleyen kapsamlı bir ölçüttür ve özellikle dengesiz veri

setlerinde kullanışlıdır. Modelin gerçek performansını tam olarak anlamak için F1 skoru, diğer performans metrikleriyle birlikte değerlendirilmeli ve yorumlanmalıdır.

Tablo 8. F-Skor Analiz Sonuçları

F-Skor	K-NN	NB	DT	CFNN
RF-HOG	94,00%	95,92%	85,19%	97,96%
HOG-PCA	46,06%	84,31%	92,93%	89,32%
RF-2DWT	87,38%	86,00%	82,24%	94,95%
PCA-2DWT	86,27%	86,00%	86,54%	94,85%



Şekil 37. F-Skor Analizi Grafiksel Gösterimi

F-Skor, bir sınıflandırma modelinin duyarlılık (sensitivity) ve hassasiyet (precision) metriklerinin harmonik ortalamasını alarak her iki metriği dengede tutmayı amaçlar. Bu çalışmada, dört farklı sınıflandırma algoritması K-NN, NB, DT, CFNN dört farklı öznelik çıkarma yöntemiyle HOG-RF, HOG-PCA, RF-2DWT, PCA-2DWT birleştirilerek F-Skor açısından değerlendirilmiştir.

Tablo 8’de K-NN algoritması, HOG-RF ile %94,00 gibi yüksek bir F-Skor elde etmiştir, bu algoritmanın hem duyarlılık hem de hassasiyet açısından dengeli bir performans sergilediğini göstermektedir. Ancak, HOG-PCA ile %46,06 gibi düşük bir F-Skor değeri gözlemlenmiştir, bu da bu öznelik çıkarma yöntemi ile K-NN algoritmasının verimli çalışmadığını işaret eder.

NB, HOG-RF ile %95,92 ile oldukça yüksek bir F-Skor sağlamıştır, bu da algoritmanın

bu öznitelik çıkarma yöntemi ile hem duyarlılık hem de hassasiyeti başarılı bir şekilde optimize ettiğini gösterir. Diğer yandan, HOG-PCA ile %84,31 gibi daha düşük bir F-Skor elde edilmiş olup, bu durum PCA yönteminin NB için optimal olmayabileceğini gösterir.

Şekil 26'da DT, HOG-RF ile %87,38 gibi iyi bir F-Skor elde etmiştir, bu da karar ağaçlarının bu öznitelik çıkarma yöntemi ile dengeli bir performans sergilediğini gösterir. HOG-PCA ile de %86,27 gibi benzer bir performans göstermiş, bu da Karar Ağaçlarının farklı öznitelik çıkarma tekniklerine karşı oldukça güçlü olduğunu işaret eder.

CFNN, tüm öznitelik çıkarma yöntemleri ile yüksek F-Skorları elde etmiştir (%89,32 ve üzeri). Özellikle HOG-RF ile %97,96 gibi mükemmel bir F-Skor sağlamıştır, bu da CFNN'nin bu öznitelik çıkarma yöntemi ile hem yüksek duyarlılık hem de yüksek hassasiyet sağlayabildiğini gösterir.

Bu analiz, farklı sınıflandırma algoritmalarının ve öznitelik çıkarma yöntemlerinin, F-Skor açısından nasıl farklılık gösterdiğini ortaya koymaktadır. F-Skor, modelin genel performansının dengeli bir ölçümünü sağlar ve özellikle algoritmaların ve öznitelik çıkarma yöntemlerinin her iki metriği nasıl optimize ettiğini gözlemlemek için yararlıdır. Algoritma seçimi ve parametre ayarlaması sırasında bu dengeli performans göstergesi, özellikle duyarlılık ve hassasiyetin her ikisi de önemli olduğu durumlar için kritik öneme sahiptir.

4.6. GEOMETRİK ORTALAMA

Geometrik ortalama, bir veri kümesindeki değerlerin çarpımlarının nüfusa (yani toplam örnek sayısına) olan oranının nüfus köküne eşitlenmesiyle bulunan bir merkezsiz eğilim ölçüsüdür. Bu ölçüm, özellikle oranlar, yüzdelikler veya diğer orantısal verilerle ilgili olduğunda kullanışlıdır. Geometrik ortalama, bir veri setindeki değerlerin çarpımlarının, veri setindeki değerlerin sayısına (n) bölünmesiyle elde edilir. Bu işlem, aritmetik ortalama ile farklı olarak, verilerin çarpılmasına ve ardından bu çarpımın n'inci kökünün alınmasına dayanır. Geometrik ortalama, özellikle büyüme oranları gibi çarpımlı ilişkilerin olduğu durumlarda anlamlıdır.

$$G - \text{Ortalama} = \left(\prod_{j=2}^n x_i \right)^{\frac{1}{2}} \quad (4.1.6)$$

Geometrik ortalama, bazı özel durumlar dışında, her zaman aritmetik ortalamadan daha düşük veya ona eşittir. Bu, özellikle verilerin dağılımında büyük farklılıklar olduğunda geçerlidir. Aritmetik ortalama, aşırı değerlerden etkilenirken, geometrik ortalama bu tür etkileri daha az hisseder ve bu nedenle daha güvenilir bir merkezi eğilim ölçüsü olabilir.

Geometrik ortalama, sadece pozitif değerlerle çalışır ve negatif veya sıfır değerlerle anlamlı bir sonuç vermez. Bu, verilerin pozitif olduğu ve çarpımlı ilişkilerin önemli olduğu durumlarda kullanımı daha uygun hale getirir. Örneğin, büyüme oranları, finansal getiriler ve biyolojik oranlar gibi durumlarda geometrik ortalama tercih edilir.

Sonuç olarak, geometrik ortalama, özellikle oransal verilerle ve çarpımlı ilişkilerle çalışırken güvenilir bir merkezi eğilim ölçüsüdür. Veri setindeki değerlerin çarpımlarının n'inci kökünü alarak hesaplanır ve bu sayede aritmetik ortalamaya göre daha az yanıltıcı sonuçlar verebilir. Geometrik ortalama, büyüme oranları ve getiri hesaplamalarında yaygın olarak kullanılır.

Tablo 9. Geometrik Ortalama Analiz Sonuçları


G-Ortalaması	K-NN	NB	DT	CFNN
RF-HOG	95,97%	96,63%	92,00%	97,98%
HOG-PCA	60,82%	89,91%	94,95%	93,65%
RF-2DWT	92,30%	90,55%	89,65%	96,31%
PCA-2DWT	91,27%	90,55%	91,98%	95,60%

G-Ortalama, bir sınıflandırma modelinin duyarlılık ve 1'den yanlış pozitif oranının çıkarılmasıyla hesaplanan değerlerin geometrik ortalamasıdır. Bu ölçüt, modelin hem pozitif hem de negatif sınıfları dengeli bir şekilde tanıyabilme yeteneğini değerlendirir. Bu çalışmada, K-NN, NB, DT, ve CFNN algoritmaları farklı öznelik çıkarma yöntemleriyle RF-HOG ,HOG-PCA, RF-2DWT, PCA-2DWT birleştirilerek G-Ortalama açısından incelenmiştir.

K-NN algoritması, HOG-RF ile %95,97 (Tablo 9) gibi yüksek bir G-Ortalama değeri elde etmiştir, bu değer algoritmanın hem pozitif hem de negatif sınıfları başarılı bir şekilde tespit edebildiğini gösterir. Ancak HOG-PCA ile %60,82 gibi oldukça düşük bir G-Ortalama değeri gözlemlenmiştir, bu da bu öznelik çıkarma yöntemi ile K-NN

algoritmasının yanlış pozitif oranında artışa yol açabileceğini düşündürebilir.

NB, HOG-PCA ile %80,82 gibi daha düşük bir G-Ortalama sağlamıştır, bu da yanlış pozitif oranının bu öznelik çıkarma yöntemi ile artmış olabileceğini gösterir. Diğer yandan, HOG-RF ile %95,67 gibi oldukça yüksek bir G-Ortalama elde edilmiş, bu da Naive Bayes'in bu öznelik çıkarma yöntemi ile daha dengeli bir performans sergilediğini gösterir.



Şekil 38. Geometrik Ortalama Analizi Grafiksel Gösterimi

DT, PCA-2DWT ile %91,98 gibi yüksek bir G-Ortalama değeri elde etmiştir, bu da Karar Ağaçlarının bu öznelik çıkarma yöntemi ile hem yanlış pozitif oranını düşük tuttuğunu hem de duyarlılıkta iyi sonuçlar elde ettiğini gösterir. RF-2DWT ile de %89,56 gibi benzer bir performans göstermiş, bu da Karar Ağaçlarının farklı öznelik çıkarma tekniklerine karşı oldukça robust olduğunu işaret eder.

Şekil 27’de görüldüğü gibi CFNN, HOG-RF ile %97,98 gibi mükemmel bir G-Ortalama değeri sağlamıştır, bu da CFNN'nin bu öznelik çıkarma yöntemi ile hem yüksek duyarlılık hem de düşük yanlış pozitif oranı sağlayabildiğini gösterir. Diğer öznelik çıkarma yöntemleri ile de genel olarak yüksek G-Ortalamalar elde edilmiştir.

Bu analiz, farklı sınıflandırma algoritmalarının ve öznelik çıkarma yöntemlerinin, modelin hem pozitif hem de negatif sınıfları dengeli bir şekilde tespit edebilme yeteneğinde nasıl farklılık gösterdiğini ortaya koymaktadır. G-Ortalama, özellikle

sınıflandırma problemlerinde dengeli bir performansın sağlanması gerektiğinde kritik bir ölçüttür. Algoritmaların ve öznitelik çıkarma yöntemlerinin kombinasyonlarının bu metrik üzerindeki etkileri, modelin uygulanacağı alan ve özel durumlar göz önünde bulundurularak değerlendirilmelidir.



5. BULGULAR VE TARTIŞMA

K-NN algoritması, RF-HOG öznitelik çıkarma yöntemiyle %97 doğruluk oranına ulaşarak, veri setindeki komşuluk ilişkilerini başarıyla yakaladığını göstermiştir. Aynı yöntem sonuçlarında ise %94 duyarlılık ve %94 hassasiyet değerleri elde edilmiştir. Bu sonuçlar, K-NN algoritmasının tespit etme ve doğru tahmin yapma konusunda yüksek performans sergilediğini ortaya koymaktadır. PCA-HOG öznitelik çıkarma yöntemiyle doğruluk oranı %55,50'ye düşmüş, duyarlılık %76 ve hassasiyet %76 olmuştur. Bu, PCA yönteminin boyut indirgeme sırasında önemli bilgileri kaybetmesine neden olduğunu göstermektedir ve K-NN algoritmasının performansını önemli NB algoritması, RF-HOG ve PCA-2DWT öznitelik çıkarma yöntemleriyle %92'nin üzerinde doğruluk oranı elde etmiştir. RF-HOG yöntemiyle %94 duyarlılık, %97,92 hassasiyet ve %95,92 F-Skor değerleri elde edilmiştir. Bu, NB modelinin olasılık temelli yaklaşımının farklı öznitelik setlerindeki bilgiyi etkili bir şekilde kullanabildiğini göstermektedir. Diğer yandan, PCA-HOG yöntemiyle %92 doğruluk oranı, %86 duyarlılık ve %86 hassasiyet ile performans biraz düşmüştür. Bu düşüş, PCA yöntemiyle indirgenen boyutlarda bazı önemli bilgilerin kaybolmuş olabileceğine işaret etmektedir.

DT makine öğrenmesi algoritması RF-HOG öznitelik çıkarma yöntemiyle %92,00 doğruluk oranı elde etmiş ve PCA-HOG ile bu oran %96,50'ye yükselmiştir. RF-HOG yöntemiyle %88 duyarlılık ve %100 hassasiyet elde edilmiştir. PCA-2DWT yöntemiyle %91,98 G-Ortalama değeri elde edilmiştir, bu da Karar Ağaçlarının farklı öznitelik çıkarma yöntemlerine karşı dengeli bir performans sergilediğini göstermektedir.

CFNN tüm öznitelik çıkarma yöntemleriyle %94,50 ve üzeri doğruluk oranları sağlamıştır. RF-HOG yöntemiyle %99,00 doğruluk ve %100,00 hassasiyet elde edilmiştir. Ayrıca, RF-HOG yöntemiyle %96 duyarlılık ve %97,96 F-Skor ve G-Ortalama değerini de %97,98 olarak ölçülmüştür.

Sonuç olarak CFNN, tüm metriklerde en yüksek performansı sergileyerek doğruluk, hassasiyet, duyarlılık, F-skor ve G-ortalama açısından diğer algoritmaların önüne geçmiştir. K-NN algoritması, RF-HOG yöntemiyle yüksek doğruluk ve dengeli performans gösterse de PCA-HOG yöntemiyle belirgin bir performans düşüşü yaşamıştır. NB modeli, farklı öznitelik çıkarma yöntemleriyle genellikle iyi performans sergilemiş, ancak PCA-HOG yöntemiyle duyarlılık ve hassasiyet oranlarında düşüş gözlemlenmiştir. DT, öznitelik çıkarma yöntemlerine karşı dengeli bir performans sunmuş, ancak RF-HOG yöntemiyle duyarlılık ve G-ortalama değerlerinde daha düşük sonuçlar elde etmiştir.

Genel olarak, CFNN en yüksek performansı sergilerken, K-NN ve NB belirli yöntemlerle iyi sonuçlar elde etmiş, ancak bazı yöntemlerle performans kaybı yaşamıştır. DT, farklı öz nitelik çıkarma yöntemlerinde tutarlı bir performans sergilemiştir.



6. SONUÇ

CFNN algoritması, RF-HOG öznitelik çıkarma yöntemi ile en yüksek performansı göstermiştir. Bu bulgular, CFNN'nin karmaşık öznitelik ilişkilerini başarıyla modelleyebildiğini ve diğer algoritmalara kıyasla üstün performans sergilediğini göstermektedir.

K-NN algoritması, RF-HOG öznitelik çıkarma metodu ile %97 doğruluk oranına ulaşarak belirli öznitelik setleriyle uyumlu olduğunu göstermiştir. Ancak, PCA-HOG öznitelik çıkarma metodu ile kullanıldığında %55,50 gibi düşük bir doğruluk elde edilmiştir. Bu sonuçlar, K-NN algoritmasının doğru öznitelik seçiminin önemini vurgulamaktadır.

NB ve DT algoritmaları, çoğu öznitelik çıkarma yöntemi ile %90'ın üzerinde stabil bir performans göstermiştir.

Öznitelik çıkarma yöntemlerinin seçimi, sınıflandırma algoritmalarının performansını önemli ölçüde etkilemektedir. RF-HOG yöntemi, genel olarak en iyi performansı göstermiştir. Bu yöntemin kullanılması, modelin doğruluğunu ve hassasiyetini artırmıştır. Bu çalışmanın bulguları ve yapılan analizler, gelecek araştırmalar için bazı öneriler sunmaktadır.

İlk olarak, derin öğrenme tekniklerinin ve otomatik öznitelik çıkarma yöntemlerinin bu tür sınıflandırma problemlerinde nasıl performans gösterdiğini incelemek faydalı olacaktır. İkinci olarak, farklı veri türleri ve çeşitli uygulama senaryoları üzerinde sınıflandırma algoritmalarının ve öznitelik çıkarma yöntemlerinin performansını inceleyen çalışmalara ihtiyaç vardır. Üçüncü olarak, multimodal veri analizine odaklanmak gelecekteki araştırmalar için önemli bir adım olabilir. Görüntü ve ses gibi multimodal veri kümeleri, tek modality verilere göre daha zengin bilgi içerir ve sınıflandırma algoritmalarının performansını artırabilir.

Bu öneriler, sınıflandırma algoritmaları ve öznitelik çıkarma yöntemleri üzerine gelecekte yapılacak çalışmalar için çeşitli yollar ve potansiyel keşifler sunmaktadır. Her bir öneri, alanın gelişimine katkıda bulunacak ve pratik uygulamalar için yeni fırsatlar yaratacaktır.

7. KAYNAKLAR

- [1] X. Du, L. Song, Y. Lv, & S. Qiu, “A lightweight military target detection algorithm based on improved yolov5,” *Electronics*, c. 11, sayı 20, ss. 3263, 2022.
- [2] R. E. Karlsen, D. J. Gorsich, & G. R. Gerhart, “Target classification via support vector machines,” *Optical Engineering*, c. 39, sayı 3, ss. 704–711, 2000.
- [3] P. J. Rösch, F. Deuser, K. Habel, & N. Oswald, “Zero-shot multimodal deep learning models for military vehicle detection – an analysis,” *NATO STO REVIEW*, c. FALL 2023, 2023
- [4] S. Vorapatratorn, “Enhancing monitoring of suspicious activities with ai-based and big data fusion,” *PeerJ Computer Science*, c. 10, 2024.
- [5] D. Agrawal, G. Singh, H. Singh, K. Singh, P. Jha, & Y. S. Patel, “Fed-avis: A lightweight federated learning assisted anti-vehicle infiltration system,” in *Proceedings of the 25th International Conference on Distributed Computing and Networking*, 2024, ss. 310–315.
- [6] A. Kasianchuk & H. Lastivka, “Uav integration with neural network in landmine and minefield detection tasks,” *Security of Infocommunication Systems and Internet of Things*, c. 1, sayı 2, ss. 02 008–02 008, 2023.
- [7] U. Seidaliyeva, L. Ilipbayeva, K. Taissariyeva, N. Smailov, & E. T. Matson, “Advances and challenges in drone detection and classification techniques: A state-of-the-art review,” *Sensors*, c. 24, sayı 1, ss. 125, 2023.
- [8] Y. YAKHELE & M. BOULOUH, “Augmented doppler filter bank for enhancing targets detection based on machine learning.” *Przegląd Elektrotechniczny*, c. 2023, sayı 12, 2023.
- [9] H. Jond & R. Sinha, “Improved target detection in radar systems using machine learning-enhanced doppler filter banks.” *IEEE Transactions on Aerospace and Electronic Systems*, c. 54, sayı 3, ss. 2458–2468, 2018.
- [10] W. Li & X. Wang, “Military target detection in satellite images using k-nearest neighbor algorithm.” *Journal of Information Computational Science*, c. 12, sayı 4, ss. 1501–1509, 2015.
- [11] S. Ahmed & A. Rehman, “Military vehicle recognition using decision tree classifiers.” *Journal of Intelligent Robotic Systems*, c. 87, sayı 2, ss. 401–414, 2017.
- [12] Y. Chen & Z. Zhang, “Explosive detection using naive bayes classifier and image processing techniques.” *Pattern Recognition and Image Analysis*, c. 22, sayı 4, ss.

563–572, 2012.

- [13] K. D. Ahmadi, A. J. Rashidi, & A. M. Moghri, “Design and simulation of autonomous military vehicle control system based on machine vision and ensemble movement approach,” *The Journal of Supercomputing*, c. 78, sayı 15, ss. 17 309–17 347, 2022.
- [14] L. Purdy, “Motorised, mechanised and armoured infantry: A short history of the development of armoured vehicle-borne infantry and its relevance to the Australian army today,” *Australian Army Journal*, c. 18, sayı 1, ss. 114–133, 2022.
- [15] FNSS. (2023, 6 Ekim). M113 FOV capability sustainment program [Online]. Erişim: <https://www.fnss.com.tr/en/products/m113-fov-capability-sustainment-program>
- [16] M. Jerchel, “Leopard 1 Main Battle Tank 1965–95.” *Bloomsbury Publishing*, 2012, c. 16.
- [17] D. King, “The survival of tanks in battle,” *The RUSI Journal*, c. 123, sayı 1, ss. 26–31, 1978.
- [18] KNDS. (2023, 6 Ekim). Leopard 1 A5 [Online]. Erişim: <https://www.knds.de/en/systems-products/tracked-vehicles/main-battle-tank/leopard-1-a5/>
- [19] M. Scheibert, “Tankograd: Leopard 1 Main Battle Tank - Volume 1: Development and German Army Service”. *Tankograd Publishing*, 2006.
- [20] Krauss-Maffei Wegmann. (2023, 6 Ekim). Krauss-maffei wegmann resmi web sitesi [Online]. Erişim: <https://www.kmweg.com/>
- [21] Alman Federal Ordusu. (2023, 6 Ekim). Alman federal ordusu resmi web sitesi [Online]. Erişim: <https://www.bundeswehr.de/>
- [22] T. Filippini, M. Aittokallio, & E. Marzouk, “The threats of brand rejuvenation: The land rover defender case,” *LBMG Strategic Brand Management-Masters Paper Series*, 2019.
- [23] E. G. Abrutsky Peralta, “Homologación de un land rover defender,” *B.S. thesis, Universitat Politècnica de Catalunya*, 2019.
- [24] Mechanics Mag. (2023, 6 Ekim). War hero [Online]. Erişim: <https://www.mechanics-mag.com.au/war-hero/>
- [25] BMC. (2023, 6 Ekim). Taktik tekerlekli araçlar [Online]. Erişim:

- [26] BMC. (2023, 6 Ekim). Defense industry [Online]. Eriřim: <https://www.bmc.com.tr/en/defense-industry/>
- [27] R. Tamilselvi, B. Sivasakthi, & R. Kavitha, “An efficient preprocessing and postprocessing techniques in data mining,” *Int. J. Res. Comput. Appl. Robot*, c. 3, sayı 4, ss. 80–85, 2015.
- [28] S. Kaur, “Noise types and various removal techniques,” *International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE)*, c. 4, sayı 2, ss. 226–230, 2015
- [29] V. Dhir & S. Kumar, “Review of various image contrast enhancement techniques,” *International Journal of Advanced Research in Computer Science and Software Engineering*, c. 4, sayı 8, ss. 110–113, 2014.
- [30] S. Gao & V. Gruev, “Bilinear and bicubic interpolation methods for division of focal plane polarimeters,” *Optics express*, c. 19, sayı 27, ss. 26 161–26 173, 2011.
- [31] B. K. Triwijoyo & A. Adil, “Analysis of medical image resizing using bicubic interpolation algorithm,” *Jurnal Ilmu Komputer*, c. 14, sayı 2, ss. 20–29, 2021.
- [32] S. M. R. Hashemi, “Review of algorithms changing image size,” *Cumhuriyet Üniversitesi Fen Edebiyat Fakültesi Fen Bilimleri Dergisi*, c. 36, sayı 3, ss. 2556–2564, 2015.
- [33] [D. Ramyachitra & P. Manikandan, “Imbalanced dataset classification and solutions: a review,” *International Journal of Computing and Business Research (IJCBR)*, c. 5, sayı 4, ss. 1–29, 2014.
- [34] F. Ersöz & Y. Çınar, “Veri madencilięi ve makine öğrenimi yaklaşımlarının karşılaştırılması: Tekstil sektöründe bir uygulama,” *Avrupa Bilim ve Teknoloji Dergisi*, sayı 29, ss. 397–414, 2021.
- [35] N. Dalal & B. Triggs, “Histograms of oriented gradients for human detection,” in *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR’05)*, c. 1. Ieee, 2005, ss. 886–893.
- [36] X. Cao, C. Wu, P. Yan, & X. Li, “Linear svm classification using boosting hog features for vehicle detection in low-altitude airborne videos,” in *2011 18th IEEE international conference on image processing*. IEEE, 2011, ss. 2421–2424.
- [37] K. W. Ong & S. L. Loh, “Vehicle classification using neural networks and image processing,” *International Journal of Electrical Engineering and Applied Sciences*

(IJEAS), c. 5, sayı 2, 2022.

- [38] N. Jahan, S. Islam, & M. F. A. Foysal, “Real-time vehicle classification using cnn,” in *2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. IEEE, 2020, ss. 1–6.
- [39] E. A. Roxas, R. R. P. Vicerra, L. A. G. Lim, J. C. D. Cruz, R. Naguib, E. P. Dadios, & A. A. Bandala, “Multi-scale vehicle classification using different machine learning models,” in *2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)*. IEEE, 2018, ss. 1–5.
- [40] N. Alpaslan, M. F. Talu, M. Gül, & B. Yiğitcan, “Hog tabanlı ysa kullanılarak yağlı karaciğer tedavisindeki ilaç etkinliklerinin hesaplanması,” *Sakarya University Journal of Science*, c. 16, sayı 2, ss. 106–112, 2012.
- [41] H. Wang, D. Zhang, & Z. Miao, “Face recognition with single sample per person using hog-ldb and svdl,” *Signal, Image and Video Processing*, c. 13, ss. 985–992, 2019.
- [42] . Albayrak & G. Bilgin, “Detection of mitotic cells in histopathological images using textural features,” in *2013 21st Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2013, ss. 1–4.
- [43] S. Ciprini, G. Tosti, F. Marcucci, C. Cecchi, G. Discepoli, E. Bonamente, S. Germani, D. Impiombato, P. Lubrano, M. Pepe et al., “1d, 2d, 3d wavelet methods for gamma-ray source analysis,” in *AIP Conference Proceedings*, c. 921, 2007, ss. 546.
- [44] R. Lang & A. Spray, “The 2d wavelet transform on a massively parallel machine,” in *Proceedings of the Australasian Conference on Parallel and Real-Time Systems*. Citeseer, 1995, ss. 325–332
- [45] I. Kononenko, E. Šimec, & M. Robnik-Šikonja, “Overcoming the myopia of inductive learning algorithms with relieff,” *Applied Intelligence*, c. 7, ss. 39–55, 1997.
- [46] M. Robnik-Šikonja & I. Kononenko, “Theoretical and empirical analysis of relieff and rrelieff,” *Machine learning*, c. 53, ss. 23–69, 2003.
- [47] R. J. Urbanowicz & J. H. Moore, “Learning classifier systems: a complete introduction, review, and roadmap,” *Journal of Artificial Evolution and Applications*, c. 2009, sayı 1, ss. 736398, 2009.
- [48] I. T. Jolliffe, “Principal component analysis for special types of data. ” *Springer*,

2002.

- [49] I. T. Jolliffe & J. Cadima, “Principal component analysis: a review and recent developments,” *Philosophical transactions of the royal society A: Mathematical, Physical and Engineering Sciences*, c. 374, sayı 2065, ss. 20150202, 2016.
- [50] A. Kataria & M. Singh, “A review of data classification using k-nearest neighbour algorithm,” *International Journal of Emerging Technology and Advanced Engineering*, c. 3, sayı 6, ss. 354–360, 2013.
- [51] S. D. Jadhav & H. Channe, “Comparative study of k-nn, naive bayes and decision tree classification techniques,” *International Journal of Science and Research (IJSR)*, c. 5, sayı 1, ss. 1842–1845, 2016.
- [52] P. Domingos & M. Pazzani, “On the optimality of the simple bayesian classifier under zero-one loss,” *Machine learning*, c. 29, ss. 103–130, 1997.
- [53] D. J. Hand & K. Yu, “Idiot’s bayes—not so stupid after all?” *International statistical review*, c. 69, sayı 3, ss. 385–398, 2001.
- [54] T. Hastie, R. Tibshirani, J. H. Friedman, & J. H. Friedman, “The elements of statistical learning: data mining, inference, and prediction.” *Springer*, 2009, c. 2.
- [55] Scikit-learn. (2023, 6 Ekim). Documentation: Decision trees [Online]. Erişim: <https://scikit-learn.org/stable/modules/tree.html>
- [56] S. Fahlman & C. Lebiere, “The cascade-correlation learning architecture,” *Advances in neural information processing systems*, c. 2, 1989.
- [57] K.-H. Tan, F.-J. Lin, C.-Y. Tsai, & Y.-R. Chang, “A distribution static compensator using a cfnn-amf controller for power quality improvement and dc-link voltage regulation,” *Energies*, c. 11, sayı 8, ss. 1996, 2018.
- [58] K. A. Al-Mashouq & A. Al-Mashouq, “Cascade forward neural networks for classification,” *International Journal of Computer Applications*, c. 180, sayı 28, ss. 1–6, 2018.
- [59] J. Schmidhuber, “Deep learning in neural networks: An overview,” *Neural Networks*, c. 61, ss. 85–117, 2015.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Anıl AKBALIK

Yabancı Dili : İngilizce

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Y. Lisans	Elektrik Elektronik Müh.	Düzce Üniversitesi	2024
Lisans	Elektrik Elektronik Müh.	Karabük Üniversitesi	2016
Lisans	Elektronik Öğretmenliği.	Kocaeli Üniversitesi	2012
Lise	Elektrik Elektronik	Mimar İzzet Baysal Anadolu Teknik Lisesi	2007

TEZ YAYINI

Akbalık, A., & Katırcıoğlu, F. “Detection and Classification of Land Military Vehicles with Machine Learning Methods,” *UBAK International Scientific Research and Innovation Congress 5-6 June 2024*, pp. 473-484.