

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**HAVADAN ALINAN TERMAL KAMERA GÖRÜNTÜLERİNDE
CANLI TASNİFİNİN YAPILMASINDA DERİN ÖĞRENME
TABANLI TEKNİKLERİN UYGULANMASI**

Halil USLU

Yüksek Lisans Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

HAZİRAN 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**HAVADAN ALINAN TERMAL KAMERA GÖRÜNTÜLERİNDE CANLI
TASNİFİNİN YAPILMASINDA DERİN ÖĞRENME TABANLI
TEKNİKLERİN UYGULANMASI**

Tez Yazarı
Halil USLU

Danışman
Prof. Dr. Engin AVCI

HAZİRAN 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Havadan Alınan Termal Kamera Görüntülerinde Canlı Tasnifinin Yapılmasında Derin Öğrenme Tabanlı Tekniklerin Uygulanması
Yazarı:	Halil USLU
İlk Teslim Tarihi:	02.06.2022
Savunma Tarihi:	27.06.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Engin AVCI Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Dr. Öğr. Üyesi. Ali ARI İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Fatih ÖZKAYNAK Fırat Üniversitesi Teknoloji Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Havadan Alınan Termal Kamera Görüntülerinde Canlı Tasnifinin Yapılmasında Derin Öğrenme Tabanlı Tekniklerin Uygulanması” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

27.06.2022

Halil USLU



ÖNSÖZ

Bu tezin hazırlanmasında değerli görüş ve önerileri ile beni yönlendiren, yardımlarını ve hoşgörüsünü esirgemeyen tez danışmanım Prof. Dr. Engin Avcı ve eşi Doç. Dr. Derya Avcı'ya,

Hayatım boyunca yanımda olan, bugünlere ulaşmamı sağlayan ve hiçbir fedakarlıktan çekinmeyen oğulları olmaktan gurur duyduğum anne ve babama,

Üzerimde emekleri geçen tüm eğitim ve bilim insanlarına,

TEKF.20.16, proje kapsamında destek verdikleri için Fırat Üniversitesi Bilimsel Araştırma Projeleri birimine,

Sevgisi ile en gerçekçi dostum olan kıymetli kardeşime teşekkürlerimi sunarım

Halil USLU
ELAZIĞ, 2022

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	x
1. Giriş	1
1.1. Literatür Çalışması	2
2. TERMAL KAMERALAR	7
2.1. Termal Kameranın Tarihçesi	7
2.2. Termal Kamera Yapıları	7
2.2.1. Optik Mekanik Birimler	7
2.2.2. Dedektör ve Soğutucu Birimi	9
2.2.3. Elektronik Sinyal İşleme Birimi	9
2.2.4. Termal Kameralarda Çözünürlük	10
2.2.5. Termal Kameralarda Sıcaklık	10
2.3. Termal Kameraların Kullanım Alanları	11
2.3.1. Elektrikle İlgili Uygulamalar	11
2.3.2. Elektromekanik ve Mekanik Uygulamalar	12
2.3.3. Süreç Uygulamaları	13
2.3.4. Bina Tanılaması	14
2.3.5. Sağlık Uygulamaları	14
2.3.6. Savunma Uygulamaları	16
2.3.7. Endüstriyel Fırın Uygulamaları	17
2.4. Termal Kamerada Görüntü Analizi	17
2.4.1. Görüntünün Elde Edilmesi	18
2.4.2. Görüntü İyileştirme	18
2.4.3. Görüntü Analizi	18
3. MAKİNE ÖĞRENMESİ	20
3.1. Makine Öğrenmesi Tarihçesi	20
3.2. Makine Öğrenmesi Teknikleri	21
3.2.1. Denetimli Öğrenme	23
3.2.2. Denetimsiz Öğrenme	24
3.2.3. Yarı Denetimli Öğrenme	24
3.2.4. Takviyeli (Pekiştirmeli) Öğrenme	25
3.2.5. Örnek Tabanlı Öğrenme	25
3.2.6. Model Tabanlı Öğrenme	25
3.3. Model Performans Değerlendirme Yöntemleri	25
3.3.1. Hold-out	25
3.3.2. Cross validation (Karşılıklı Doğrulama)	26
3.4. Model Performans Değerlendirme Ölçütleri	26
3.4.1. Regresyon Model Değerlendirme Ölçütleri	26

3.4.2. Sınıflandırma Model Değerlendirme Ölçütleri.....	26
4. DERİN ÖĞRENME	28
4.1. Derin Öğrenme Tarihçesi	29
4.2. Evrişimsel Sinir Ağı.....	30
4.2.1. Giriş Katmanı.....	31
4.2.2. Evrişim Katmanı	31
4.2.3. Düzleştirilmiş Doğrusal Birim Katmanı.....	31
4.2.4. Havuzlama Katmanı.....	31
4.2.5. Tam Bağlantılı Katman	32
4.2.6. Sınıflandırma Katmanı	32
5. MATERYAL VE METOT	33
5.1. Kullanılan Derin Öğrenme Mimarileri.....	33
5.1.1. Alexnet Mimarisi	33
5.1.2. Resnet Mimarisi	33
5.1.3. Inceptionv3 mimarisi.....	35
5.2. Kullanılan Sınıflandırıcılar.....	35
5.2.1. Destek Vektör Makineleri (SVM-Support Vector Machine)	35
5.2.2. SVM Türleri.....	36
5.2.3. SVM Algoritmasında Hiper Düzlem ve Destek Vektörleri	37
5.2.4. SVM Algoritması Çalışma Prensibi.....	37
5.2.5. Doğrusal SVM	37
5.2.6. Doğrusal Olmayan SVM	38
5.2.7. SVM Algoritması Avantajları.....	39
5.2.8. SVM Algoritması Avantajları.....	39
5.2.9. K-En Yakın Komşuluk (K-Nearest Neighbor/KNN).....	39
5.2.10. K-NN Algoritmasının Çalışma Prensibi.....	40
5.2.11. K-NN Algoritmasının Avantajları	42
5.2.12. K-NN Algoritmasının Dezavantajları	42
5.3. Veri Seti ve Özellikleri.....	42
5.4. Kullanılan Model Performans Değerlendirme Yöntemi ve Ölçütleri.....	44
6. SONUÇLAR.....	48
6.1. Alexnet Mimarisinin Eğitimi ve Testi.....	48
6.2. Resnet101 Mimarisinin Eğitimi ve Testi.....	49
6.3. Inceptionv3 mimarisinin eğitimi ve testi.....	50
ÖNERİLER	52
KAYNAKLAR	53
ÖZGEÇMİŞ	

ÖZET

Havadan Alınan Termal Kamera Görüntülerinde Canlı Tasnifinin Yapılmasında Derin Öğrenme Tabanlı Tekniklerin Uygulanması

Halil USLU

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Haziran 2022, Sayfa: x + 55

Yapay zekâ günümüzde birçok uygulama ve araştırma alanında kullanılmaktadır. İnsan gücü gereken işleri otomatikleştirmek, iletişim kurmak, görüntü ve konuşmaları anlamak, kısaca insanların yaşamını kolaylaştıracak her işte yapay zekadan destek alınmaktadır. Bu nedenle sistemleri daha zeki hale getirebilecek yapay zekâ teknikleri de hızla gelişmektedir. Yapay zekanın kullanıldığı sistemlerden biri de görüntüleme sistemleridir. Çeşitli kamera sistemlerinden alınmış veriler, yapay zekanın görüntü işleme teknikleri ile işlenebilir ve yorumlanabilir hale gelmiştir. Günümüzde birçok görüntü alma sistemi bulunmaktadır. Bunlara; enerji yüklü röntgen ışınlarının farklı yapılardan dönmesiyle görüntü alan röntgen cihazları, ses dalgaları aracılığıyla görüntü oluşturabilen ultrason cihazları, elektromanyetik kuvvet radyo frekansları ile görüntü elde eden MR cihazları, radar kullanarak yer altındaki değerli maden, su kaynağı, yeraltı boşlukları gibi verileri 2 veya 3 boyutlu görüntüleyebilen çeşitli dedektörler, kızılötesi ışınlar ile görüntüleme yapabilen termal görüntüleme sistemleri örnek olarak verilebilir. Termal görüntüleme sistemleri, cisimlerin sıcaklık farklılıklarının kızılötesi ışının değerleri kullanılarak renkselleştirildiği görüntüleme sistemidir. Görüntüleme yöntemi olarak elektromanyetik spektrumda yer alan IR (kızılötesi) enerjiyi esas almaktadır. Günümüzde başta savunma sanayi olmak üzere sağlık, ziraat, inşaat gibi birçok farklı alanda termal kameralar kullanılmaktadır. Gelişen teknoloji ile termal görüntüleme sistemleri ve yapay zekâ aracılığıyla çeşitli ortamlar hakkında bilgi toplanabilir ve işlenebilir hale gelmiştir. Bu çalışmada termal görüntüleme üzerinde yapay zekâ tekniklerinin nerede ve nasıl uygulandığına ilişkin araştırma yapılmıştır. Çalışmada termal kameralar yardımıyla yapılan termal 3B modelleme nesnesi binaların kullanımı, hareket ve hedef tespiti, alkollü birey tespiti, zirai ve ormancılık çalışma sahalarındaki yapısal sorunların tespiti gibi birçok farklı çalışmaya yer verilmiştir.

Bu tez çalışmasında termal kamera görüntülerindeki nesnelerin sınıflandırması otonom olarak yapılabilmesi için derin öğrenme tabanlı teknikler kullanılmıştır. Çalışma kapsamında 4 sınıftan oluşan 836 görüntü kullanılmıştır. Görüntülere temel derin öğrenme mimarilerine entegre edilen K en yakın komşuluk algoritması ve Destek vektör Makineleri algoritması ile sınıflandırılmıştır.

Anahtar Kelimeler: Termal Kamera, Kızılötesi Işın, Derin Öğrenme, Makine Öğrenme.

ABSTRACT

Application of Deep Learning-Based Techniques for Performing Live Sorting on Aerial Thermal Camera Images

Halil USLU

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Software Engineering

June 2022, Pages: x + 55

Artificial intelligence is currently used in many applications and research areas. Artificial intelligence is supported in everything that will automate the work that requires manpower, communicate, understand images and conversations, in short, make people's lives easier. For this reason, artificial intelligence techniques that can make systems more intelligent are also developing rapidly. One of the systems where artificial intelligence is used is imaging systems. The data taken from various camera systems have become processable and interpretable with the image processing techniques of artificial intelligence. There are many image retrieval systems available today. Them; installed energy X-rays for the different structures of the rotation of the image Area X-ray devices, ultrasound devices that can generate images through sound waves, radio frequency, electromagnetic force who obtained the image with MR devices, using radar precious minerals in the ground, water supply, underground spaces that can display various data, such as 2D or 3D detectors, capable of imaging with infrared rays, thermal imaging systems are examples.

Thermal imaging systems are imaging systems in which the temperature differences of objects are colorized using the values of the infrared ray. As an imaging method, it is based on IR (infrared) energy contained in the electromagnetic spectrum.

Nowadays, thermal imagers are used in many different fields such as health, agriculture, and construction, especially in the defense industry. With the developing technology, information about various environments can be collected and processed through thermal imaging systems and artificial intelligence. In this study, research has been conducted on where and how artificial intelligence techniques are applied on thermal imaging. In the study, many different studies such as the use of thermal 3D modeling object buildings made with the help of thermal cameras, motion and target detection, alcohol individual detection, determination of structural problems in agricultural and forestry work sites were included.

In this thesis, deep learning-based techniques were used to classify the objects in thermal camera images autonomously. Within the scope of the study, 836 images consisting of 4 classes were used. the images were classified using the K nearest neighbor algorithm and the Support vector Machines algorithm, which are integrated into basic deep learning architectures.

Keywords: Thermal Camera, Infrared Ray, Deep Learning, Machine Learning

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Bir termal kameranın optik birimi [15]	8
Şekil 2.2. Termal kamera dedektörleri [15].....	9
Şekil 2.3. Elektriksel Uygulamalar [20].....	12
Şekil 2.4. Elektriksel Uygulamalar-2 [20].....	12
Şekil 2.5. Bir fabrikada ısı yayan bir makinenin gerçek ve termal görüntüsü [20]	13
Şekil 2.6. Çok fazla ısınmış motor bloğu [20].....	13
Şekil 2.7. Bina uygulamaları [15]	14
Şekil 2.8. Burundaki kırık ve beldeki incilme [20].....	15
Şekil 2.9. Kalabalık ortamlarda hastalıklı kişilerin tespiti [20]	15
Şekil 2.10. Boru hattına yaklaşan insanlar [20].....	16
Şekil 2.11. Savunma uygulamalarında termal kamera görüntüleri [20]	16
Şekil 2.12. Endüstriyel fırın bacalarındaki gaz birikmesi [16].....	17
Şekil 2.13. Endüstriyel bir fırının tamamen kapanması [16].....	17
Şekil 2.14. Eşikleme işlemine tabi tutulan termal sokak görüntüsü [16]	19
Şekil 3.1. Makine öğrenmesi uygulamaları	21
Şekil 3.2. Makine öğrenmesi öğrenme süreçleri.....	22
Şekil 3.3. Makine öğrenmesi öğrenme yöntemleri	23
Şekil 4.1. Derin öğrenme süreçleri.....	28
Şekil 4.2. Derin öğrenme tarihçesi.....	30
Şekil 4.3. Derin öğrenme katmanları	30
Şekil 5.1. Alexnet Modeli [37]	33
Şekil 5.2. Resnet Modeli [39]	34
Şekil 5.3. InceptionV3 ve üç temel parçasının şeması [39]	35
Şekil 5.4. SVM'de Bir Karar Sınırının Gösterimi [38].....	36
Şekil 5.5. SVM Uygulanma Prensibi [10].....	38
Şekil 5.6. 3 Boyutlu Düzenleme [37].....	39
Şekil 5.7. Öklid Mesafesinin Hesaplanması [29]	41
Şekil 5.8. Komşulara göre yeni veri noktasının sınıflandırılması [29]	42
Şekil 5.9. Veri setindeki termal kamera görüntü örnekleri	43
Şekil 5.10. Kullanılan mimarilerin akış diyagramı	44

TABLÖLER LİSTESİ

	Sayfa
Tablo 3.1. Sınıflandırma model değerlendirme ölçütleri	27
Tablo 6.1. Alexnet + KNN yönteminin karmaşıklık matrisi	48
Tablo 6.2. Alexnet + SVM yönteminin karmaşıklık matrisi	48
Tablo 6.3. Resnet101 + KNN yönteminin karmaşıklık matrisi	49
Tablo 6.4. Resnet101 + SVM yönteminin karmaşıklık matrisi	50
Tablo 6.5. Inceptionv3 + KNN yönteminin karmaşıklık matrisi	50
Tablo 6.6. Inceptionv3 + SVM yönteminin karmaşıklık matrisi	51
Tablo 6.7. Sınıflandırıcılara göre sınıflandırma performansları	51

1. GİRİŞ

Günümüzde veri analiz yöntemlerinin gelişmesi ve yaygınlaşmasıyla yapay sinir ağları, makine öğrenmesi ve derin öğrenme gibi yapay zekâ tekniklerinin kullanım alanları hızla artmaktadır. Savunma sanayi, enerji santralleri, sağlık uygulamaları, mekanik tesisat uygulamaları gibi alanlarda bu yapay zekâ uygulamaları insanların yerini almıştır. Böylece sektörlerin üzerindeki süreç yükü ve sürecin tamamlanıp uygulama aşamasındaki süreler azalmıştır. Derin öğrenme uygulamaları, dijital sistemleri yapılandırarak, verileri öğrenmesini ve daha hızlı karar almasını sağlamak için yapay sinir ağlarından oluşan makine öğrenmesi türlerinin bir alt kırılımıdır. Derin öğrenme uygulamalarının temelleri geçmişte atılmasına rağmen uygulamaların kullanımı özellikle pandemi döneminden sonra yaygınlaşmıştır. Sağlık alanında temasa gerek kalmadan hastaların uzaktan ateş ölçümleri, vücutlarındaki kırık eklemlerin tespiti, çeşitli tıbbi analizlerde, kanser ve benzeri hastalıkların tespitleri gibi uygulamalarda kullanılmaktadır. Enerji alanında rüzgâr türbinlerindeki kanatlarda oluşan hasarları tespiti, güneş panelleri üzerindeki hasarların tespiti ve enerji üretim kaynaklarının optimizasyonu gibi alanlarda derin öğrenme uygulamalarının kullanımı mevcuttur. Savunma sanayinde ve havacılık alanında görüntü işleme teknolojileri ile entegre kullanılarak ateşleme sistemlerinin geliştirilmesi, otonom kullanım, karakol ve sınırlarda güvenliğin sağlanması, boru hatları ve pompalama istasyonların güvenliğinin sağlanması gibi uygulamalarda da etkin olarak kullanılmaktadır. Derin öğrenmenin kullanıldığı uygulamalar arasında binalardaki hasar tespiti ve mekanik tesisat sızıntılarının tespiti vb. uygulamalar da yer almaktadır.

Özellikle savunma sanayi kapsamındaki hava araçlarında görüntüleme sistemi olarak kullanılmakta olan termal kameraların çeşitli yapay zekâ uygulamalarıyla birleşerek çok daha sistematik hale gelmesi için yapılan çalışmalar literatürde mevcuttur. Böylece insan gözüyle fark edilemeyecek detayların elde edilmesini hatta tanımlanmasını sağlanmaya çalışılmaktadır. Termal kamera görüntüler üzerinde uygulanan bu yapay zekâ çalışmaları ile görüntülerin kullanılacağı alanlara ışık tutulup, havacılık sektörü için yeni uygulamalar yapılması böylece savunma sanayisinde yapay zekâ ve derin öğrenme uygulamaları artması hedeflenmiştir. Bu çalışmada da benzer hedefler temel alınarak termal kameralardan elde edilen görüntülerdeki nesnelerin sınıflandırılması için derin öğrenme mimarileri ile makine öğrenmesi yöntemlerinin hibrit modelleri önerilmiştir. Çalışmada Alexnet, Resnet ve Inceptionv3 derin öğrenme mimarileri ile K en yakın komşuluk algoritması (KNN) ve destek vektör makineleri (SVM) gibi makine öğrenmesi tekniklerinden hibrit modeller kullanılmıştır. Çalışma kapsamında 4 Sınıftan oluşan 836 termal kamera görüntüsü kullanılmıştır.

1.1. Literatür Çalışması

Termal Görüntü İşleme Üzerine Genel Bir Bakış isimli makalede Kalsiyum karbür arsenik ve fosfor izlerini barındırdığı için muz meyvesinin kalsiyum karbür ile olgunlaştırılmış mı yoksa doğal olarak olgunlaşmış mı olduğunun doğru tanımlanması ve sınıflandırılması üzerine bir çalışma yapılmıştır. İnsan vücudu için önemi incelenmiştir. Bu makale, bu tür bir problemi tespit etmek için bir Termal Görüntüleme Teknolojisi yöntemi sunmaktadır, çünkü meyvelerin kalitesini tespit etmek için farklı teknikler kullanılmaktadır ve bu makalede meyvelerin toksik kimyasallarla kirlenmesine odaklanılmıştır. Görüntü işleme için farklı adımlar üzerine durulmuş ve görüntü için sınıflandırma amacıyla Sinir Ağı kullanılmıştır [1].

Güç Ekipmanlarının Kızılötesi Termal Görüntüleme Tanı Teknolojisinde Yöntemler isimli makalede Yaygın olarak kullanılan kızılötesi termografi, önemli bir elektrikli ekipman izleme ve arıza teşhis teknolojisi incelenmiştir. Kızılötesi termal görüntü işleme ve yapay zeka tanı hataları hakkında iki temel adımı üzerine bilgi verilmiştir. Elektrik donanımı termik arıza teşhis doğruluğunu geliştirmek amacıyla, denoising, görüntü işleme, akıllı teşhisi için yapay sinir ağları BP ve FUL ağ modeli olarak segment ve özellik çıkarma algoritmaları belirli deneysel koşullar, Çeşitli teknolojilerin avantaj ve dezavantajları ile ele alınmış ve geliştirilmiş yöntemler verilmiştir. Akıllı teşhis, elektrik alanında sürekli ilerleyen bir kenar ve odak noktasıdır, arıza tiplerini tam olarak teşhis etmek çok karmaşık ve zordur, ancak görüntü işleme teknolojisinin ve yapay sinir ağı modelinin sürekli iyileştirilip geliştirilmesi, teşhis verimliliğini ve doğruluğunu önemli ölçüde arttıracak saptanmıştır. Makalede, kızılötesi termal görüntü işleme teknolojisini ve sinir ağı modelini adım adım anlatılıp, avantaj ve dezavantajları analiz edilerek, akıllı sistemin daha da geliştirilmesi için fikir ve yöntemler sunulmuştur [2].

Makine Durum İzleme İçin Termal Görüntü İşleme Tekniklerinin İncelenmesi isimli makalede Kızılötesi termografi veya termal görüntüleme, elektronik komponent, bina etütleri, mekanik komponentler ve ekipmanlar gibi birçok fiziksel varlık türü için kullanılan çok kullanışlı, çok yönlü ve temassız bir yöntemdir. Kızılötesi termografi ilk olarak askeri uygulama için kullanıldı, ancak günümüzde bu teknoloji arıza tespiti, tanımlama ve arıza teşhisi gibi makine durum izlemesinde kullanılıyor. Bu makale, nesne sıcaklığına bağlı olarak arıza tespiti ve teşhisi için farklı termal görüntüleme teknikleri üzerine bir anket sunmaktadır [3].

Kızılötesi Termal Görüntüleme ve Derin Öğrenme Modeli Kullanarak Meme Kanseri Tespiti isimli makalede sağlıklı bir meme ile kanserli bir meme arasındaki temel bir termal karşılaştırmanın, prekanseröz dokularda ve gelişmekte olan meme kanserini çevreleyen alanlarda her zaman termal aktivitede bir artış gösterdiğini varsayan kızılötesi dijital görüntüleme araştırılmıştır. Yapılan araştırmada, kızılötesi görüntü işleme yoluyla gerçekleştirilen Bilgisayar Destekli bir Teşhisin (CAD), iyi bilinen hemisferik model gibi bir model olmadan elde edilemeyeceğini fark edilmiştir. Bu çalışma ile güçlü bilgisayar görme teknikleri ve derin öğrenme modelleri kullanarak literatüre

çeşitli meme kanseri tespit tekniklerinin karşılaştırmalı bir analizi konulmuştur. Gelecekteki yapacakları bir çalışmada 0.5'lik termal duyarlılık kamerası kullanıp kesin tanı üretebilecek bir model ortaya koyacaklarını belirtmişlerdir [4].

Gömülü Cisimlerin ve Mayınların Tespiti İçin Derin Öğrenmeye Dayalı Termal Görüntü İşleme Yaklaşımı isimli makalede Termal görüntüleme tabanlı mayın tespit tekniği, savaş alanlarında gömülü metalik ve metalik olmayan kara mayınlarının tespit edilmesinin uygunluğu nedeniyle yaygın olarak kullanılmaktadır. Termal görüntüler kullanılarak doğru maden tespiti, toprak ile maden arasındaki termal kontrasta bağlıdır ve gömülme derinliği, toprak özellikleri ve özellikleri, topraktaki su içeriği, maden özellikleri ve görüntü elde edilme günü gibi çeşitli faktörlerden etkilenir. Toprağın zamansal sıcaklık değişimleri ile, geleneksel olarak takip edilen ikili eşikleme yaklaşımını gri ölçekte kullanarak gömülü nesne ile termal görüntüdeki arka plan arasında ayırım yapmak ve ayırt etmek zordur. Bu makale, termal görüntülerdeki gömülü nesneleri tanımlamak için derin öğrenme bölgesi konvolüsyonuna dayalı sinir ağı yaklaşımını sunmaktadır. Termal görüntüdeki gömülü nesneyi tanımlamak için bağlı bir kutu kullanılarak bir bölge ilgi alanı seçimi izlenir. Deneysel sonuçlardan, çevreleyen toprağın ısı taşıma kapasitesindeki değişime bağlı olarak gömülü nesnelerin termal görüntülerinde sıcaklık değişimi olduğu bulunmuştur. Önerilen sinir ağı yöntemi, termal görüntülerde gömülü nesnelerin hedef konumlarını tahmin etmede %90 doğruluk göstermiştir ve termal görüntü işleme yaklaşımı kullanılarak kara mayını tespiti için genişletilebilir [5].

Derin Termal Görüntüleme: Uzamsal Derin Öğrenme yoluyla Vahşi Doğada Yakın Materyal Türü Tanıma Yüzey Sıcaklığı Modelleri isimli makalede İnsanların ve yakın çevrelerinin her yerde bulunan teknolojilerinin anlaşılmasını geliştirmek için malzemelerin yakın mesafeden otomatik olarak tanınmasına yönelik yeni bir yaklaşım olan Derin Termal Görüntülemeyi tanıtmıştır. Yaklaşımımız, termal dokuları yakalamak için bir akıllı telefona entegre edilmiş düşük maliyetli bir mobil termal kamera kullanmaktadır. Derin bir sinir ağı bu dokuları malzeme türlerine ayırır. Bu yaklaşım, ortam ışığı kaynaklarına veya malzemelerle doğrudan temasa gerek kalmadan etkili bir şekilde çalışır. Ayrıca, bir derin öğrenme ağının kullanılması, farklı materyaller için bir dizi özellik oluşturma ihtiyacını ortadan kaldırır. Sistemin performansını hem iç hem de dış ortamlarda 32 malzeme türünü tanıyacak şekilde eğiterek değerlendirilmiştir. Yaklaşımımız, 15 iç mekân malzemesinin 14.860 görüntüsünde %98'in üzerinde ve 17 dış mekân malzemesinin 26.584 görüntüsünde %89'un üzerinde tanıma doğruluğu üretti. HCI uygulamalarında gerçek zamanlı kullanım potansiyellerini ve gelecekteki yönleri tartışarak sonucuna ulaşılmıştır [6].

Kızılötesi Termal Görüntü Tabanlı Derin Öğrenme Makine Sağlığı İzleme isimli makalede Bir makinenin durumu, ölçülen sinyallerin özelliklerini özetleyen özellikler oluşturularak ve sınıflandırılarak otomatik olarak tanımlanabilir. Günümüzdeki mevcut durumda, uzmanlar, kendi alanlarında, bu özellikleri kendi bilgilerine göre düzenlemektedirler. Bu nedenle, performans ve

kullanışlılık, uzmanın temel fizik veya istatistik hakkındaki bilgisine bağlıdır. Ayrıca, yeni ve Özellik mühendisliğinin dezavantajlarını azaltmak için, bu makalede özellik öğreniminin alt alanından, yani derin öğrenmeden, daha spesifik olarak kıvrımlı sinir ağlarından bir yöntem araştırılmıştır. Ek koşullar tespit edilebilirse, uzmanlar yeni özellik çıkarma yöntemleri uygulamak zorundadır. Bu makalenin amacı, makinenin durumunu otomatik olarak belirlemek için kızılötesi termal videoya derin öğrenmenin uygulanıp uygulanamayacağını ve nasıl uygulanabileceğini araştırmaktır. Bu yöntemi iki kullanım durumunda, yani makine arıza tespiti ve yağ seviyesi tahmini için kızılötesi termal veriler üzerinde uygulayarak, önerilen sistemin temel fizik hakkında herhangi bir ayrıntılı bilgi gerektirmeden dönen makinelerdeki birçok koşulu çok doğru bir şekilde tespit edebildiğini gösterdik (yani ilgili kullanım durumları için %95 ve %91,67 doğruluk) ve böylece karmaşık sensör verilerini kullanarak durum izlemeyi önemli ölçüde basitleştirme potansiyeline sahiptir. Ayrıca, eğitilmiş sinir ağlarını kullanarak, kızılötesi termal görüntülerdeki önemli bölgelerin, potansiyel olarak yeni fiziksel görüşlere yol açabilecek belirli koşullarla ilgili olarak tanımlanabileceğini gösterdik [7].

Termal Özellik Analizine Dayalı elmanın Erken Çürüğü için On-line Tespit Sistemi Tasarımı isimli makalede erken mekanik çürüklerin nasıl ayırt edileceği, meyve kusurları ayırma sisteminde kalıcı bir sorundur. Kızılötesi kameranın termal uyarım sırasında yüzey sıcaklığı değişikliklerine duyarlılığı nedeniyle, elma erken çürük tespiti için taşıma ve ısıtma ünitesi, elma yönlendirme ve döndürme ünitesi, çürük tespiti ve kontrolünden oluşan çevrimiçi bir aktif termal görüntüleme sistemi tasarlanmıştır. Bilgisayarda çevrimiçi olarak meyve yüzeyi termal özelliklerinin analizi ile, denemede çürük kusuru etkin bir şekilde tanınabilir. Bu çevrimiçi test sonuçları, kusurlu elma için %90 tanıma oranı ve sağlam elma için %83,3 tanıma oranı sağlarken, çanaklı iyi elma tamamen ayırt edilebildiğini göstermektedir [8].

Güç ekipmanlarının kızılötesi termal görüntüleme tanı teknolojisindeki yöntemler isimli makalede Yaygın olarak kullanılan kızılötesi termografi, önemli bir elektrikli ekipman izleme ve arıza teşhis teknolojisi. Kızılötesi termal görüntü işleme ve yapay zekâ teşhis hataları konusunda iki temel adımı vardır. Elektrikli ekipman termal arıza teşhisinin doğruluğunu artırmak için, görüntü işlemede gürültü giderme, segmentasyon ve özellik çıkarma algoritmaları, akıllı teşhis için sinir ağlarının BP ve RBF ağ modeli, spesifik deneysel koşullar, avantajlar ve dezavantajlar ile tartışılmıştır. Çeşitli teknolojiler ve geliştirilmiş yöntemler belirtilmiştir [9].

Yumuşak hesaplama yöntemlerine dayalı termal görüntü kullanarak arıza tespiti: Karşılaştırmalı çalışma isimli makalede termal görüntü işleme kullanılarak bir Baskılı Devre Kartı (PCB) modelinin Tümüleşik Devre (IC) arıza algılamasını sunar. Termal görüntü, sonlu elemanlar yöntemi (FEM) ile PCB modelinden yakalanır ve işlenir. Histogram öznelikleri, bir sınıflandırıcı modelinde girdi olarak kullanılan IC'lerin sıcak noktalarından çıkarılır. Etkin öznelikler, temel bileşen analizi yöntemi ile en aza indirilmiştir. Bu çalışmada, üç yumuşak hesaplama tekniğine

dayalı olarak görüntü sınıflandırma ve algılama için karşılaştırmalı bir çalışma yapılmıştır: çok katmanlı algılayıcı, destek vektör makinesine uyarlanabilir nöron bulanık çıkarım sistemi. Modellerin etkinliği, sınıflandırmanın performansı ve doğruluğu karşılaştırılarak değerlendirilir. Modeli doğrulamak için, gerçek zamanlı çalışan PCB'deki arıza durumunu tespit etmek için Arduino UNO üzerinde deneysel değerlendirme yapılır [10].

Termal Görüntü İşleme ile PCB'de Hatalı Entegre Devrelerin Tespiti isimli makalede Arızalı Entegre devrelerin (IC'ler) tespiti için kullanılabilecek bir sistem geliştirmek, elektronik endüstrisindeki en büyük zorluklardan biridir. IC'lerde çeşitli nedenlerle ısınma, performansın düşmesine neden olabilir ve Baskılı Devre Kartlarında (PCB) ciddi tehlikeli etkilere neden olabilir. Termal görüntü işleme, IC arıza tespiti için kullanılabilecek en iyi temassız, müdahalesiz yöntemlerden biridir. Bu makale, termal görüntüleme kamerası ve görüntü işleme teknikleri yardımıyla PCB'deki hatalı IC'lerin tespit edilmesini amaçlamaktadır. Farklı arıza durumları için dizi dedektör devresinin termal görüntüleri toplanır. Görüntü eşleştirme, Hızlandırılmış Sağlam Özellikler (SURF) algoritması kullanılarak eğitim görüntülerinin özellikleri ile test görüntüsünün özellikleri karşılaştırılarak elde edilir. Sistem, görüntünün belirli bir arıza sınıfına ait olduğunu gösterecektir [11].

Konu ile ilgili bilimsel çalışmalar incelendiğinde; termal 3B modelleme nesnesi olarak genelde binaların kullanıldığı görülmektedir. Weinmann ve diğerleri literatüre, radyometrik düzeltme, geometrik kalibrasyon, benzerliklerin tespiti, 3B nokta bulutunu ve termal bilgiyi birleştirme olmak üzere 4 aşamalı 3B modelleme yöntemi sunmuşlardır. Bu metodun diğer metotlara göre iç mekanlarda daha uygulanabilir olduğunu savunmuşlardır [12].

Termal kızılötesi görüntüleri kullanarak sarhoş kişileri tanımlamak için sinir ağları isimli makalede sinir ağları, alkol almış kişileri ayırt etmek için yüzlerin kızılötesi görüntüleri üzerinde test edildi. Görüntüler kırk bir kişi tarafından gerçekleştirilen kontrollü alkol tüketimi sırasında elde edildi. İki farklı deneysel yaklaşım derinlemesine araştırıldı. Bunların ilkinde, her bir yüz, alkol almamış bir kişiden alkol almış/sarhoş bir kişiyi ayırt etmek maksadıyla kullanılabilecek bölgeleri bulmak için, her seferinde farklı bir sinir ağı kullanarak, bölge incelenmiştir. Alkol tüketimiyle termal davranışı/durumu değişen kısmın, çoğunlukla yüzün alın bölgesi olduğu tespit edilmiştir. İkinci prosedürde tüm yüz üzerinde tek bir sinirsel yapı denendi. Bu sinirsel yapının ayırt etme performansı, aynı yüzün yanı sıra bilinmeyen yüzlerde de test edildi. Sinir ağları, sırasıyla alkol almamış olan ve sarhoş kişinin yüzlerinin alın kısımlarında denendiğinde, bilinmeyen kişiler üzerinde bile yüksek ayırt etme performansı sundu. Küçük sinir yapıları daha iyi genelleme performansı göstermiştir [13].

Seralarda Isı Kaybına Neden Olan Yapısal Sorunların Termal Kamera ile Belirlenmesi isimli makalede Tarımsal üretim yapıları olan seralarda ısıtma yapılarak daha fazla ve aynı zamanda kaliteli ürün alınabileceği bilinmektedir. Soğuk mevsimlerde ısıtılarak üretim yapılan seralarda,

ısıtma girdileri üretim giderleri içerisinde önemli bir yer tutmaktadır. Seralarda ısıtma giderlerinin en az düzeye indirilmesi ve tüketilen enerjiden en fazla etkinin elde edilmesi amacıyla teorik olarak öngörülen ve uygulanan bazı ısı tasarruf önlemleri, yeterli sızdırmazlık ve yalıtımın yapılmamasından dolayı istenilen etkiyi gösterememektedir. Bu amaçla, seralardaki yapısal sorunlardan kaynaklanan ısı kayıplarının belirlenmesi için termal görüntüleme yönteminin kullanılabilirliği bu çalışma ile irdelenmiştir. Termal kamera ile seralarda ısıtma yapılırken alınan görüntüler, analiz yazılımıyla detaylı olarak incelenerek ve ısı kaybına neden olan sorunlar belirlenmeye çalışılmıştır. Elde edilen sonuçlar, ısı kayıplarına neden olan yapısal sorunların termal görüntüleme tekniği ile tespit edilebildiğini ve bu sorunların en çok kapı altları ve kenar boşlukları, havalandırma penceresi kenarlarındaki açıklıklar, örtü malzemesinin çatı-ön duvar ve çatı-yan duvar birleşim noktaları ile iyi izole edilmeyen subasman betonunda olduğu göstermiştir [14].



2. TERMAL KAMERALAR

2.1. Termal Kameranın Tarihçesi

Termal kamera kızılötesi radyasyonun bulunmasıyla ortaya çıkmıştır. Kızılötesi kamera, termal görüntüleme ve termal görüntüleme aleti olarak da adlandırılır. 1800’lü yıllarda sanayi devriminin yeni başlaması ile birçok icat yapıldı. William Herschel kırmızı ışığın ötesinde renk tayfında olan bir ışın keşfetti. Bu ışığa Latince de infra adına gelen kızılötesi ismini verdi. I. Dünya savaşına aktif olarak kullanılmayan kızılötesi ışınlar 1. Dünya savaşından sonra önem kazandı. Daha çok barometre ve termometre kullanımına odaklanılmıştı. Bu cihazlar ise buharla çalışan cihazların ve kazanların sıcaklık ölçümünde kullanılıyordu. Seebeck etkisinin kullanılmasıyla günümüzdeki termal kameralar bulunmuştur. 1826 yılında Leopoldo Nobili bu etkiyi kullanarak ilk Termografik kamerayı icat etmiştir. Başlangıçta Leopoldo Nobili, ve Macedonio Melloni 10 metre uzaklıktaki bir kişiyi tespit edebilen ısı ölçer cihazını 1833 yılında icat etti. 1880 yılında Samuel Pierpont Langley termal kameranın ilkel hali olan ilk bolometre cihazını icat etti. Yüksek sıcaklıklara duyarlı olup ve 400 metre uzaklıktan gelen bir trenin içindeki ineğin sıcaklığını tespit edebiliyordu. İlk termografik kamera ise ordu için geliştirilmişti. Macar Fizikçi Kalman Tihanyi 1929 yılında İngiltere’nin savaş uçaklarını savunması için ısıyı ölçebilen ve gece görüşüne sahip televizyon kamerası icat etmişti. Daha sonra bu cihaz kızılötesi ışınları tespit edebilmek için geliştirildi. 1947 yılında ABD ordusu kızılötesi ışınları tespit edebilecek bir cihaz yapması için Texas Instruments firmasını görevlendirdi. Termal kameranın ilk ticari şekli 1965 yılında üretildi. Yüksek voltajlı kabloların ve panoların ısı değerini ölçmek için sanayi alanında faaliyet gösteren firmaya satıldı. 1950’li yıllarda İngilizlerin “Sarı Ördek” adını verdikleri ilk Kızılötesi Linescan sistemi icat edildi. Aslında bu icat çeşitli detektör ve aynaların kullanıldığı tarayıcı sistemdi. 1970 yıllarında LED ışıklarıyla desteklenen ve yüksek çözünürlüğe sahip, ısı detektörleri üretilmeye başlandı.


2.2. Termal Kamera Yapıları

Termal kameralar optik mekanik birimleri, sinyal işleme ve dedektör soğutucu birimlerinden oluşmaktadırlar.

2.2.1. Optik Mekanik Birimler

Tipik termal kameralar merceği, mercek muhafazasını, ekranı, dedektör ve işleme elektronik cihazlarını, kumanda araçlarını, veri depolama cihazlarını, veri işleme ve rapor oluşturma yazılımlarını içeren çok sayıda ortak bileşenden oluşur. Bu bileşenler termal görüntülemenin model ve tipine göre değişiklik gösterebilir. Optik birimin görevi, nesnelerden salınan IR radyasyonu odaklayıp dedektör üzerine düşürmeyi sağlamaktır. Optik birim olarak IR bandı için tasarlanmış

ayna, mercek ve prizmalar kullanılmaktadır. Şekil 2.1'de bir termal kameranın yapısındaki optik bölüm verilmiştir. Bakış açısı, büyütme, optik çözünürlük ve geçirgenlik optik birimi oluşturmaktadır [15].



Şekil 2.1. Bir termal kameranın optik birimi [15]

Çoğu uzun dalga boylu termal görüntüleyicinin mercekleri germanyumdan (Ge) yapılmıştır.

İnce yansıma önleyici astar tabakaları, merceklerin geçirimini artırır. Termal bir kameranın üzerine konumlandırılmış sıvı kristal görüntülü (LCD) araştırma monitörü üstünde, termal bir imaj açığa çıkarılır. Çeşitli saha konumlarında yüz yüze kalınan değişik tenvir koşulları altında kolayca incelenebilmesi için LCD araştırma monitörü, yeterince geniş ve parlak olmalıdır. Bir imaj sık sık batarya şarjı, tarih, saat, hedef sıcaklığı görülebilir ışıklı imaj ve sıcaklığa ilişkin bir renk spektrumu anahtarı şeklinde bilgilerde sağlayacaktır [15]. Dedektör ve işleme elektronik cihazları, kızılötesi enerjiyi işleyerek kullanılabilir bilgiye dönüştürmek için kullanılır.


Hedeften gelen termal ışınım, çoğu zaman elektronik yarıiletken bir malzeme olan dedektör üzerine odaklandırılır. Termal radyasyon, dedektörden gelen ölçülebilir bir reaksiyon üretir. Bu reaksiyon, termal görüntüleyicinin gösterme ekranında termal bir imaj oluşturmak suretiyle, termal görüntüleyici arasında elektronik olarak işlenir. Ekran üstündeki termal bir görüntüyü düzeltmek için kumanda araçları ile çeşitli elektronik ayarlamalar yapılabilir.

Sıcaklık aralığı, termal standardize menzili ve düzen, renk paletleri ve görüntü tevhit gibi değişkenlere elektronik ayarlamalar yapılabilir. Ayarlamalar hem de yayma kuvvetine ve yansıtılan

arka plan sıcaklığını da yapılabilir. Termal görüntüleri ve ait verileri içeren elektronik dijital dosyalar, farklı tiplerde elektronik hafıza kartları ya da depolama ve aktarma cihazlarında depolanır. Pek oldukça kızılötesi görüntüleme sistemi tümleşik, görülebilir ışıklı bir kamera ile elde edilen bir görsel imajın yanında tamamlayıcı ses ya da metin verilerinin depolanmasına da izin verir [15].

2.2.2. Dedektör ve Soğutucu Birimi

Normal kameralar görüntüyü ışık yardımıyla oluştururken termal kameralar görüntüyü ısı yardımıyla oluştururlar. Bu tür kameralarda kullanılan dedektörler çok minik ısı farklarını yakalayabilen (0,01 °C gibi) ve bu farklılıktan görüntü oluşturabilen özelliklerdedir. Ayrıca imaj oluşturabildikleri belli bir ısı aralığına sahiptirler [17]. Her ısı değerinde farklı IR yayılımlar olduğu ve her IR yayılımın değişik dalga boyuna sahip olduğu için dedektörler belli ısı aralıklarında görüntü verebilirler. Performans belirleyici unsurların başı dedektördür. Hassas dedektörlerin kullanılması çözünürlüğü arttırmaktadır. Şekil 2.2 'de termal kamera dedektörlerinin yapısı verilmiştir. Dedektörlerde, optik-mekanik sistem ile alınan kızılötesi ışınlar kararı ısı değişimleri meydana gelir. Kameraya gelen ışık, ışık miktarına bağlı olan bu ısı değişimlere göre değerlendirilerek elektriksel sinyale çevrilir.



Şekil 2.2. Termal kamera dedektörleri [15]

2.2.3. Elektronik Sinyal İşleme Birimi

Termal kameranın sahip olduğu analiz yazılımları diğer görüntüleme cihazlarından ayırmaktadır. Analiz yazılımı sayesinde bilgisayar ortamında çekimi yapılan objelere ilişkin problemlerin tespiti yapılabilir. Ortama bakılırsa farklılıkları ya da eşdeğer noktaların birbirlerine göre farklılıkları tespit edilebilir. Bunlar belli formatlarda raporlar haline getirilerek bakım kadrosu tarafından

anlaşılır raporlar haline çevrilebilir. Analiz sırasında çekimi yapılan materyalin cinsinin ne olduğu doğru girilir ise sonuçlar son aşama kırılğan bir halde alınabilir. Bir tuğla ile paslı bir metalin veya parlak bakır bir elektrik sisteminin kızılötesi yayılımları bir olmadığı için çekimi yapılan materyalin yayılım payı doğru girilmelidir [15]. Her materyalin kızılötesi yayılımını bilmemiz ara sıra olası olmayabilir. Bu durumda analiz yazılımı sayesinde doğada bulunan derhal bütün materyal tiplerinin kızılötesi yayılımları bulunabilir.

2.2.4. Termal Kameralarda Çözünürlük

Modern termal kameraların görüntüleri ve kullanımları düzgüsel kameralarla benzerlikler taşımaktadır. Normal kameralarda kullanılan CCD ve CMOS imaj sensörleri görünebilir ışıkları alabilecek biçimde tasarlanmışlardır [15], infrared ışığa karşı kırılğan değildirler. Bu yüzden birçok termal görüntüleme kamerasında focal plane arrays (FPA) imaj sensörleri kullanılmaktadırlar.

FPA'lar daha uzun dalga boylarına cevap verebilmektedirler. Termal kameralarda yapısal farklılıkları bulunmasına rağmen sonuçta normal kameralar gibi görüntü oluşturdıkları için oluşturulan görüntünün çözünürlüğü çözümleme açısından önemlidir. Teknolojinin gelişimi ile beraber 160x120 piksel çözünürlükte imaj oluşturabilenlerin yanı sıra 320x240 px boyutta görüntü oluşturabilen kameralar pazarda yer almaktadır. Termal kamera mevzusunda 1950'den bu yana yapılan emek harcamalar da 640x480 çözünürlüğünde olan kameraların üretimine ulaşılmıştır. 640x480 pixel çözünürlük şu an en iyi termal kamera çözünürlüğüdür. $640 \times 480 = 307.200$ px ile daha uzaktan daha fazla detay görmeyi sağlar [19]. Çözünürlükleri düzgüsel optik kameralardan düşüktür. En sık kullanılan çözünürlük değerleri; 160×120 , 320×240 , 640×512 ' dir.

Çözünürlük arttıkça maliyet oldukça artmaktadır. Termografik kameralar görünür spektrumu yayınlayan kameralara nazaran çok pahalıdır ve son olarak modelleri çoğu zaman ithalat sınırlamalılardır. Eski nesil ışınmölçerler (Bolometre) ya da daha kırılğan modeller (InSb şeklinde) kriyojenik soğutma isteyebilmektedirler [16]. Bu işlem minyatür stirling döngülü buzdolapları veya likit nitrojen ile yapılabilir.

2.2.5. Termal Kameralarda Sıcaklık

Termal kameralar belli bir sıcaklık aralığında görüntü oluşturabilirler. Her sıcaklık değerinde farklı IR yayılımlar olduğu ve her IR yayılımının değişik dalga boyuna haiz olmasından ötürü da bu objektifler belli ısı aralıklarında görüntü verebilirler. Bu kameralarda kullanılan objektifler çok küçük sıcaklık farklarını yakalayabilmekte ($0,01$ °C şeklinde) ve bu farklılıktan imaj oluşturabilme özelliklerindedir [15].

Isıl kızılötesi görüntüleyiciler kızılötesi dalga boyundaki enerjiyi görünür fer video ekranına dönüştürürler. 0° Kelvin'in üstündeki bütün cisimler ısı kızılötesi enerji yayarlar bundan dolayı


edilgen olarak tüm objeleri ortam ışığından bağımsız olarak görebilirler [15]. Bununla birlikte, birçok termal görüntüleyici sadece -50°C ' den daha sıcak cisimleri görebilirler. Isıl ışıının miktarı ve spektrumu cismin yüzeyinin sıcaklığına bağlıdır. Bu özellik termal kamera ile cismin yüzey sıcaklığının görüntülenmesini sağlar.

Bununla birlikte, öteki etkiler, bu tekniğin doğruluğunu kısıtlayan ışıının etkisinde bırakır. Işıının sadece cismin sıcaklığına bağlı olmayıp, aynı zamanda cismin salım gücünün bir fonksiyonu olmuştur. Ayrıca radyasyon cisimlerden gelen, cisimden yansıyan ve cismin ışıınınla yansıyan ışıının atmosferin soğurmasından da etkilenir. Infrared ışın (IR) -273°C 'nin üzerindeki her nesnenin yaymış olduğu sıcaklığı alabilir. İnsan gözünün göremediği infrared ışını termal bir kamera görebilir. Yayıdıkları sıcaklığın miktarını göstermek için nesnelerin fotoğraflarını çekebilir. Bu tür resimler nesnenin ısı düzeyini harita renkleriyle gösterir.


2.3. Termal Kameraların Kullanım Alanları

2.3.1. Elektrikle İlgili Uygulamalar

Elektrikli sistemlerin dayanıklılığını incelemek için en fazla termal kameralar kullanılır. Termal görüntüleyicilerin test sistemleri temassız ve hızlı uygulanabilir. Elektriğin iletimi esnasında direnç üzerinden akım geçerken enerji ısı olarak harcanır. Bu esnada elektrik hatlarının kontak noktalarındaki ısının artışı o noktada direncin olduğunun belirtisidir. Sigorta yuvası, kablo ve birleşme noktalarında, şalterlerde oluşabilecek ısınmalar termal kameralar ile gözlenerek noktasal tespit yapılabilir. Bu tespitler şekil 2.3 ve şekilde 2.4'te gösterilmiştir [17]. Elektrik sistemlerindeki gevşek yada aşırı sıkı bağlantılar, çok fazla bükülmüş kablolar, çok fazla yüklü kablolar, kesitin yetersiz olması, yük dağılımlarının yetersiz olması, eski ekipman ve eşli kabloların kullanımı gibi problemler daha başlangıç anında termal kameralar ile görüntülenerek ekipmanın zarar görmesi engellenerek, arızaların meydana getirebileceği büyük kayıpların önüne geçilir [18].



Şekil 2.3. Elektriksel Uygulamalar [20]




Şekil 2.4. Elektriksel Uygulamalar-2 [20]


2.3.2. Elektromekanik ve Mekanik Uygulamalar

Termal kamera ile elektromekanik ve mekanik denetimleri motorlar, döner parçalar, buhar ayırıcıları ekipmanları kapsar. Bu yapılan uygulamaların çoğu nitelikseldir. Alınan termal görüntü daha öncekiyle kıyaslanır [18]. Daha sonra ekipmanda meydana gelen sıcaklık değişiminden oluşan her farklı durum dikkate alınır. Motorlar ısıyla oluşabilecek arızalara elverişli olduğu için termal olarak incelenirler. Motor ayarının yanlış yapılması veya motorun dengesizliği çok fazla ısınma ile sonuçlanır. Motorun iç sıcaklığındaki değişimler her zaman çok kısa bir zamanda anlaşılamaz. Zaman içinde sık sık ya da benzer motorlarla termal görüntülerini kıyaslamak yararlı olabilir. Denetlemelerde motor yataklarının termal görüntüsü de kullanılmaktadır. Örneğin şekil 2.5 ve şekil 2.6'da ki motor yatakları motordan daha çok sıcaksa bu, bir sorun olabileceğinin göstergesidir. Benzer şekilde normal olarak işleyen motor bağlantıları ve mil yatakları ortam hava sıcaklığına çok yakın termal imzalar sergilemelidir. Düşük hızlı döner ekipmanların denetlenmesinde

termografinin oldukça faydalı olduğu kanıtlanmıştır. Türbinler, ısı değıştirciler ve dişli kutuları gibi daha karmaşık tipteki ekipmanlar da bir termal kamera ile incelenebilir [19].



Şekil 2.5. Bir fabrikada ısı yayan bir makinenin gerçek ve termal görüntüsü [20]




Şekil 2.6. Çok fazla ısınmış motor bloğu [20]

2.3.3. Süreç Uygulamaları

Termal kameralar ısıya dirençli olan yüksek sıcaklıklara dayanabilen ekipmanları denetlemek için oldukça sık kullanılırlar. Depolama tankları, silolardaki gazların sıvıların ve katıların seviyelerini tespit etmek için çoğunlukla termografiden faydalanılır. Deponun içindeki malzeme seviyesini göstermek üzere depoların çoğu bir düzenlemeye sahip olsa da bu düzenlemelerin uygun şekilde işlevlerini yerine getirememesi durumunda veriler pek kesin değildir [17].

2.3.4. Bina Tanılaması

Termal görüntüleme ticari amaçlı bina veya ikamet için ayrılmış bina tanılamasıyla ilgili çeşitli uygulamalar için uzun zamandır kullanılmaktadır. Bina tanılama uygulamaları binalarda ısı yalıtım kontrolü, çatı nemlilik kontrolü, hava ve enerji sızıntısına enerji göre bina yalıtımı denetlemelerini kapsar. Şekil 2.7.'de pencere altlarında bulunan radyatörlerin olduğu yerlerde yüksek sıcaklıklar nedeniyle ısı kayıplarının arttığı görülmektedir. Binanın dış yüzeylerinden radyatörlerin yerleri bu şekilde kolaylıkla saptanabilmektedir [18].



Şekil 2.7. Bina uygulamaları [15]

2.3.5. Sağlık Uygulamaları

Sağlık alanında termografi canlıların yüzeyindeki sıcaklık farklılıklarını kaydeden, araştıran ve termogram adı verilen görüntüsünü elde eden tanısal bir görüntüleme yöntemidir. Canlıların dolaşım sistemi, vücudu, hücrelerin yaktığı oksijen, hastalık sırasında savunma sisteminin devreye girmesi, stres gibi nedenlerden dolayı yayılan ısı termal kameralar ile tespit edilip vücudun neresinde sıcaklık değişimi olduğunu ve rahatsızlıkları tespit edilebilir.


Vücut yüzeyinin sıcaklığı cinsiyet, yaş, metabolizma kilo ve damarlardan akan kanın miktarına bağlı olarak değişiklik göstermektedir. Termal kameralar ile; deri yüzeyinden yaklaşık 6mm derinliğinde ısı emisyonu algılanarak termografik görüntüler elde edilmektedir [20]. Normalde vücutta termal olarak simetri olduğundan, asimetrik sıcaklık farkları kolaylıkla tespit edilir.

Vücuttaki simetrik bölgeler arasında anlamlı sıcaklık farkı bu yöntem ile belirlenerek, ağrının asıl yeri bulunabilir [21].

Termal kameralar son yıllarda sağlık alanında özellikle domuz gribi, covid 19 gibi yüksek ateşe oluşturan hastalıkların tespiti için kullanılmaya başlanmıştır. Termal kameralar kalabalık halde geçiş yapan veya kalabalık bir ortamda insanları tek tek derece ile ölçmek yerine çok daha hızlı bir şekilde ölçüm yapılmasını sağlamıştır. Hızlı bir şekilde insan ısısını ± 1 derece hassasiyetle ölçmektedir. Ayrıca tıpta iltihap ve damar tıkanıklıklarının tespiti, iç yaralanmalarda, meme kanseri ve hastalıklarında, dolaşım sistemi ve hastalıkları, gut hastalığı, kas eklem ve sistemi hastalıklarında kullanılırlar. Şekil 2.8’de beldeki incinme ve burundaki kırık ve şekil 2.9’ da kalabalıklık kişilerin tespiti gösterilmektedir.



Şekil 2.8. Burundaki kırık ve beldeki incinme [20]



Şekil 2.9. Kalabalık ortamlarda hastalıklı kişilerin tespiti [20]


2.3.6. Savunma Uygulamaları

Termal kameralar ilk olarak güvenlik amaçlı, savunma alanında kullanılmaya başlanmış olup zamanla çok çeşitli alanlarda kullanılmıştır [15]. Özellikle ısıya güdümlü füze ve gece görüş sistemleri gibi askeri tekniklerin gelişmesi ile önemli hale gelmiştir. Karakolların korunması, Sınır-kıyı liman gözetlemeleri, karargâh, askeri tesis, petrol platformu, baraj ve boru hattı gibi sivil tesislerin güvenliğinde termal kameralar kullanılmaya başlanmıştır.



Şekil 2.10. Boru hattına yaklaşan insanlar [20]

Pompalama istasyonlarının ve petrol boru hatlarının hırsızlık, sızıntı ve kaza risklerine karşı güvenliği çok önemlidir. Bu amaçla, daha uzun mesafeleri alan yüksek dereceli görüntü işleyen yeni termal kameralar, boru hattının etrafında bir tampon bölge yaratılarak güvenliği sağlamada etkin bir şekilde kullanılmaktadır [22].




Şekil 2.11. Savunma uygulamalarında termal kamera görüntüleri [20]


Petrol sınırında görüntülenen insanların görüntüsü Şekil 2.10'da verilmiştir. Şekil 2.11'de (a-b) sınırdan geçmeye çalışan insanlar ve bina önünde bekleyen insanlar termal kameralar ile görüntülenmiştir.

2.3.7. Endüstriyel Fırın Uygulamaları

Enerji endüstrisindeki işlem sıcaklıkları belirlenen aralıklar dahilindeyse, ürünler istenen kalitede üretilebilir. Tüm süreçlerde plana göre ve doğru sıcaklıklarda çalışıp çalışmadığını düzenli kontrol edilmesi gerekir. Örneğin şekil 2.12’de gösterildiği gibi çelik endüstrisinde ürünler, ham demirin çeliğe işlenmesi ile optimum sertlik derecesinin elde edebilmek için bir süre sabit kalması gereken belirli bir sıcaklığa ısıtılmalıdır. Yüksek sıcaklıklar nedeniyle, çalışan makineler, kullanılan endüstriyel fırınlar şekil 2.13’te gösterildiği gibi özellikle arızaya açıktır. Yenilikçi termal kameralar ile çok yüksek sıcaklıklarda bile yüksek çözünürlüklü termal görüntülerle çalışabilmektedir.



Şekil 2.12. Endüstriyel fırın bacalarındaki gaz birikmesi [16]



Şekil 2.13. Endüstriyel bir fırının tamamen kapanması [16]

2.4. Termal Kamerada Görüntü Analizi

Doğada bulunan bütün nesneler sahip oldukları sıcaklığa bağlı olarak farklı dalga boylarında yoğunluk değişimi yayınlayan termal radyasyon olarak da adlandırılan Elektromanyetik enerji

yayarlar. Dalga boyu $0.7\mu\text{m}$ 'den Uzun, $0.4\mu\text{m}$ 'den kısa ışıma infrared ışıma (radyasyon) denir. Termal görüntüleme sistemlerinin temeli de infrared ışıma dayanır şu demek oluyor ki bir cisim tarafından yayılan ışımadan yararlanarak onun görüntüsünü üretme esasına dayanır. Görüntü işleme teknikleri görüntüyü elde etme, görüntü Zenginleştirme, görüntü iyileştirme, görüntü sıkıştırma, Morfolojik işlemler, bölütleme, sunma ve tanıma gibi isimlerden meydana gelir [15]. Her bir adımda, amaca müsait bir ekip işlemler gerçekleştirilmektedir. Görüntüye uygulanacak işlemler daha sonra sistemin çıkışı; yeni bir görüntü, giriş Görüntüsünün bir kısmı ya da giriş imajındaki nesneler olabilir.

2.4.1. Görüntünün Elde Edilmesi

Termal kamerada ilk yapılan işlem dizi kamera görüntüsünden iki boyutlu imgenin elde edilmesi, ikinci aşamada bu görüntüdeki dedektör farklılıklarını gidermektir. Sonrasında histogram eşleme algoritmalarından biri kullanılarak görüntü ekrana verilir. Termal kameralar gündüz kameralarından farklı olarak tertipli dedektör pikselleri barındırmazlar. Bazı yüksek menzil kameralarda kenar güçlendirme özelliği de kullanılmaktadır [15]. Yüksek menzilli termal kameralar çoğunlukla dizi dedektör yapısına sahiptir. Bu yapılarda, dizi dedektör mekanik olarak tek bir yönde hareketi ile sahne taranarak görüntü elde edilir.


2.4.2. Görüntü İyileştirme

Görüntü içerisindeki gürültünün azaltılması, kenarların belirginleştirilmesi, karışıklığın artırılması, insan gözünün ayırm edemediği sadece şeklin içinde bulunan bilgilerin göz ile Fark edilebilir şekle dönüştürülmesi için kullanılan tekniklerin genelidir. Genel anlamda karışıklık, histogram, filtreleme, keskinleştirme, düzmece renklendirme ve değişiklikleri büyütme gibi teknikler kullanılmaktadır. İşlenecek şeklin özelliklerine ve amaca uygun görüntü işleme tekniklerinin belirlenmesi çok önemlidir.

2.4.3. Görüntü Analizi

Nesnelerin görüntülerinin analizinde öncelikli olan konu görüntünün üzerinde ilgilenilen kısım ve “geri kalanı” arasındaki farkı bulmaktır. Bu da görüntünün detayının ölçülerek, boyutlandırılarak ve sayılarak nesnelerin tanınması işlemidir. Görüntü analizinde giriş görüntüyken, çıkış görüntüden elde edilen özelliklerdir. Görüntünün içerisinde ilgilenilen kısmı bulmaya yarayan tekniklere bölümlendirme teknikleri denmektedir. Bölümlendirme tekniğinde parlaklık eşik değeri olarak bir θ değeri seçilerek görüntüye uygulanır. Algoritma açık rengin üzerindeki koyu kısımları veya tersi olarak koyu zemin üzerinde parlak kısımları arar. Sonuçta “nesne” ve “arka plan” olarak iki kısım

belirlenir. Şekil 2.14’de sokaktaki termal yaya görüntüsünün eşikleme işlemi yapılmış görüntüsü verilmiştir [23].



Şekil 2.14. Eşikleme işlemine tabi tutulan termal sokak görüntüsü [16]

3. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, geçmiş uygulamaları ve/veya ilgili uygulamalardaki örnek veri setlerini kullanarak bir sürecin optimizasyonu geliştirmek için matematiksel ve istatistiksel denklemler kullanarak bilgisayarları programlamaktır. Çalışmalarda kullanılan veri setinden yüksek olasılıklı modeller oluşturup istenilen sonuçların otomatik olarak elde edilmesidir. Makine öğrenmesi, elimizdeki uygulamalarda kullandığımız veya kullanacak olduğumuz büyük veri kümeleri ile gelecekte tahmin edilebilecek değerlerin elde edilmesine öncülük etmektedir. Tüm canlılar geçmiş tecrübelerinden öğrenerek, karşılaştıkları olaylara karşı bilgili davranışlar sergiler, geçmiş tecrübelerinden edindiği bilgiler sayesinde yeni karşılaşılabilecek durumlarda kendilerini sürece hazırlama ve adapte olma eğiliminde bulunmaktadırlar. Bu kısımda önemli olan sürekli hatırlatma, sürece uyum sağlatırma ve genelleştirme yetenekleridir. Geçmiş yıllarımızda yaşadığımız veya karşılaştığımız durum/olay karşısında bir duruma veya olaya bağlı olarak bir eylem faaliyete geçirdiğimizi varsayalım [24], Eğer süreci durumun veya sürecin üstesinden gelmek için uyguladığımız bu eylem başarılı olmuş ise aynı eylemi gelecekte benzer durum ve olaylar karşısında uygulayabiliriz. Fakat bu eylem başarılı olmaz ise durumun veya sürecin üstesinden gelmek için farklı çözüm eylemlerinin tespit edilmesi, yani farklı bir eylemin uygulanması gerekmektedir.

Makine öğrenmesinde, mevcut öğrenme algoritmasını kullanarak, veri kümelerinin analizinde istatistiksel ve matematiksel denklemleri uyguladıktan sonra süreçler karşısında uygun eylemler gösterilebilmektedir [24].

Bir matematik denklemi çözerken nasıl bir yol izliyoruz? Eğitim dönemimizde öğretmenlerimizin konuyla ilgili örnek çözmüş olduğu soruları inceleyip benzer denklemleri çözüp farklı çözümleri geliştirebiliriz. Farklı bir örnek daha verecek olursak, Sesleri analiz eden bir sisteme, defalarca farklı seslerdeki insanların seslerini dinlettikten sonra sistem kendi performansını arttırarak farklı sesleri değerlendirme yeteneği kazanıp yorumlayabilecektir. Bu bunun sonucunda öğrenmiş olduğu için performansı artacaktır [24].


3.1. Makine Öğrenmesi Tarihçesi

Makine öğrenmesi kavramı dünya tarihinde ilk kez 1959'lu senelerde IBM şirketinde çalışan Arthur Lee Samuel'nin geliştirmiş olduğu dama oyununda kullanılmıştır [25]. Robert Nealey, Arthur Lee Samuel'in geliştirmiş olduğu dama oyunu oynamış ve bilgisayara karşı mağlup olmuştur. Çünkü Arthur'un geliştirmiş olduğu dama programı yapılan her hamleyi öğreniyor, mevcut hatalarını düzeltiyor ve yaptığı bu adımlardaki verileri öğrenecek karşı tarafı mağlup etmenin farklı yollarını buluyordu. Bunun sonucunda Arthur'un geliştirmiş olduğu dama oyunu her

oyun sırasında kendini daha çok geliştirmekteydi [25]. 1960'lı yıllardan sonra Makine öğrenmesi günümüzde enerji, sağlık, savunma sektörleri başta olmak üzere birçok alt ve farklı sektörde yaygın olarak kullanılmaktadır.


3.2. Makine Öğrenmesi Teknikleri

Makine öğrenmesi, derin öğrenme uygulamalarının bir üst kümesi olup, yapay zekâ uygulamalarının bir alt kümesinde bulunmaktadır. Literatürde dış katmandan iç katmana doğru yapay zekâ – makine öğrenmesi – derin öğrenme – sinir ağları olarak sıralanmıştır. Makine öğrenmesinde istatistiksel uygulamalar ve matematiksel denklemlerden oluşan algoritmalar, modellerde kullandığımız veri setlerindeki kalıpları, regresyonları ve korelasyonları tespit etmek ve bu istatistiksel analizleri temel alan en optimum tahminleri tasarlamak ve karar mekanizmalarını oluşturmak için eğitilmektedir [26]. Makine öğrenimi uygulamaları, kullanım sayısı ve veri girişi arttıkça gelişir ve daha doğru sonuçlar elde edilir.



Şekil 3.1. Makine öğrenmesi uygulamaları

Şekil 3.1.'den de anlaşılacağı üzere makine öğrenmesi kavramı yapay zekâ ve derin öğrenme konularıyla ilişki içerisinde.



Şekil 3.2. Makine öğrenmesi öğrenme süreçleri

Şekil 3.2’de göreceğiniz gibi Makine öğrenmesinin, öğrenme süreci beş temel adımda özetlenebilmektedir [24].

Makine öğrenmesinde, öğrenme sürecinin birinci adımı olarak çözülmesi istediğimiz problemin iyi bir şekilde açıklanması ve problemin çözülmesi için gerekli görevlerin tespit edilerek tanımlanması gerekmektedir [24]. Problem Tanımla adımıyla ilgili detaya incek olursak, bu adımda çözülmesi istediğimiz problemin ne olduğunu, problem çözümü için neler istendiği ve problemin çözüm süreci konusunda araştırmalar bu adımda incelenmektedir.


Makine öğrenmesi sürecinin ikinci adımı ise çalışmada kullanacağımız veri kümesinin yapılacak analizlere göre hazırlanması sürecidir [24]. Beş aşamalı tüm sürecin en önemli aşamasıdır. Öğrenme için mümkün olduğundan fazla veri toplanırsa toplansın, en optimum algoritmalar oluşturacak şekilde veriler analiz edilmez yada düzenlenmez ise sonuç çıktıların bir önemi olmayacaktır. Algoritmalarımızı oluşturacak veri setinin problemin çözümüne uygun nitelikleri taşıması/anlaşılması gerekmektedir. Veri analizde yapılacak düzenlemeleri; Kategorik ve numerik veri ayrımı, korelasyon – regresyon analizi, ortalama üzeri/aykırı değerlerin tespiti, eksik verilerin kontrolü ve yerinin doldurulması, analizlere uymayan verilerin veri kümesinden çıkarılması, normalizasyon işlemleri, istatistiksel kontroller gibi düzenlemelerden oluşmaktadır.

Makine öğrenmesinde problemi tanımlayıp veri setlerini düzenledikten sonra modellerde kullanılabilecek k-en yakın, Naive Bayes, Yapay sinir ağları ve k-ortalama gibi algoritmalar bulunmaktadır [24]. Üçüncü aşamada yukarıda bahsetmiş olduğumuz algoritmalar veri kümelerine

entegre edilerek modelleme oluşturulur. Üçüncü aşamada birçok algoritmayı kullanarak problemin çözümüne en uygun algoritma seçilip modelin performansı optimize edilir.

Dördüncü aşamada ise oluşturulan model çeşitli yöntemler kullanılarak geliştirilir eksik algoritmalar var ise gerekli iyileştirmeler yapılır [24]. Algoritma da yapılacak düzenlemeler blendleme, boosting ve bagging gibi yöntemlerden faydalanılabilir.

Makine öğrenmesinin son aşamasında ise kurulan modelin değerlendirmesi yapıldıktan sonra yapılan analizlerin sonuçları incelenip raporlanarak sunulur [24]. Elde ettiğimiz sonuçlar ve algoritmanın performansı problemin çözümünde tutarlı ise model uygulanır.



Şekil 3.3. Makine öğrenmesi öğrenme yöntemleri

Şekil 3.3'te belirtildiği gibi Makine öğrenmesinde kullanılan öğrenme yöntemleri denetimli öğrenme yöntemi ve denetimsiz öğrenme yöntemi olarak iki ana başlıkta incelenebilir.

3.2.1. Denetimli Öğrenme

Denetimli öğrenme, makine öğrenmesinde kullanılan en yaygın öğrenim tekniklerinden biridir. Makine öğrenmesindeki tespit edilen problemin çözümünde genellikle regresyon analizi ya da sınıflandırma teknikleri kullanılmaktadır. Bu öğrenme tekniğinde algoritmadaki eğitim verileri bizim tarafımızdan isimlendirilen, istediğimiz formül veya çözüm yöntemlerinden oluşmaktadır. Problemlerin çözümleri giriş yapılan kullanıcı tarafından bilinmesine rağmen algoritma

içerisindeki formüller tanımlanarak, gözlemler öğrenilir ve çözüm için sonuç çıktısında tahminler elde edilir [24].

Sınıflandırma: Veri kümesi içerisindeki değişkenlerin aralarındaki benzerlik, uyum vb. değerlendirme parametresine göre sonuç çıktıları elde edilerek veri kümesi içinde- karar ağaçları, rastgele tahminler, Bayes sınıflandırıcı gibi sınıflandırma yöntemleri kullanılarak sınıflandırmalar yapılmaktadır [27]. Örneğin bir elektrik şirketinde müşterilerin faturalarını ödeme zaman aralıklarına göre sınıflandırma yapılabilir ya da çeşitli marketlerde müşterilerin ürün alımlarındaki davranışlar izlenerek hangi ürün gruplarını aldıklarına göre sınıflandırmalar yapılabilir [28].

Regresyon: Makine öğrenmesindeki veri kümesindeki değişkenler arasındaki ilişkileri analiz ederek bir sonraki değeri tahmin edip anlamlandırmamız sağlamaktadır [27]. Örneğin rüzgâr enerjisinden üretilen enerji miktarını geçmiş dönemlerdeki üretilen enerji ve rüzgar hızı arasında regresyon analizi yaparak kısa, orta ve uzun vadede tahminlerde bulunabiliriz. Geçmiş dönemlerdeki, yağış ve sıcaklık verilerine barajlarda üretililecek enerjiyi tahmin edebiliriz [28].

3.2.2. Denetimsiz Öğrenme

Makine öğrenmenin tekniklerinden farklı bir öğrenim tekniği olan denetimsiz öğrenme algoritmaları model içerisindeki veri setindeki, verinin tüm özelliklerinden yararlanarak örnekleri gruplar halinde ayırır. Denetimsiz öğrenme yöntemi sayesinde, denetimli öğrenmeye göre daha karmaşık analizler yapılabilmektedir [26].

Problemlerin çözümünde kullanılan bu yöntem kümeleme algoritma yöntemi denir. Kümeleme yönteminde veri setindeki değişkenler arasında benzerlik ve/veya farklılık, ya da değişkenlerin birbirlerine göre yakınlık-uzaklık durumuna göre kümeleme işlemi yapılır [24]. Kümeleme işleminde veri setindeki örneklerin kaç adet farklı kümeye ayrılacağı bizim tarafımızdan belirleneceği gibi algoritmada analizler yapılarak da belirlenebilir. Kümeleme yönteminde aynı grupta yer alan veri değişiklerinin arasındaki mesafenin minimum, kümeler arasındaki uzaklığın maksimum olması gerekmektedir.

Boyut küçültme yönteminde ise temel olarak amaç, yapacağımız analiz sonucu kesin sonuca ulaşmak için veri setindeki değişken sayısını azaltmaktır [27].

3.2.3. Yarı Denetimli Öğrenme

Makine öğrenmenin tekniklerinden diğeri olan yarı denetimli öğrenme tekniği denetimli öğrenme ve denetimsiz öğrenme tekniklerinin kombinasyonudur [29]. Bu yöntemde veri setindeki verilerin bazıları özel olarak etiketlenilirken bazıları ise etiketlenmemektedir. Bu yöntemin temel amacı iki öğrenme yöntemini de pekiştirerek öğrenme performansını arttırmaktır [26].

3.2.4. Takviyeli (Pekiştirmeli) Öğrenme

Takviyeli öğrenme yöntemi diğer yöntemlerden farklı olarak ödül ve ceza sisteminde göre öğrenim sağlamaktadır. Takviyeli öğrenim yönteminin amacında problemin çözümünde çözüme giderken en doğru yolu bulmak, bu yolu bulurken analizlerde yapılan hatalardan çıkarımlar yapmaktır. Çıkarımlar sonucu en a hata tespiti ile en doğru gidiş yolunu bulmak amaçlanmaktadır [24]. Bu öğrenme tekniğinde algoritma dış ortamla soru-cevap yapıp, geri bildirim alarak ödülleri artırıp öğrenme performansını arttırabilmektedir. Bebeklerin yanan sobaya elleri ile dokunup, ellerinin yanması ve bir daha sobaya dokunmaması takviyeli öğrenmeye örnektir [29].

3.2.5. Örnek Tabanlı Öğrenme

Örnek tabanlı öğrenme tekniğinde algoritma, yeni ve farklı bir örnek ile karşılaştığında hafızasında bulunan diğer eğitim verileri ile oluşan örnek toplulukları ile bu yeni ve farklı örneği karşılaştırıp onu tanımaya çalışarak farklı bir etiket oluşturmaktadır [29].

3.2.6. Model Tabanlı Öğrenme

Model tabanlı öğrenme tekniğinde algoritmada oluşturulan model sonucu bilgisayarlarda ve dış dünyada eylemler faaliyete geçmektedir [29]. Bu faaliyete geçiş sonrası modelin ödülü ne olursa olsun dış ortamdan alır ve sonuçlarını öğrenerek sürekli kendini günceller. Öğrenme tekniğini hızlandırma gibi avantajları vardır. Öğrenmenin devam etmesi için dış ortamın yanıt vermesi beklenmez ve çevreyi sıfırlama işlemi yapmamıza gerek yoktur.

3.3. Model Performans Değerlendirme Yöntemleri

Makine öğrenmesinde algoritmalar kullanılarak problemlere uygun veri kümelerine göre modeller elde edilmektedir. Değerlendirme yöntemleri, algoritmalar kullanılarak oluşan modellerin hangisini daha iyi olduğu tespit etmek ve ilerleyen zamanlarda eğitim modelinin çalışma kalitesini anlamamız amaçlanmıştır [30]. Hold-out ve cross validation olmak üzere iki temel model performans değerlendirme yaklaşımı bulunmaktadır.

3.3.1. Hold-out

Makine öğrenmesi için elimizdeki algoritmaların veri setleri; test, doğrulama ve eğitim olmak üzere üç gruba ayrılır [30]. Eğitim Verileri: Modelimizdeki girdi değişkenlerine bağlı olarak çıktı değişkenlerinin özelliklerinden oluşan gruptur. Doğrulama Verileri: Eğitim verilerine bağlı olarak çıktı sonuçlarından elde edilen modelin performans parametrelerini incelemek ve değerlendirmek için kullanılmaktadır. Model-problem arasındaki en iyi optimizasyonu sağlayarak, kullanılacak

model için en optimum parametreleri seçme olanağı sağlamaktadır. Test Verileri: Modelimizin mevcut veri kümelerindeki veri setleri kullanılarak ilerleyen zamanlardaki performans kalitesini incelemek için kullanılmaktadır.

3.3.2. Cross validation (Karşılıklı Doğrulama)

Modelimizi oluşturan eğitim verileri alt veri setlerine ayrılır. Tek bir alt veri setini eğitmek için kullanırken, diğer veri setlerini doğrulama işlemi kullanılmaktadır. Her bir alt veri seti işlem bu işlem çapraz olarak tekrarlanmaktadır [30].

3.4. Model Performans Değerlendirme Ölçütleri

3.4.1. Regresyon Model Değerlendirme Ölçütleri

R^2 , yapılan regresyon analizi sonucu veri seti içerisindeki verilerin regresyon grafiğine olan yakınlığı ve uzaklığı başka bir değişle ilişkisini inceleyen regresyon analizinin istatistiksel ölçütüdür. İki veri arasındaki ilişkiyi ve bu ilişkiyi incelerken de uygunluk değerinin ölçütüdür [31]. Ayarlanmış R^2 ise R^2 'nin değerine göre veri setine eklediğimiz her bir ek verinin değeri R^2 değerini değiştirmektedir [31]. Ayarlanmış R^2 , veri kümesindeki bağımsız değişkenleri telafi ederek, değişken modele fayda sağlar ise artmaktadır.

Ortalama Mutlak Hata, yapılan analizler sonucu olarak tahmin edilen değerler ile gerçek değer arasındaki farkı ifade etmektedir [31]. Veri seti ile oluşan örneklemede, o örneklem için model ile yapılan tahmini değerler ile öngörülen değerler arasındaki her farkın mutlak değer ortalamasıdır.

Ortalama Kare Hata, Regresyon analizlerinde en yaygın olarak kullanılan regresyon kayıp fonksiyonlarından biridir [31]. Ortalama Kare Hata, veri kümesindeki her bir örneğe göre ortalama kare kaybını ifade etmektedir.

3.4.2. Sınıflandırma Model Değerlendirme Ölçütleri

Karışıklık – Bulanık Matrisi, sınıflandırma modeli için kullanılan performans ölçütüdür [31]. Tahmin edilen ve hesaplanan gerçek değerlerden oluşan 4 farklı kombinasyon içermektedir. Karışıklık-Bulanıklık matrisinde kullanılan terimleri örnekler ile özetleyecek olursak;

TP (Pozitif): Hasta bir insana hasta teşhisi koymak

FP (Pozitif Değil): Hasta olmayan bir insana hasta teşhisi koymak

TN (Doğru Negatif): Hasta olmayan bir insana hasta değil teşhisi koymak

FN (Negatif Değil): Hasta olan bir insana hasta değil teşhisi koymak

Doğruluk, karışıklık – bulanıklık matrisine göre doğru sınıflandırılan örneklemelerin yüzdesini ifade etmektedir.

Hatırlama/Hatırlatma, bulanıklık matrisine göre algoritmadaki pozitif örneklerin sınıflandırmada ne kadar başarılı olduğunun tespitinde kullanılan bir ölçüttür.

Kesinlik, bulanıklık matrisine göre algoritmadaki pozitif olarak ifade ettiğimiz örneklerin, gerçek anlamda pozitif olma olasılığının tespitinde kullanılan bir ölçüttür. Tablo 3.1’de sınıflandırma model değerlendirme ölçütlerine ait formüller açıklanmıştır.


F-Ölçütü, Makine öğrenmesi algoritmalarındaki testlerin doğrulunun bir ölçütüdür. Doğruluk ve hatırlatmanın harmonik ölçüsüdür [31]. Bu F-ölçütü en yüksek 1 ve en düşük 0 olarak hesaplanabilir. Özetlemek gerekirse algoritmada oluşturulan modelin tutarlılığının ve kesinliğinin bir ölçütü olarak ifade edilmektedir. İki algoritma modellerini karşılaştırmak için kullanılmaktadır. ROC-AUC Eğrileri, Makine öğrenmesi algoritmalarındaki eşit ayarlama süreçlerinde sınıflandırma probleminin çözümü için bir performans ölçümünü ifade etmektedir [31]. ROC eğrisi bir olasılık eğrisini temsil etmektedir. AUC ise ROC olasılık eğrisi altında kalan alanı ifade etmektedir. Sınıflar arasındaki modellerin ayırt edilebilme olasılığını anlatmaktadır. AUC eğrisi ve eğriye bağlı olarak ne kadar yüksek olursa modelimizin tahmin değerleri yüksek olur [31].

Tablo 3.1. Sınıflandırma model değerlendirme ölçütleri

Ölçüt	Formül	Özellik
Doğruluk	$\frac{TP + TN}{TP + TN + FP + FN}$	Model genel performansı
Kesinlik	$\frac{TP}{TP + FP}$	Doğru tahmin kesinliği
Hatırlama/Hatırlatma	$\frac{TP}{TP + FN}$	Gerçekleşen pozitif örnek oranı
Özgüllük	$\frac{TN}{TN + FP}$	Gerçekleşen negatif örnek oranı
F-ölçütü	$\frac{2TP}{2TP + FP + FN}$	Dengesiz sınıflandırmalar için hibrit ölçüt

4. DERİN ÖĞRENME

Derin öğrenme dediğimiz kavram, algoritmaların önceki tecrübelerinden yararlanarak öğrenmeleri sağlayan makine öğrenmeni sınıflarından biridir. Derin öğrenme, algoritmalara bağlı olarak özellik sonuçlardan anlamlı özellikler çıkarmak ve dönüştürmek için istatistiksel yöntemler ve doğrusal olmayan işlem birimi katmanlarından yararlanmaktadır [32]. Derin öğrenmenin farklı tanımları arasında karmaşık problemlerin gözlenmesi, analiz edilmesi, öğrenilmesi ve karar verilmesi gibi insan beyninin çeşitli fonksiyonlarını denetimsiz bir makine öğrenmesi gibi taklit etmesi yer almaktadır. Derin öğrenme, insanların geçmiş tecrübelerinden öğrenip ders çıkardığı gibi algoritmayı iyileştirmek için sürekli değişiklikler yaparak daha optimum daha net daha iyi sonuç çıkarmayı amaçlamaktadır.



Şekil 4.1. Derin öğrenme süreçleri

Şekil 4.1’de görüldüğü gibi derin öğrenmenin öğrenme süreçlerini beş temel adımda özetleyebiliriz.

Derin öğrenmenin günümüzde kullanıldığı alanlar;

- Ses, Yüz ve Görüntü tanıma teknolojileri
- Otomobillerde sürücüsüz kullanma imkânı sağlayan otopilot teknolojilerinde
- Tüketici alışkanlarının izleyip, tavsiye ve öneri teknolojilerinde

- Savunma ve Sanayi sektöründe ekipmanların ve araçların tahminleyici bakım teknolojilerinde
- Sağlık uygulamalarında Kanser, Şeker hastalığı gibi kalıtsal hastalıkların tespiti için kullanılan teknolojilerde

4.1. Derin Öğrenme Tarihçesi


Makine öğrenme sınıflarından biri olan derin öğrenme yapay sinir ağlarını gibi yöntemleri kullanarak canlıların beyni gibi beyin fonksiyonlarını taklit eden hesaplama uygulamalarına dayanmaktadır. Derin öğrenme ilk olarak şekil 4.2’de de görüldüğü gibi 1943’lü yıllarda Waller Pitts ve Warren McCulloch’un düşünce süreçlerini taklit etmek amacıyla kullanmış olduğu sinir sistemlerinin mantığı ve matematik uygulamalarını baz alan bir hesaplama algoritması oluşturmalarına dayanmaktadır [32]. 1958’li yıllara geldiğimizde Frank Rosenblatt temel toplama ve çıkarma işlemlerini hesaplayabilmek için iki katmanlı yapay sinir ağı ve denetimli öğrenme kullanan bir desen tespit etme algoritması olan perceptron’u oluşturmuştur.

Şekil 4.2 ‘da görüldüğü gibi 1965’li yıllara geldiğimizde Lap ve Ivakhnenko’nun derin öğrenme algoritmalarını iyileştirmek için Siberetik Tahmin çalışmalarında, karmaşık denklem hesaplamalarının aktivasyon fonksiyonlarına sahip model çeşitlerini kullanmışlardır [32].

1997’li yıllarda Schmid ve Hochriter tarafından uzun kısa süreli hafıza problemlerinin analiz edilmesi için tekrarlayan bir sinir ağı uygulaması modeli önerilmiştir.

2000’li yıllara geldiğimizde Google 2012’de 16000 işlemciden ve bir milyar üzerinde bağlantıdan oluşan bir yapay desen tanıma algoritmaların performansını kullanılarak, insan düzeyine çıkarmıştır [32]. 2014’te Facebook, sosyal ağda paylaşılan fotoğraflarda insanlara otomatik etiketleme imkânı sağlamak için DeepFaze isimli derin öğren teknolojisini faaliyet geçirmiştir.


Günümüzde giyim ve kozmetik sektöründe fiziksel olarak müşterilerin ürünlerini sanal ortamda deneme imkânı sağlayan çeşitli uygulamalar geliştirilmiştir.



Şekil 4.2. Derin öğrenme tarihçesi

4.2. Evrişimsel Sinir Ağı

Derin öğrenme algoritmalarından biri olan evrişimsel sinir ağı algoritması, dış ortamdan bir görüntü verisini girdi olarak alıp, görüntüdeki pikselleri inceleyerek görünüşleri ve nesneleri ayırt etmektedir [33]. Evrişimsel sinir ağlarının temel amacı görüntülerden oluşan veri kümelerini sınıflandırmak, benzer görüntüleri sınıflandırmak ve canlı ve yapay görüntülerdeki nesneleri tanımdır. Şekil 4.3 de görüldüğü gibi evrişimsel sinir ağları dört temel katmandan oluşmaktadır. Bu dört temel katman kendi alt katmanlarında Havuzlama katmanı, filtre katmanı, doğrusal olmayan katman ve sınıflandırma katmanı gibi üç alt katman daha bulunmaktadır [34].



Şekil 4.3. Derin öğrenme katmanları

4.2.1. Giriş Katmanı

Evrişim sinir ağlarının ilk katmanı olan giriş katmanı, algoritması gereği dışarıdan uygun formatlarda görüntü, hareketli resim ve video girdisi veriler alınır. Görüntü ve video girdisinin çözünürlüğü ve piksel kalitesi oluşturulacak modelin performansını etkilemektedir. Görüntü ve video girdilerinin çözünürlük kalitesi ve kapladığı alan yüksek olması algoritmada kullanılan modelin performansını artırırken, test sürelerini uzatmakta ve arka planda çalışan bellek ihtiyacı da arttırmaktadır. Görüntü ve video girdilerinin çözünürlük kalitesi ve kapladığı alanın düşük olması model performansı olumsuz yönde etkiler iken, test sürelerini kısaltmakta ve arka planda çalışan bellek ihtiyacını azaltmaktadır. Giriş katmanında optimum görüntü ve video kalitesini tespit etmek modelin performansı ve verilerin eğitilmesi için gereken süre bakımından önem arz etmektedir.

4.2.2. Evrişim Katmanı

Evrişim sinir ağlarının temel yapısı oluşturan Evrişim katmanının amacı bir filtre kullanarak görüntü girdisi üzerinde taramalar yaparak analiz için uygun matrisi oluşturmaktır [34]. Matris oluşumunda kullanılan filtreler bir önceki görüntüye göre evrişim işlemi uygulayıp bir sonuç çıktısı oluşturulur ve böylece evrişim katmanında özellik haritası da oluşmaktadır [33]. Evrişim katmanında eğitim sürecindeki bütün filtreler sürekli kendini yenileyerek yeniden öğrenmektedirler. Örneğin 34x34 giriş matrisimizin olduğunu düşünelim. 6x6'lık bir filtre kullanarak görüntü üzerindeki tüm piksel değerlerini tarayacak şekilde kaydırma işlemi uygulanır. 6x6'lık filtredeki kat sayılar her bir piksel'deki renk kanalındaki değerle çarpıp, sonuçlarını toplanarak aktivasyon haritası elde edilmektedir. Matriste kullanacağımız filtre sayesinde görüntü ve video veri setlerinde belli parametreler ile karşılaştırmalar yapılacak görüntüler üzerinden veriler sağlanabilir.

4.2.3. Düzleştirilmiş Doğrusal Birim Katmanı

Evrişim sinir ağlarının düzleştirilmiş doğrusal birim katmanı tüm elemanlarında yaygın olarak kullanılan birim katmanıdır [33]. Bu katman literatürde aktiveleştirme katmanı olarak da bilinmektedir. Düzleştirilmiş doğrusal birim katmanı, evrişim katmanındaki doğrusal olan yapıyı doğrusal olmayan yapıya düzeltirmeyi amaçlamıştır. Böylece algoritmanın öğrenmesi de her zaman daha da hızlanacaktır.

4.2.4. Havuzlama Katmanı

Havuzlama katmanının temel amacı, evrişimsel katmanında yapılan gerekli işlemler sonrasında yapılan bir örnek elde etme yöntemidir [34]. Ayrıca havuzlama katmanında evrişim katmanı için

veri kümelerinin giriş boyutları azaltılmaktadır. Havuzlama katmanında görsel verideki boyutlar azaltıldığı için bilgi kaybına neden olmaktadır. Bilgi kaybındaki eksiklikler sebebiyle kendinden sonraki katman için eksik veriler olduğundan dolayı sistemin eksik öğrenmesine sebep olur. Havuzlama katmanında da evrişim katmanındaki gibi çeşitli filtreler kullanılmaktadır [33]. Bu filtreler sayesinde, maksimum ortaklama ve ortalama ortaklama gibi özel ortalama türleri kullanılmaktadır. Bu ortaklama türünde maksimum havuzlama en iyi sonuç-performans göstergesi elde edilmektedir.

4.2.5. Tam Bağlantılı Katman

Evrişim sinir ağları mimarilerinde giriş katmanı, evrişim katmanı, düzleştirilmiş doğrusal birim katmanı ve havuzlama katmanından sonra son katmandan bir önceki katman olan tam bağlantılı katman gelmektedir [34]. Bu katmanda her bir veri girişinin tüm nöron yapılarına bağlı olduğu bir algoritma üzerinde çalışmaktadır. Tam bağlantılı katmanlar genellikle evrişim sinir ağlarının son adımlarında hesaplanır ve eğitim sonuçlarında göre en uygun performansı seçmek üzere kullanılmaktadır [33].

4.2.6. Sınıflandırma Katmanı


Evrişim sinir ağlarının son katmanı sınıflandırma katmanıdır. Bu katman benzer şekilde derin öğrenme algoritmalarında kullanılmaktadır [33]. Görüntü verisinin eğitim sürecindeki tüm sınıflar, tahmin edilerek ve sınıflandırma yapılarak eşit sayıda bu katmanın sonuç çıktısıdır. Örnek verecek olursa veri setine bağlı olarak 20 farklı nesne üzerinde sınıflandırma yapılacak veya tahmini bulunacaksa sınıflandırma katmanı değeri de 20 olmalıdır. Buna bağlı olarak bağlantı katmanının çıkış değeri de 20 olacaktır. Sınıflandırma katmanında softmax, Alexnet, Resnet ve inception v3 gibi sınıflandırıcı mimarılar kullanılmaktadır.

5. MATERYAL VE METOT

5.1. Kullanılan Derin Öğrenme Mimarileri

5.1.1. Alexnet Mimarisi

Alexnet, ilk kez 2012 yılında Krizhevsky ve Hinton tarafından önerildi. Alexnet ağ modeli, önerildiği dönemde büyük ölçekli görsel tanıma zorluğunun (ILSVRC) görüntü sınıflandırma yarışmasının şampiyonluğunu kazandı. Model yapısı, şekil 5.1’de gösterildiği gibi giriş katmanı hariç, üst ve alt dallar dahil olmak üzere toplam 8 katmandan oluşmaktadır [35].



Şekil 5.1. Alexnet Modeli [37]

Alexnet, CNN ağlarından biri olan ve giriş katmanı, evrişim katmanı, normalizasyon katmanı, maksimum havuzlama katmanı ve çıkış katmanı gibi 10 katmandan oluşan bir ileri yayılma ağına dayanmaktadır. Toplamda, 8 evrişim katmanı vardır. Havuzlama katmanları da dahil olmak üzere ilk 5 katman evrişim katmanıdır ve son 3 katman tam bağlantı katmanıdır [35].


Alexnet, 60 milyon parametre ve 650.000 nöron içeren büyük bir ağ yapısıdır [36]. Çıktıda beş evrişim katmanı, iki normalizasyon katmanı, üç maksimum havuzlama katmanı, üç tam bağlı katman ve çıktıda Softmax aktivasyonlu doğrusal bir katman bulunur. Ayrıca, evrişim katmanlarının aktivasyonu için (ReLU’lar) uygular [37].

5.1.2. Resnet Mimarisi

Derin CNN modellerinin eğitimindeki zorlukları aşmak için 2015 yılında K. He ve ark. Resnet modelini önerdiler. Resnet modeli, sıradan CNN’ye dayalı kimlik eşlemeleri tasarlayarak derin sinir ağlarının eğitim zorluğunu azaltır. Hataların geriye yayılmasını kolaylaştırır ve model parametrelerini optimize eder. Hedef konumlandırma, görüntü tanıma, vb. gibi bilgisayarlı görme ile ilgili görevlerde iyi sonuçlar elde etti.

Aslında Resnet modeli, temelinde yatan CNN modelinin yükseltilmiş bir versiyonudur. Temelde bir giriş katmanı, bir dizi evrişim katmanı (Conv), toplu normalleştirme (BN), kimlik eşlemeleri ve genel ortalama havuzlama, tam bağlantılı bir çıktı katmanı vb. katmanlardan oluşur. Standart evrişim modülüne benzer şekilde, Resnet’de temel artık bloklara sahiptir.

Esasen Resnet modeli, rüzgâr türbini dişli kutusunun arıza teşhisi için bu yazıda kullanılan temel yöntem olan CNN modelinin yükseltilmiş bir versiyonudur. Genellikle bir giriş katmanı, bir dizi evrişim katmanı (Conv), toplu normalleştirme (BN), kimlik eşlemeleri ve genel ortalama havuzlama, tam bağlantılı bir çıktı katmanı vb. dahil olmak üzere önemli temel bloklardan oluşur. Standart evrişim modülüne benzer şekilde, Resnet de temel artık bloklara sahiptir. Bu blok Şekil 5.2’de gösterildiği gibi, ana işlem yolunun “BN → ReLU → Conv → BN → ReLU → Conv” olduğu ve daha sonra çapraz katman yoluna eklendiği ortak bir temel artık bloktur.




Şekil 5.2. Resnet Modeli [39]

5.1.3. Inceptionv3 mimarisi

2015 yılında, araştırmacılar önceki katmandaki özellik haritalarına paralel olarak çoklu evrişim veya havuzlama işlemleri gerçekleştiren ve ardından tüm çıktıları daha büyük bir özellik haritası olacak şekilde birleştiren Inceptionv3 adlı yeni bir modüle sahip bir CNN yapısı önerdi [38].

InceptionV3 Şekil 5.3'te gösterildiği gibi InceptionV3 modülü I (IM I), InceptionV3 modülü II (IM II) ve InceptionV3 modülü III (IM III) olmak üzere üç çekirdek modülüne sahiptir. IM I, IM II ve IM III aynı çalışma prensibine sahiptir, yani daha az hesaplama maliyetine yol açarken ağın derinliğini ve genişliğini artırır. Üç modülde, $n \times n$ evrişim çekirdeği, ağ parametrelerini büyük ölçüde azaltan ve algılama hızını önemli ölçüde artıran $1 \times n$ ve $n \times 1$ olmak üzere iki evrişim çekirdeğine bölünmüştür. Üç modülün son katmanı, bir LRN (Local Response Normalization) katmanı ve bir Depthconcat katmanından oluşan Filter concat katmanıdır, burada Depthconcat katmanı, evrişim katmanları tarafından çıkarılan özellikleri birleştirir. Son olarak, InceptionV3, tamamen bağlı bir katmandan önce ortalama bir havuzlama katmanı ve bir bırakma katmanı kullanır ve kaybolan gradyan problemini önlemek için ileriye doğru yayılma için bir softmax katmanı ekler. Her evrişim katmanının doğrusal olup olmadığını bir BN katmanı ve bir ReLU takip eder [39].




Şekil 5.3. InceptionV3 ve üç temel parçasının şeması [39]

5.2. Kullanılan Sınıflandırıcılar

5.2.1. Destek Vektör Makineleri (SVM-Support Vector Machine)

Destek Vektör Makineleri (SVM), Alexey ya Chervonenkis ve Vladimir N. Vapnik tarafından 1963 yılında oluşturulmuştur. Destek Vektör Makinelerinin ortaya çıkmasından bu yana, bu teknik görüntü, metin ayırma ve sınıflandırmada kullanım için yaygın olarak benimsenmiştir. Bu algoritmalar oldukça gelişmiştir ve biyolojik laboratuvarlarda protein sınıflandırmasının yanı sıra el yazısı metinler için kullanılabilir. Kendi kendini süren arabalar, sohbet robotları, yüz tanıma vb.

gibi diğer birçok alanda kullanılırlar. Oldukça yaygın olan denetimli tip öğrenme algoritmalarından biri olan Destek Vektör Makinesi algoritması, regresyon ve sınıflandırma sorunları için tasarlanmıştır. SVM algoritması, n boyutlu uzayı çeşitli sınıflara ayıran ve uygun kategoride farklı bir noktayı yerleştirmeyi kolaylaştıran hiper düzlem olarak bilinen en uygun karar limitini veya sınırını oluşturmayı amaçlar. SVM algoritmasında, uygun bir hiper düzlem oluşturmaya yardımcı olan Destek Vektörleri adı verilen uç vektör noktaları seçilir. SVM algoritması, yüzlerin tespiti, bazı görüntülerin sınıflandırılması, metinlerin sınıflandırılması, vb. 'de uygulanır. Şekil 5.4'te bir örnek gösterilmektedir, burada iki zıt kategori SVM algoritması kullanılarak sınıflandırılmaktadır. Örneğin, bir kişi, bir köpeğe benzer bazı özelliklere sahip garip bir kedinin görüntüsüne rastlar. Bu nedenle, köpek mi yoksa kedi mi olduğunu kesin olarak tanımlayan bir model oluşturmak için SVM algoritması oldukça faydalıdır [40].



Şekil 5.4. SVM'de Bir Karar Sınırının Gösterimi [38]

5.2.2. SVM Türleri

Doğrusal SVM algoritması, verilerin doğrusal bir şekilde ayrılmasının gerektiği durumlarda yararlıdır; bu, veri kümesinin tek bir düz çizgi ile ayrılmış iki sınıfa bölünebileceği anlamına gelir [40].

Doğrusal olmayan SVM algoritması, verilerin doğrusal olmayan bir şekilde ayrılacağı durumlarda yararlıdır; bu, veri kümesinin düz bir çizgi kullanılarak sınıflara bölünemeyeceği anlamına gelir [40].

5.2.3. SVM Algoritmasında Hiper Düzlem ve Destek Vektörleri


SVM algoritmasının hiper düzlemi, sınıfları n boyutlu uzayda doğru bir şekilde sınıflandıran çeşitli olası karar sınırlarından mümkün olan en iyi karar sınırı olarak tanımlanır. Veri kümesinin özellikleri, hiper düzlemin boyutlarını belirler, yani bir veri kümesinin 2 özelliği varsa, tek boyutlu bir hiper düzlemi ifade ederken, 3 özellik iki boyutlu bir hiper düzlemi ifade eder. İki veri noktası arasındaki mesafenin maksimum olduğu anlamına gelen maksimum marjlara sahip bir hiper düzlem tercih edilir [40].

Destek vektörleri, hiper düzlemin konumunu etkileyen en yakın veri işaretçileridir. Hiper düzlemi destekleyen bir yapıya sahip oldukları için destek vektörleri olarak adlandırılırlar [40].

5.2.4. SVM Algoritması Çalışma Prensibi

5.2.5. Doğrusal SVM


SVM algoritması çalışma modeli bir örnek ile göstermek gerekirse, iki farklı nesneye (kırmızı ve sarı) ve X_1 ve X_2 'nin tahsis edildiği iki özelliğe sahip bir veri seti düşünün. Koordinat çiftini (X_1 , X_2) kırmızı veya sarı olarak doğru bir şekilde ayırabilen bir sınıflandırma algoritması istenir. 2 boyutlu bir uzay olduğu ve iki özelliğe sahip olduğu için, iki kategoriyi sadece bir düz çizgi ile ayırmak oldukça kolaydır, ancak bu tür birçok düz çizgi mümkündür. İşte tüm olası satırlar veya karar sınırlarından en uygun karar sınırını bulan bu algoritmanın rolü geliyor; bu en uygun karar sınırına hiper düzlem denir. SVM algoritması, destek vektörlerini, yani her iki sınıf içindeki karar sınırından en yakın noktaları bulur. SVM algoritması, optimal bir çözüm döndürmek için hiper düzlem ve vektörler arasındaki mesafeyi en üst düzeye çıkarır. Şekil 5.5'te SVM algoritmasının uygulanma prensibi gösterilmiştir [40].



Şekil 5.5. SVM Uygulanma Prensibi [10]

5.2.6. Doğrusal Olmayan SVM

Kullanılan veriler doğrusal olmayan bir şekilde düzenlenmiş ise burada sadece tek bir düz çizgi çizilemez. Bu nedenle, bu veri noktalarını ayırmak için ek bir boyuta ihtiyaç vardır. Doğrusal olarak düzenlenmiş veriler için sadece iki boyut kullanılmıştır, yani x ve y , ancak doğrusal olmayan bir şekilde düzenlenmiş veriler için ek bir üçüncü boyut, yani geometrik formül ($z = x^2 + y^2$) kullanılarak basitçe hesaplanabilen bir z değeri gereklidir. İş 3 boyutlu bir uzay içerdiğinden, x eksenine paralel bir düzlemi andırıyor. $Z = 1$ olan 2 boyutlu bir uzaya dönüştürüldüğünde, Şekil 5.6'da gösterildiği gibi yarıçapı 1 birim olan bir daire elde edilir [40].



Şekil 5.6. 3 Boyutlu Düzenleme [37]

5.2.7. SVM Algoritması Avantajları

- SVM algoritması, sınıflar arasında net bir bölünmenin olduğu durumlarda kullanılabilecek en uygun algoritmadır.
- SVM, daha yüksek boyutlu uzaylar söz konusu olduğunda daha fazla verimlilik gösterir.
- SVM, boyutsal boşlukların sayısının örnek değerlerin miktarını aştığı durumlarda da etkin bir şekilde çalışır.
- SVM, oldukça arzu edilen bir özellik olan bellek açısından nispeten verimlidir [40].

5.2.8. SVM Algoritması Avantajları

- SVM algoritması, büyük boyutlu veri kümeleri için uygun şekilde çalışmaz.
- SVM, veri kümesinin çok büyük miktarda gürültü içerdiği, yani pratik olarak çok sık olan örtüşen hedef sınıfları içerdiği durumlarda verimli bir şekilde çalışmaz.
- SVM, her bir veri noktasının özelliklerinin sayısal değerinin eğitim veri örneklerinden daha yüksek olduğu durumlarda çalışır [40].

5.2.9. K-En Yakın Komşuluk (K-Nearest Neighbor/KNN)

Veri ayrımı için en temel ve etkili algoritmalarından biri olan K-NN, özellikle veriler oldukça belirsiz olduğunda, uygulama için birincil seçenek haline gelebilir. Bu algoritma 1951'de Evelyn Fix ve Joseph Hodges tarafından parametrik tahminle olasılık yoğunluklarına karar vermenin nispeten zor olduğu durumlarda diskriminant incelemesi için geliştirildi. Ayrıca 1967 yılında, bu algoritmaya ait birkaç özellik hesaplandı, örneğin 'k' = 1 ve 'n'nin sonsuz olma eğiliminde olduğu durumlarda,

KNN sınıflandırma yanlışlığı veya hatası, Bayes'in hata oranının iki katı ile sınırlandırılır. Bu tür belirli özelliklerin ve özelliklerin oluşturulmasından sonra, yeni reddetme yaklaşımlarını, Bayes hata oranındaki iyileştirmeleri, yumuşak hesaplama için yalnızca mesafe yöntemlerine dayanan prosedürleri ve diğer yaklaşımları saymak için uzun süreler boyunca araştırma ve deneyler yapıldı. K-NN algoritması, denetimli tip öğrenme tekniği altında konumlandırılmıştır ve Makine Öğreniminde kullanımı en kolay algoritmalarından biri olarak kabul edilir. Hem sınıflandırma hem de regresyon için uygun olmasına rağmen, ağırlıklı olarak nesneleri sınıflandırmak için kullanılır. Herhangi bir eksik değeri atamak ve verileri yeniden örneklemek için kullanılan son derece kullanışlı bir algoritmadır. Belirli bir veri kümesi için, bu algoritma görünmeyen veriler ile hali hazırda var olan veriler arasındaki bağlantıyı tahmin eder ve bu tahmine dayanarak yeni verileri onunla en iyi eşleşen geçerli bir kategoriye atar. Bu nedenle, taze veriler K-NN algoritması tarafından sınıflandırılabilmesi büyük ölçüde mümkündür [40].

KNN aynı zamanda tembel öğrenen algoritması olarak da adlandırılabilir. Çünkü veri seti yalnızca başlangıçta depolanır, ancak eğitim veri setinin öğrenme süreci, yeni veri setinin sınıflandırılması veya tahmini için bir talep olana kadar gerçekleşmez. Ayrıca K-NN algoritması parametrik değildir, yani girdi ve çıktı arasındaki ilişkinin önceden belirlenmiş herhangi bir yöntemi veya biçimi yoktur. K-NN, kullanılan veri seti etiketlendiğinde ve gürültüsüz olduğunda sınıflandırma için kullanılabilir [40].


5.2.10. K-NN Algoritmasının Çalışma Prensibi

K-NN algoritmasının ismindeki 'K', yeni veri noktasının komşularının sayısını ifade eder. Bu algortmada en önemli süreç K için uygun bir değere karar vermektir. Daha iyi doğruluk için, K'nin doğru değerinin seçilmesi zorunludur ve bu işleme parametre ayarlama denir. 1 veya 2 gibi çok düşük bir K değeri, gürültülü sonuçlara yol açabilirken, çok yüksek bir değer, veri setine bağlı olarak zaman zaman karışıklık yaratabilir. K için sabit bir değer yoktur. Fakat K'nin sıklıkla varsayılan değer olarak '5' alınır. Yani çoğunluk oylama işlemi için yeni veri noktasına en yakın 5 komşu dikkate alınır. İki veri kümesi sınıfı arasındaki hataları ve karışıklığı önlemek için genellikle tek bir K değeri uygundur. K değerinin hesaplanabilmesi için aşağıdaki formül uygulanabilir.

$$K = \sqrt{n} \quad (1)$$

Burada n veri noktalarının toplamıdır.

K değerinin hesaplanmasının ardından veri setinde hâkim olan noktaların yeni veri noktasından Öklid tipi uzaklığı hesaplanır. Bunun için veri setinin grafiksel olarak çizilmesi zorunludur. Öklid mesafesi, Şekil 5.7'te gösterildiği gibi hesaplanır [40].



Şekil 5.7. Öklid Mesafesinin Hesaplanması [29]

Yeni veri noktasından tüm noktaların Öklid uzaklıklarının değerleri hesaplandıktan sonra, en yakın komşuların çoğunluğunun ait olduğu kategori gözlemlenmeli ve bu nedenle dikkatli bir hesaplamadan sonra bu sınıf, sınıflandırma için atanan veri noktasına atanmalıdır. Şekil 5.8'teki gibi, bu kategoriden en yakın 3 (çoğunluk) komşusu olduğundan, noktanın A sınıfına gittiği sonucuna varılabilir [40].



Şekil 5.8. Komşulara göre yeni veri noktasının sınıflandırılması [29]

5.2.11. K-NN Algoritmasının Avantajları

- K-NN algoritması, problemlere uygulanması kolay bir algoritmadır.
- K-NN algoritması, eğitim için kullanılan veri setinde hâkim olan gürültüye karşı toleranslı ve dayanıklıdır.
- Veri seti fazlasıyla büyük olsa bile hızlı, kolay yorumlanabilir ve etkilidir.

5.2.12. K-NN Algoritmasının Dezavantajları

- K için uygun bir değere karar vermek karmaşıktır. Çünkü bazen sonuçları büyük ölçüde değiştirir.
- Eğitim için kullanılan veri kümesine ait her bir veri noktası arasındaki Öklid tipi uzaklığın hesaplanması gerektiğinden; yüksek hesaplama maliyetine yol açar.

5.3. Veri Seti ve Özellikleri


Çalışma kapsamında kullanılan veri seti kaggle’ dan elde edilmiştir. Çalışmada toplamda 4 kategoriden oluşan 836 görüntü kullanılmıştır. Veri setinde 198 içerisinde araba bulunan termal kamera görüntüsü, 100 içerisinde ev bulunan termal kamera görüntüsü, 204 içerisinde çeşitli hayvan bulunan termal kamera görüntüsü, 334 içerisinde insan bulunan termal kamera görüntüsü bulunmaktadır. Şekil 5.9’da çalışmada kullanılan veri setindeki her bir sınıfın ikişer örnek görüntüsü verilmiştir.



Şekil 5.9. Veri setindeki termal kamera görüntü örnekleri

Yapılan tüm çalışmalar, Intel Core i7 2.70 GHz işlemci, 12GB DDR4 RAM, 2GB NVIDIA ekran kartına sahip bilgisayarda gerçekleştirilmiştir. Tüm çalışmalar, 64 bitlik Windows 10 işletimi üzerinde kurulu Matlab R2021a üzerinde derlenmiştir. Kullanılan yöntemlerdeki tüm parametreler aynı değerlerle uygulanmıştır. Veri tabanını %70 eğitim ve %30 test için ayıran holdout metodu kullanılmıştır.

Çalışmada kullanılan Alexnet, Resnet101 ve Inceptionv3 derin öğrenme mimarileri ile makine öğrenme tekniklerinden (KNN, SVM) oluşturulan hibrit modellerin yapısı Şekil 5.10' da verilmiştir.



Şekil 5.10. Kullanılan mimarilerin akış diyagramı

Veriler üzerinde kullanılan derin öğrenme mimarilerinin genel yapısı korunmuştur. Alexnet mimarisinde tam bağlantı katmanı aşamasında fc8 katmanında elde edilen 1000 adet özneliğin KNN ve SVM yöntemleri ile sınıflandırılması gerçekleştirilmiştir. Alexnet mimarisinde tam bağlantı katmanı aşamasında fc8 katmanında elde edilen 1000 adet özneliğin KNN ve SVM yöntemleri ile sınıflandırılması gerçekleştirilmiştir. Resnet101 mimarisinde tam bağlantı katmanı aşamasında fc1000 katmanında elde edilen 1000 adet özneliğin KNN ve SVM yöntemleri ile sınıflandırılması gerçekleştirilmiştir. Inceptionv3mimarisinde tam bağlantı katmanı aşamasında predictions katmanında elde edilen 1000 adet özneliğin KNN ve SVM yöntemleri ile sınıflandırılması gerçekleştirilmiştir. Tüm bu sınıflandırmalardan elde edilen sonuçlara 6. Bölümde yer verilmiştir.

5.4. Kullanılan Model Performans Değerlendirme Yöntemi ve Ölçütleri

Makine öğrenmesi; "Eğer bir bilgisayar programının G görevlerinde P ile ölçülen performansı, deneyim D ile artıyorsa, o bilgisayar programının bazı G görevlerinin sınıflarına ve performans ölçüsü P'ye göre deneyim D'den öğrendiği söylenmektedir" biçiminde açıklanabilir. Bu tanımlı daha anlaşılabilir kılmak adına, tanımlı örnekler yardımı ile somut hale getirelim. Bunun için öncelikle X Sigortacılık Şirketi'ni ele alalım. Şirket, otomobili için kasko sigortası yaptırmak isteyen bir müşterinin öncelikle risk grubunu tespit etmekte ve buna göre sigorta primini belirlemektedir. Çalışanlar gelen her yeni müşterinin risk grubunu tespit edebilmek için müşteriye ve otomobile ait birtakım özellikleri değerlendirmek ve buna göre karar vermek zorundadır. Söz konusu karar verme işinin bir makine tarafından gerçekleştirilmesi istendiğinde, makinenin G Görevi müşteri risk

grubunun belirlenmesi, D Deneyimi müşteri ve ilgili müşterinin otomobiline ait özelliklerin bulunduğu veri tabanı, P Performansı ise doğru sınıflandırılan müşteri grubu yüzdesi olabilir. Makinenin, kendisine deneyim olarak verilen veri setini kullanarak öğrenmeyi sağlayabilmesi, bu amaçla geliştirilmiş ve problem tipine uygun çeşitli algoritmalar yardımı ile sağlanmaktadır. Sonuçta elde edilen performansa göre makinenin öğrenip öğrenmediği ortaya çıkmaktadır. Eğer performans yüksekse, yeni bir müşteri için makinenin doğru çıktı (risk grubu) üretmesi mümkün olacaktır. Performansın düşük olması durumunda ise makine öğrenmesini etkileyen faktörlerde değişiklik yapılarak performansın optimize edilmesi sağlanacaktır.

Makine öğrenmesini etkileyen faktörlerden ilki makineye deneyim olarak sunulan veri setidir (Şekil 9). Tıpkı insanlarda olduğu gibi deneyim ne kadar fazla ve farklı olası durumları içeriyorsa, öğrenmeye o kadar pozitif yönde katkı sağlayacaktır. Örneğin, köyde ve büyükşehirde görev yapan iki doktorun elde edeceği bir aylık deneyimi göz önüne alalım. Köy ve büyükşehir birbiriyle kıyaslandığında hem nüfus yoğunluğu bakımından hem de karşılaşılabilecek hastalık çeşitliliği bakımından, büyükşehir köyden daha öndedir. Bu nedenle, büyükşehirde görev yapan bir doktorun muayene ettiği hasta sayısı ve incelediği vaka sayısının, köyde görev yapan bir doktora göre daha fazla olması beklenecektir. Aynı bakış açısı ile bir ayda büyükşehirdeki doktorun elde edeceği deneyim köydekinden fazla olacaktır. Dolayısıyla yalnızca bir ayın sonunda her iki doktordan yeni bir hasta için hastalık teşhis yapması istendiğinde hem çok sayıda hem de farklı hastalıklara sahip hastalardan elde ettiği deneyim sayesinde büyükşehirdeki doktorun daha kolay teşhisi gerçekleştireceği söylenebilir. Makine öğrenmesinde de probleme ilişkin toplanan veri setinin önemi benzer biçimdedir. Örneğin, makinenin A ve B gibi iki gazoz türü içinden sınıflandırma yapması beklensin ve bu sınıflandırma işlemi için makineye az sayıda ve yalnızca A tipinde gazozun bulunduğu örnekler sunulsun. Bu durumda, makine hem yeteri kadar örneğin bulunmaması hem de B tipindeki gazoz hakkında herhangi bir bilgisinin bulunmaması nedeniyle doğru ve güvenilir bir sınıflandırma yapamayacaktır. Dolayısıyla elde edilen performans da düşük olacaktır.

İkinci faktör veri setinde sonuca etkisi olduğu düşünülen değişkenlerin bulundurulmasıdır. Bir öğrencinin bağıl not hesabı yapılırken hem "final notu" hem de "final notunun iki katının birlikte değerlendirmeye alınması ne kadar anlamsızsa; öğrencinin sınıfı geçip geçemeyeceğini makine öğrenmesi ile araştırırken de bu iki değeri bir arada ele almak yararsız olacaktır. Bir tenis maçının oynanıp oynanmayacağını tahmin edebilmek için havanın ısı, nem, rüzgâr gibi özelliklerine bakılırken, bir hastanın ölüm riskinin belirlenmesi için yaş cinsiyet, sigara/alkol kullanıp kullanmadığı bilgisi birer özellik olarak dikkate alınmaktadır. Makine öğrenmesi çalışmalarında bu özellikler nitelik olarak adlandırılmaktadır. Bazı problemlerde, birbiriyle yüksek ilişkili ya da çözüme katkısının çok az olduğu tespit edilen nitelikler elenebilmektedir. Üçüncü faktör, seçilen öğrenme stratejisidir. Öğrenme stratejisi hem makinenin öğrenmesi istenilen görevle hem de bunun

için gerekli veri setiyle yakından ilişkilidir. Çünkü makine öğrenmesi bazı problemlerin çözümü için veri setinde çıktı değerlerine ihtiyaç duyarken, bazılarında bu değerlere ihtiyaç duymaz. Çıktı değeri, çalışmalarda hedef nitelik olarak adlandırılmaktadır.

Örnek çıktılar:

- Tenis maçının oynanıp oynanmayacağı ile ilgili tahmin yapılırken tenis maçlarının oynanıp oynanmaması (Evet/Hayır),
- Kanser hastalığının teşhisinde hastaların kanserli olup olmama durumu (Evet/Hayır),
- Bir bankanın kredi konusunda müşterilerini risk gruplarına göre sınıflandırırken müşterilerin risk grupları (Düşük/Orta/Yüksek),
- Bir projeye ait maliyet tahmini yapılırken kategorik olarak sıralanmış projelerin maliyeti hedef niteliklidir.

Örnekler incelendiğinde, hedef niteliğe ihtiyaç duyulan problemlerin daha çok tahmin ve sınıflandırma problemleri üzerine olduğu görülebilir. Dolayısıyla, makine öğrenmesinde ele alınacak probleme göre öğrenme stratejisinin belirlenmesi ve yine bu stratejiye uygun veri setinin temin edilmesi önemlidir.

Dördüncü faktör ise öğrenme için kullanılan algoritma ve varsa algoritmaya ait parametrelerdir. Algoritma, verilen bir problemin çözümü için adım adım izlenmesi gereken yol şeklinde ifade edilebilir. Makinenin de elbette sahip olduğu veri setini göz önünde bulundurarak öğrenebilmesi için gereken birtakım adımlar mevcuttur. Literatürde bu amaçla geliştirilmiş olan pek çok algoritma mevcuttur. k-En Yakın Komşu (k-NN), k-Ortalamlar (k-means) gibi algoritmalar analiz öncesinde k sayılarını parametre olarak gerektirirken, Basit (Naif) Bayes Sınıflandırıcısı analiz için herhangi bir parametreye ihtiyaç duyulmamaktadır.

Makine öğrenmesi için veri seti ve algoritma temelinde model/modeller kurulmakta, en yüksek performansın elde edildiği modelin kullanılması tercih edilmektedir. Tüm modellerin yer aldığı küme $M = \{M_1, M_2, \dots, M_n\}$ ile gösterilsin. M kümesinde aynı öğrenme modeli farklı biçimlerde denenebileceği gibi, farklı öğrenme modelleri de bir arada kullanılabilir.

Örneğin:

M1: k — En Yakın Komşu Algoritması (k=5) ,M2: k — En Yakın Komşu Algoritması (k=7) ,M3: Basit (Naive) Bayes Sınıflandırıcısı, M4: Yapay Sinir Ağları,Makine öğrenmesi için geliştirilen algoritmalar bilgisayarlara kolaylıkla aktarılabilindiğinden makine, basitçe günlük hayatta sıklıkla kullandığımız bilgisayarlar olarak düşünülebilir. Performansı yüksek bir modelin bilgisayar programları ile farklı donanımlara aktarılması kolaylıkla sağlanmaktadır. Makine öğrenmesi alanı aşağıda verilen üç temel araştırma üzerine kurulmuştur:

Bir modelin performansı, kullanılan öğrenme algoritmasının yanı sıra sınıf dağılımı, hatalı sınıflandırma ya da eğitim ve test kümelerinin büyüklüğüne bağlı olabilir. Model performans

değerlendirme yöntemleri bir bakıma mevcut veri setinde örneklemenin nasıl yapılacağını göstermektedir. Eğitim ve test kümeleri için literatürdeki karşılaşılan bazı örnekleme yöntemler: Holdout: Holdout (dışarıda tutma), veri setinin eğitim ve test olmak üzere iki parçaya ayrıldığı yöntemdir. Test setinde kullanılan veri eğitim setinin dışındaki verilerden oluşmaktadır. Eğitim veri seti ile öğrenme sağlanmakta, test veri seti ile de öğrenmenin ne kadar gerçekleştiği kontrol edilmekte ve böylece model performansı elde edilmektedir. Eğer modelde kullanılan algoritmaya ait parametreler varsa, parametrelerin düzenlenmesi eğitim veri seti ile gerçekleştirilir. Bu yöntemin iki temel dezavantajı vardır: İlki veri setindeki gözlem sayısının az olması durumunda, test veri seti için yeteri kadar örneğin ayrılamayacak olması, ikincisi ise veri setinin eğitim ve test veri seti olarak sadece bir defaya mahsus ayrılmış olması ve elde edilen performansa da bu ayrım nedeni ile yeterince güvenilememesidir.

Tekrarlı Holdout: Kısaca Holdout yönteminin birkaç defa tekrarlanmasıdır. Bu yöntemde seçim işlemi her ne kadar rastgele yapılsa da seçilmiş farklı test veri setleri üst üste binebileceğinden tekrarlı Holdout yöntemi elverişli görülmemektedir.

6. SONUÇLAR

6.1. Alexnet Mimarisinin Eğitimi ve Testi

Termal kamera görüntülerinin Alexnet mimarisi ile öznitelikleri çıkartılmıştır. Elde edilen öznitelikler KNN ve SVM yöntemleri ile sınıflandırılmıştır. Sonuçlar Tablo 6.1 ve Tablo 6.2 'de verilmiştir.

Tablo 6.1. Alexnet + KNN yönteminin karmaşıklık matrisi

Çıkış Sınıfı	Araba	52 20.6%	4 1.6%	2 0.8%	2 0.8%	86.7% 13.3%
	Ev	2 0.8%	24 9.5%	0 0.0%	0 0.0%	92.3% 7.7%
	Hayvan	0 0.0%	2 0.8%	54 21.4%	6 2.4%	87.1% 12.9%
	İnsan	6 2.4%	0 0.0%	6 2.4%	92 36.5%	88.5% 11.5%
		86.7% 13.3%	80.0% 20.0%	87.1% 12.9%	92.0 % 8.0 %	88.1% 11.9%
		Araba	Ev	Hayvan	İnsan	
		Hedef Sınıfı				

Alexnet + KNN yönteminde sistemin başarımları %88,1 bulunmuştur. Sistemin eğitim ve test süresi toplam 0.091 saniye sürmüştür. Sistemde tamamının doğru tespit edildiği sınıf bulunmamakla birlikte en yüksek %92,3 ile ev görüntülerinde doğru tahmin gerçekleşmiştir. En çok hatalı sınıflandırmayı araba görüntülerinde gerçekleşmiştir.

Tablo 6.2. Alexnet + SVM yönteminin karmaşıklık matrisi

Çıkış Sınıfı	Araba	48 19.0%	4 1.6%	2 0.8%	6 2.4%	80.0% 20.0%
	Ev	2 0.8%	20 7.9%	0 0.0%	0 0.0%	90.9% 9.1%
	Hayvan	2 0.8%	2 0.8%	56 22.2%	6 2.4%	84.8% 15.2%
	İnsan	8 3.2%	4 1.6%	4 1.6%	88 34.9%	84.6% 15.4%
		80.0% 20.0%	66.7% 33.3%	90.3% 9.7%	88.0 % 12.0 %	84.1% 15.9%
		Araba	Ev	Hayvan	İnsan	
		Hedef Sınıfı				

Alexnet + SVM yönteminde sistemin başarımı %84,1 bulunmuştur. Sistemin eğitim ve test süresi toplam 0.086 saniye sürmüştür. Sistemde tamamının doğru tespit edildiği sınıf bulunmamakla birlikte en yüksek %90,9 ile ev görüntülerinde doğru tahmin gerçekleşmiştir. En çok hatalı sınıflandırma araba görüntülerinde gerçekleşmiştir.

6.2. Resnet101 Mimarisinin Eğitimi ve Testi

Termal kamera görüntülerinin Resnet101 mimarisi ile öznitelikleri çıkartılmıştır. Elde edilen öznitelikler KNN ve SVM yöntemleri ile sınıflandırılmıştır. Sonuçlar Tablo 6.3 ve Tablo 6.4 'de verilmiştir.

Tablo 6.3. Resnet101 + KNN yönteminin karmaşıklık matrisi

Çıkış Sınıfı	Araba	50 19.8%	6 2.4%	0 0.0%	0 0.0%	89.3% 10.7%
	Ev	6 2.4%	20 7.9%	4 1.6%	2 0.8%	62.5% 37.5%
	Hayvan	2 0.8%	2 0.8%	52 20.6%	0 0.0%	92.9% 7.1%
	İnsan	2 0.8%	2 0.8%	6 2.4%	98 38.9%	90.7% 9.3%
		83.3% 16.7%	66.7% 33.3%	83.9% 16.1%	98.0 % 2.0 %	87.3% 12.7%
		Araba	Ev	Hayvan	İnsan	
		Hedef Sınıfı				

Resnet101 + KNN yönteminde sistemin başarımı %87,3 bulunmuştur. Sistemin eğitim ve test süresi toplam 0,12 saniye sürmüştür. Sistemde tamamının doğru tespit edildiği sınıf bulunmamakla birlikte en yüksek %92,9 ile hayvan görüntülerinde doğru tahmin gerçekleşmiştir. En çok hatalı sınıflandırma ev görüntülerinde gerçekleşmiştir.

Tablo 6.4. Resnet101 + SVM yönteminin karmaşıklık matrisi

Çıkış Sınıfı	Araba	56 22.2%	6 2.4%	2 0.8%	0 0.0%	87.5% 12.5%
	Ev	0 0.0%	24 9.5%	0 0.0%	0 0.0%	100% 0.0%
	Hayvan	0 0.0%	0 0.0%	54 21.4%	4 1.6%	93.1% 6.9%
	İnsan	4 1.6%	0 0.0%	6 2.4%	96 38.1%	90.6% 9.4%
		93.3% 6.7%	80.0% 20.0%	87.1% 12.9%	96.0 % 4.0 %	91.3% 8.7%
		Araba	Ev	Hayvan	İnsan	
		Hedef Sınıfı				

Resnet101 + SVM yönteminde sistemin başarımı %91,3 bulunmuştur. Sistemin eğitim ve test süresi toplam 0.376 saniye sürmüştür. Sistemdeki ev görüntülerinin tamamı doğru tespit edilmiştir. Bununla birlikte en çok hatalı sınıflandırma araba görüntülerinde gerçekleşmiştir.

6.3. Inceptionv3 mimarisinin eğitimi ve testi

Termal kamera görüntülerinin Inceptionv3 mimarisi ile öznetelikleri çıkartılmıştır. Elde edilen öznetelikler KNN ve SVM yöntemleri ile sınıflandırılmıştır. Sonuçlar Tablo 6.5 ve Tablo 6.6 'de verilmiştir.

Tablo 6.5. Inceptionv3 + KNN yönteminin karmaşıklık matrisi

Çıkış Sınıfı	Araba	48 19.0%	2 0.8%	0 0.0%	2 0.8%	92.3% 7.7%
	Ev	4 1.6%	28 11.1%	0 0.0%	8 3.2%	70.0% 30.0%
	Hayvan	0 0.0%	0 0.0%	48 19.0%	6 2.4%	88.9% 11.1%
	İnsan	8 3.2%	0 0.0%	6 5.6%	84 33.3%	79.2% 20.8%
		80.0% 20.0%	93.3% 6.7%	77.4% 22.6%	84.0 % 16.0 %	82.5% 17.5%
		Araba	Ev	Hayvan	İnsan	
		Hedef Sınıfı				

Inceptionv3 + KNN yönteminde sistemin başarımı %82,5 bulunmuştur. Sistemin eğitim ve test süresi toplam 0.754 saniye sürmüştür. Sistemde tamamının doğru tespit edildiği sınıf

bulunmamakla birlikte en yüksek %92,3 ile araba görüntülerinde doğru tahmin gerçekleşmiştir. En çok hatalı sınıflandırma ev görüntülerinde gerçekleşmiştir.

Tablo 6.6. Inceptionv3 + SVM yönteminin karmaşıklık matrisi

Çıkış Sınıfı	Araba	54 21.4%	2 0.8%	2 0.8%	4 1.6%	87.1% 12.9%
	Ev	0 0.0%	24 9.5%	0 0.0%	0 0.0%	100% 0.0%
	Hayvan	0 0.0%	0 0.0%	56 22.2%	6 2.4%	90.3% 9.7%
	İnsan	6 2.4%	4 1.6%	4 1.6%	90 35.7%	86.5% 13.5%
		90.0% 10.0%	80.0% 20.0%	90.3% 9.7%	90.0 % 10.0 %	88.9% 11.1%
		Araba	Ev	Hayvan	İnsan	
Hedef Sınıfı						

Inceptionv3 + SVM yönteminde sistemin başarımları %81,3 bulunmuştur. Sistemin eğitim ve test süresi toplam 0.376 saniye sürmüştür. Sistemdeki ev görüntülerinin tamamı doğru tespit edilmiştir. Bununla birlikte en çok hatalı sınıflandırma insan görüntülerinde gerçekleşmiştir.

Çalışmada 4 farklı nesne bulunan termal kamera görüntülerinin Alexnet, Resnet101 ve Inceptionv3 mimarisi ile öz nitelikleri çıkartılmıştır. Ardından KNN ve SVM yöntemleri ile elde edilen öz nitelikler sınıflandırılmıştır. Tablo 6.7.'de sınıflandırma yöntemleri ile elde edilen başarımlar sonuçları verilmiştir.

Tablo 6.7. Sınıflandırıcılara göre sınıflandırma performansları

Sınıflandırıcı	Doğruluk (ACC) (%)
Alexnet + KNN	88.1
Alexnet + SVM	84.1
Resnet101 + KNN	87.3
Resnet101 + SVM	91.3
Inceptionv3 + KNN	82.5
Inceptionv3 + SVM	88.9

Kullanılan Derin öğrenme algoritmaları arasında en başarılı algoritma %91,3 doğruluk ile termal kamera görüntüleri sınıflandıran Resnet101 + SVM algoritmasıdır.

Çalışma kapsamında yapılan tüm sınıflandırmalar için en başarılı sınıflandırılan sınıflar canlıların oluşturduğu (insan- hayvan) grubu olurken en başarısız sınıflandırmalar ev-araba gibi cansız nesnelerin bulunduğu sınıflarda elde edilmiştir.

ÖNERİLER

Çalışmada 4 farklı nesne içeren termal kamera görüntüleri kullanılmıştır. Termal kamera görüntüleri çok daha fazla nesneyi ayırt etmek için kullanılmaktadır. Sınıf sayısının arttırdıkça tanıma başarımındaki değişim ölçülmelidir. Ayrıca görüntülerde nesne ile birlikte koyu renk arka plan ve arka planda değişik boyutlarda farklı nesnelerde bulunmaktadır. Temel CNN mimarilerinde bu arka plan elimine edilmemektedir. Bu nedenle minerali görüntüsünü ön plana alabilecek R-CNN (daha hızlı olması için Faster R-CNN) mimarileri kullanılabilir.



KAYNAKLAR

- [1] Ansari, S., & Salankar, S. (2017). An Overview on Thermal Image Processing. RICE, 117-120.
- [2] Cui, H., Xu, Y., Zeng, J., & Tang, Z. (2013, November). The methods in infrared thermal imaging diagnosis technology of power equipment. In 2013 IEEE 4th International Conference on Electronics Information and Emergency Communication (pp. 246-251). IEEE.
- [3] Ashish, V. (2014). Review on thermal image processing techniques for machine condition monitoring. International Journal of Wireless Communications and Networking Technologies, 3(3).
- [4] Roslidar, R., Rahman, A., Muharar, R., Syahputra, M. R., Arnia, F., Syukri, M., ... & Munadi, K. (2020). A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection. IEEE Access, 8, 116176-116194.
- [5] Priya, C. N., Ashok, S. D., Maji, B., & Kumaran, K. S. (2021). Deep Learning Based Thermal Image Processing Approach for Detection of Buried Objects and Mines. Engineering Journal, 25(3), 61-67.
- [6] Cho, Y., Bianchi-Berthouze, N., Marquardt, N., & Julier, S. J. (2018, April). Deep thermal imaging: Proximate material type recognition in the wild through deep learning of spatial surface temperature patterns. In Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems (pp. 1-13).
- [7] He, Y., Deng, B., Wang, H., Cheng, L., Zhou, K., Cai, S., & Ciampa, F. (2021). Infrared machine vision and infrared thermography with deep learning: A review. Infrared physics & technology, 116, 103754.
- [8] Jianmin, Z., Qixian, Z., Juanjuan, L., & Dongdong, X. (2010, May). Design of on-line detection system for apple early bruise based on thermal properties analysis. In 2010 International Conference on Intelligent Computation Technology and Automation (Vol. 2, pp. 47-50). IEEE.
- [9] Cui, H., Xu, Y., Zeng, J., & Tang, Z. (2013, November). The methods in infrared thermal imaging diagnosis technology of power equipment. In 2013 IEEE 4th International Conference on Electronics Information and Emergency Communication (pp. 246-251). IEEE.
- [10] Al-Obaidy, F., Yazdani, F., & Mohammadi, F. A. (2017). Fault detection using thermal image based on soft computing methods: Comparative study. Microelectronics Reliability, 71, 56-64.
- [11] Sarawade, A. A., & Charniya, N. N. (2019, January). Detection of faulty integrated circuits in PCB with thermal image processing. In 2019 International Conference on Nascent Technologies in Engineering (ICNTE) (pp. 1-6). IEEE.
- [12] Weinmann, M., Leitloff, J., Hoegner, L., Jutzi, B., Stilla, U., & Hinz, S. (2014). Thermal 3d mapping for object detection in dynamic scenes. isprs annals of photogrammetry, Remote Sensing & Spatial Information Sciences, 2(1).
- [13] Koukiou, G., & Anastassopoulos, V. (2015). Neural networks for identifying drunk persons using thermal infrared imagery. Forensic Science International, 252, 69-76..
- [14] Cayli, A., & Akyüz, A. (2019). The Experimental Determination of The Impact of Overall Heat Consumption Coefficient and Thermal Screens on Heat Saving in Plastic Greenhouses. Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi, 22(2), 270-280.

- [15] Berkmen, G. (2001). Dış Cephe Yalıtım Sistemleri ve Uygulama Prensipleri. Yalıtım Kongresi ve Sergisi Bildirileri MMO Yayını.
- [16] Gonzalez, R. C., & Woods, R. E. (2008). Digital image processing: Pearson international edition.
- [17] Çalışan, M., & Türkoğlu, İ. (2011). Termal kameralar ve uygulamaları. Elektrik-Elektronik Bilgisayar Sempozyumu (FEEB 2011), 46, 50.
- [18] Değirmenci, A. İ. (2010). Türkiye’de uygulanan yalıtım tekniklerinin araştırılmasında termal kameranın etkin biçimde kullanılması.
- [19] Aslan, S. (2016). Mühendislik uygulamalarında termal kamera kullanımı (Master's thesis, İskenderun Teknik Üniversitesi/Mühendislik ve Fen Bilimleri Enstitüsü/Makine Mühendisliği Anabilim Dalı).
- [20] Dunbar, M. R., Johnson, S. R., Rhyon, J. C., & McCollum, M. (2009). Use of infrared thermography to detect thermographic changes in mule deer (*Odocoileus hemionus*) experimentally infected with foot-and-mouth disease. Journal of zoo and wildlife medicine, 40(2), 296-301.
- [21] Palmon, L. U., Foshager, M. C., Parantainen, H., Everson, L. I., & Cunningham, B. (1997). Ruptured or intact: what can linear echoes within silicone breast implants tell us?. AJR. American journal of roentgenology, 168(6), 1595-1598.
- [22] Aslan, S. (2016). Mühendislik uygulamalarında termal kamera kullanımı (Master's thesis, İskenderun Teknik Üniversitesi/Mühendislik ve Fen Bilimleri Enstitüsü/Makine Mühendisliği Anabilim Dalı).
- [23] Çalışan, M., & Türkoğlu, İ. Improvement of Thermal Camera Images Termal Kamera Görüntülerinin İyileştirilmesi.
- [24] Kartal, E., Makine Öğrenmesi ve Yapay Zeka, *TIP BİLİŞİMİ*, İSTANBUL, İstanbul University Press, 2021, pp. 352-365.
- [25] Samuel, A. L. (1988). Some studies in machine learning using the game of checkers. II—recent progress. Computer Games I, 366-400.
- [26] Gökalp, M. Ö. (2022). Makine Öğrenmesi - Machine Learning
- [27] Karakuş, C., Makine Öğrenmesi Temelleri Ders Notu.
- [28] Available: <http://www.prowmes.com/blog/makine-ogrenmesi/>. Erişim: 10 Mayıs 2022
- [29] <https://www.veribilimiokulu.com/makineler-nasil-ogrenir/>. Erişim: 10 Mayıs 2022
- [30] https://erdincuzun.com/makine_ogrenmesi/makine-ogrenmesinden-elde-edilen-modellerin-degerlendirmesi/. Erişim: 10 Mayıs 2022
- [31] <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1>. Erişim: 10 Mayıs 2022
- [32] Kayaalp, K., & Süzen, A. A. (2018). Derin Öğrenme, Iksad Yayınevi: TÜRKİYE
- [33] Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85-104.
- [34] <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks> Erişim: 23 Nisan 2022.

- [35] Luo, X., Wen, W., Wang, J., Xu, S., Gao, Y., & Huang, J. (2022). Health classification of Meibomian gland images using keratography 5M based on AlexNet model. *Computer Methods and Programs in Biomedicine*, 219, 106742.
- [36] Lu, S., Lu, Z., & Zhang, Y. D. (2019). Pathological brain detection based on AlexNet and transfer learning. *Journal of computational science*, 30, 41-47.
- [37] Ghazi, M. M., Yanikoglu, B., & Aptoula, E. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235, 228-235.
- [38] Liao, J., Lam, H. K., Jia, G., Gulati, S., Bernth, J., Poliyivets, D., ... & Hayee, B. (2021). A case study on computer-aided diagnosis of nonerosive reflux disease using deep learning techniques. *Neurocomputing*, 445, 149-166.
- [39] Zhou, Z., Song, Z., Fu, L., Gao, F., Li, R., & Cui, Y. (2020). Real-time kiwifruit detection in orchard using deep learning on Android™ smartphones for yield estimation. *Computers and Electronics in Agriculture*, 179, 105856.
- [40] Bansal, M., Goyal, A., & Choudhary, A. (2022). A comparative analysis of K-Nearest Neighbour, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, 100071.
- [41] Değirmenci, A. İ. (2010). Türkiye’de uygulanan yalıtım tekniklerinin araştırılmasında termal kameranın etkin biçimde kullanılması.
- [42] Marsland, S. (2015). *Machine Learning*, Florida: CRC Press