

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ TABANLI YÜZ
İFADELERİNİ TANIMA SİSTEMİ

Muhammed Kerem TÜRKEŞ

Danışman: Dr. Öğr. Üyesi Yıldız AYDIN

YAPAY ZEKA VE ROBOTİK
ANABİLİM DALI

ERZİNCAN
2024
Her Hakkı Saklıdır.

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ TABANLI YÜZ İFADELERİNİ TANIMA SİSTEMİ

Muhammed Kerem TÜRKEŞ

Erzincan Binali Yıldırım Üniversitesi
Fen Bilimleri Enstitüsü
Yapay Zeka ve Robotik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Yıldız AYDIN

İnsanlar arasındaki yüz yüze iletişimde kelimeler, ses tonu ve yüz ifadeleri verimli etkileşim açısından çok önemli bir konumdadır. Jestlerin ve yüz ifadelerinin kişilerarası ilişkiler üzerinde önemli bir etkiye sahip olduğu gözlemlenmektedir. Yüz ifadelerinden duygu tanıma işlemleri sayesinde tıp, eğitim, güvenlik başlıca olmak üzere birçok alanda çeşitli işlemlerde kolaylık sağlanmaktadır. Bu çalışma kapsamında, yüz ifadelerinden duygu tahmini işlemi gerçekleştirilen çalışmalarda verimi artırmak amacıyla hibrit yaklaşım yöntemleri kullanılmıştır. Geliştirilen bu uygulama, öznitelik çıkarımı ve sınıflandırma olmak üzere iki adımdan oluşmaktadır. Bu tez çalışması kapsamında, ilk adımda SIFT, SURF, KAZE öznitelikleri SVM, XGB, RF, LR sınıflandırıcıları kullanılarak sınıflandırılmıştır. İkinci adımda ise CNN, ResNet50, VGG16 yöntemleri ile sınıflandırma işlemi yapılmıştır. Hibrit metotların ilk aşamasında derin öğrenme ve klasik makine sınıflandırıcılarının kendi aralarında kombinasyonel olarak kullanımıyla, SIFT, SURF, KAZE, ResNet50, VGG16 ile elde edilen öznitelikler SVM, XGB, RF, LR ve derin öğrenme metotları kullanılarak sınıflandırılmıştır. Hibrit metotların ve çalışmanın son aşamasında ise Hessian dedektörü ile tespit edilen anahtar nokta konumlarına SIFT tanımlayıcı inşa edilerek elde edilen hibrit öznitelik (HessianSIFT), SVM, XGB, RF, LR sınıflandırıcıları ile sınıflandırılmıştır. Elde edilen deney sonuçlarına göre, ResNet50 ve SVM'nin birlikte kullanılmasıyla yüz ifadelerinden tespit edilen duyguların tanıma başarısı %100 olarak belirlenmiştir.

2024, 51 Sayfa

Anahtar Kelimeler: Derin Öğrenme, Makine Öğrenmesi, Öznitelik Çıkarımı, Sınıflandırma

ABSTRACT

MSc Thesis

DEEP LEARNING AND MACHINE LEARNING BASED FACIAL EXPRESSION RECOGNITION SYSTEM

Muhammed Kerem TÜRKEŞ

Erzincan Binali Yıldırım University
Graduate School of Natural and Applied Sciences
Department of Artificial Intelligence and Robotics

Supervisor: Asist. Prof. Dr. Yıldız AYDIN

In face-to-face communication, words, tone of voice, and facial expressions are crucial for efficient interaction. It is observed that gestures and facial expressions significantly impact interpersonal relationships. Thanks to emotion recognition from facial expressions, various operations in many fields, especially medicine, education, and security, are facilitated. Within the scope of this study, hybrid approach methods were used to increase the efficiency of studies that performed emotion prediction from facial expressions. This developed application consists of two steps: feature extraction and classification. Within the scope of this thesis study, in the first step, SIFT, SURF, and KAZE features were classified using SVM, XGB, RF, and LR classifiers. In the second step, classification was performed using CNN, ResNet50, and VGG16 methods. In the first stage of hybrid methods, by using deep learning and classical machine classifiers in combination with each other, the features obtained with SIFT, SURF, KAZE, ResNet50, VGG16 were classified using SVM, XGB, RF, LR, and deep learning methods. In the final stage of the hybrid techniques and study, the hybrid feature (HessianSIFT) obtained by building a SIFT descriptor on the critical point locations detected with the Hessian detector was classified with SVM, XGB, RF, LR classifiers. According to the experimental results, the recognition success of emotions detected from facial expressions was determined as 100% using ResNet50 and SVM together.

2024, 51 Pages

Keywords: Classification, Deep Learning, Feature Extraction, Machine Learning

TEŞEKKÜR

Yüksek lisans eğitimim ve çalışmalarım boyunca, tarafıma bilgisi ve tecrübesi ile her zaman yol gösteren, hoşgörü ve sabırla her konuda desteklerini veren danışman hocam Sayın Dr. Öğr. Üyesi Yıldız AYDIN'a sonsuz teşekkürlerimi ve saygılarımı sunarım.

Tez çalışmamın yürütülmesinde desteklerini esirgemeyen, bu süreçte bana her zaman yol gösteren Sayın Doç. Dr. Volkan KAYA'ya ve Sayın Doç. Dr. Durmuş ÖZDEMİR'e;

Uzun yıllardır varlıklarıyla tarafıma her zaman destek olan kadim can dostlarım Müh. Ahmet Furkan POLAT'a ve Müh. Ömer KARAKAŞ'a;

Eğitim hayatım boyunca maddi ve manevi desteklerini esirgemeyen, her türlü koşulda tarafıma desteklerini hissettiren anneme, babama ve kardeşim Hatice Aişe'ye;

Gönülden teşekkür ve saygılarımla...

Muhammed Kerem TÜRKEŞ

Temmuz, 2024

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER	iv
ŞEKİLLER LİSTESİ.....	vii
TABLolar LİSTESİ.....	ix
SİMGELER ve KISALTMALAR	x
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ	4
3. KURAMSAL TEMELLER.....	7
3.1. Öznitelikler.....	7
3.1.1. SIFT (Ölçeklemeden bağımsız öznitelik dönüşümü).....	7
3.1.2. SURF (Hızlandırılmış gürbüz özniteliği).....	8
3.1.3. KAZE	9
3.1.4. Kelimelerin çantası yöntemi (BoW)	9
3.2. Makine Öğrenmesi Yöntemleri.....	10
3.2.1. Destek vektör makineleri-DVM (Support vector machine-SVM).....	10
3.2.2. Rassal orman-RO (Random forest-RF).....	12
3.2.3. Lineer regresyon-LR (Linear regression-LR)	13
3.2.4. XGBoost (XGB).....	14
3.3. Derin Öğrenme Yöntemleri.....	14
3.3.1. Evrişimsel sinir ağı-ESA (Convolutional Neural Network-CNN).....	15
3.3.1.1. Evrişimsel sinir ağı katmanları.....	16
3.3.1.1.1. Giriş katmanı.....	17
3.3.1.1.2. Evrişim katmanı	17
3.3.1.1.3. Havuzlama katmanı.....	18
3.3.1.1.4. Aktivasyon katmanı	18
3.3.1.1.5. Tam bağlı katman.....	19
3.3.1.1.6. Düzleştirme katmanı	19

3.3.1.1.7. Sınıflandırma katmanı	20
3.3.2. Standart evrişimli ağ mimarileri.....	20
3.3.2.1. VGG16	20
3.3.2.2. ResNet50	21
4. MATERYAL ve YÖNTEM	22
5. BULGULAR	24
5.1. Veri Seti.....	24
5.2. Performans Metrikleri	25
5.2.1. Doğruluk.....	25
5.2.2. Kesinlik	26
5.2.3. Duyarlılık	26
5.2.4. F1 değeri.....	26
5.3. Deneysel Sonuçlar.....	27
5.3.1. Klasik öznitelikler ve klasik makine sınıflandırıcıları ile gerçekleştirilen deneyler.....	28
5.3.1.1. SIFT özniteliği ile klasik makine öğrenme sınıflandırıcılarına ait performans verileri	28
5.3.1.2. SURF özniteliği ile klasik makine öğrenme sınıflandırıcılarına ait performans verileri	29
5.3.1.3. KAZE özniteliği ile klasik makine öğrenme sınıflandırıcılarına ait performans verileri	30
5.3.2. Derin öğrenme metotları ile gerçekleştirilen deneyler.....	31
5.3.2.1. Derin öğrenme metotları kullanılarak elde edilen öznitelik ile derin öğrenme sınıflandırıcılarına ait performans verileri	32
5.3.3. Hibrit metotlar ile gerçekleştirilen deneyler.....	32
5.3.3.1. Derin öğrenme ve klasik makine öğrenmesi yöntemlerine ait kombinasyonel deneyler.....	33
5.3.3.1.1. ResNet50 tarafından elde edilen öznitelik ile klasik makine sınıflandırıcılarına ait performans verileri	33

5.3.3.1.2. VGG16 tarafından elde edilen öznitelik ile klasik makine sınıflandırıcılarına ait performans verileri	34
5.3.3.1.3. Klasik yöntemler kullanılarak elde edilen öznitelik ile derin öğrenme sınıflandırıcılarına ait performans verileri	35
5.3.3.2. HessianSIFT hibrit özniteliğine ait deneyler.....	36
5.4. Deneyisel sonuçlar özet.....	37
6. SONUÇLAR.....	40
KAYNAKLAR.....	42
EKLER.....	51
Ek-1. Tez Çalışması Süresince Yapılan Akademik Çalışmalar	51

ŞEKİLLER LİSTESİ

Sayfa

Şekil 3.1. SVM genel yapısı (Uçak, 2012).....	11
Şekil 3.2. Rastgele Orman algoritması genel yapısı	13
Şekil 3.3. Lineer regresyon yöntemine ait grafik (Tharwat vd., 2017).....	14
Şekil 3.4. Aralarındaki ilişkiyi temsil eden görüntü	15
Şekil 3.5. Evrişimsel sinir ağına ait genel çalışma prensibi (Konca, 2020).....	16
Şekil 3.6. Filtreleme işlemine ait örnek (Aggarwal, 2018).....	17
Şekil 3.7. Maksimum havuzlama tekniği örnek (Aggarwal, 2018)	18
Şekil 3.8. Düzleştirme katmanı örnek	19
Şekil 3.9. VGG16 mimarisi (Khandelwal, 2020).....	20
Şekil 3.10. ResNet mimarisi.....	21
Şekil 4.1. Sisteme ait yöntemleri gösteren yapı	22
Şekil 4.2. Deneysel çalışmalara ait akış diyagramı.....	23
Şekil 5.1. CK+48 veri setine ait örnek görüntüler	24
Şekil 5.2. Tez kapsamında gerçekleştirilen deneyler	28
Şekil 5.3. SIFT özneliği ve klasik makine sınıflandırıcılara ait sınıflandırma performansları	29
Şekil 5.4. SURF özneliği ve klasik makine sınıflandırıcılara ait sınıflandırma performansları	30
Şekil 5.5. KAZE özneliği ve klasik makine sınıflandırıcılara ait sınıflandırma performansları	31
Şekil 5.6. Derin öğrenme metotları tarafından elde edilen öznelik ve derin öğrenme metotları sınıflandırma performansları	32
Şekil 5.7. ResNet50 tarafından elde edilen öznelik ve klasik makine sınıflandırıcılara ait sınıflandırma performansları	34
Şekil 5.8. VGG16 tarafından elde edilen öznelik ve klasik makine sınıflandırıcılara ait sınıflandırma performansları	35
Şekil 5.9. Klasik metotlar tarafından elde edilen öznelik ve derin öğrenme metotları sınıflandırma performansları	36

Şekil 5.10. Hibrit metotlar tarafından elde edilen HessianSIFT öznitelik ve klasik makine sınıflandırıcılara ait sınıflandırma performansları	37
---	----



TABLÖLAR LİSTESİ

	Sayfa
Tablo 5.1. SIFT Özniteliği – Klasik Makine Öğrenmesi Yöntemleri.....	29
Tablo 5.2. SURF Özniteliği – Klasik Makine Öğrenmesi Yöntemleri	30
Tablo 5.3. KAZE Özniteliği – Klasik Makine Öğrenmesi Yöntemleri	31
Tablo 5.4. Derin Öğrenme Öznitelik – Derin Öğrenme Sınıflandırma.....	32
Tablo 5.5. ResNet50 Öznitelik – Klasik Makine Öğrenmesi Yöntemleri	33
Tablo 5.6. VGG16 Öznitelik – Klasik Makine Öğrenmesi Yöntemleri	34
Tablo 5.7. Klasik Öznitelik – Derin Öğrenme Sınıflandırma	35
Tablo 5.8. HessianSIFT Hibrit Özniteliği – Klasik Makine Öğrenmesi Yöntemleri.....	36
Tablo 5.9. Deneysel Sonuçlar	38

SİMGELER ve KISALTMALAR

Simgeler

s	Adım
∇	Degrade Operatörü
β_l	Doğruya Ait Eğim
f	Filtre Sayısı
n	Görüntü Boyutu
L	Görüntü Parlaklığı
ε	Hata Katsayısı
C	İletkenlik Fonksiyonu
β_0	Kesim Noktası
p	Sıfır Dolgu
$\%$	Yüzde

Kısaltmalar

BoW	Kelimelerin Çantası Yöntemi
CNN	Evrişimsel Sinir Ağı
LR	Lineer Regresyon
ResNet	Artık Ağ
RF	Rassal Orman
SVM	Destek Vektör Makineleri
SIFT	Ölçeklemeden Bağımsız Öznitelik Dönüşümü
SURF	Hızlandırılmış Gürbüz Özniteliği
VGG	Görsel Geometri Grubu
XGB	Aşırı Gradyan Arıtma

1. GİRİŞ

İnsanlar arasındaki yüz yüze iletişimde kelimeler, ses tonu ve yüz ifadeleri verimli etkileşim açısından çok önemli bir konumdadır. Jestlerin ve yüz ifadelerinin kişilerarası ilişkiler üzerinde önemli bir etkiye sahip olduğu gözlemlenmektedir (Riggio ve Lee, 2007). Yüzde oluşan bu ifadelerin, kişiler için kişilik yansımalarının yanı sıra duygusal ve içlerinde barındırdıkları psikolojik durumları hakkında da bilgiler taşımaktadır (Petrovici ve Dobrescu, 2014). Kişilerin hayatları boyunca gösterdikleri davranışları, basit bir husustan aldıkları zorlu bir karara kadar çok geniş bir yelpazedeki davranış kalıpları genel olarak duygusal durumlar diye ifade edilmektedir (Sanfey, 2003; Angie, 2011). Temel duygular olarak kabul edilen 6 adet duygunun (mutluluk, üzüntü, öfke, korku, şaşkınlık, iğrenme) yaşama dair her ortamda ve bu ortamlarda bulunan insanlar tarafından genel olarak kabul gördüğü ve karşılıklı olarak kullanıldığı görülmektedir (Ortony, 2022).

Bahsedilen bu duygular, bireylerin göstermiş olduğu çeşitli vücut hareketleriyle ve anlık olarak gelişen yüz ifadeleriyle aktarılmaktadır ve bu aktarımlar düzenli ve etkileşim yoluyla olmaktadır (Matsumoto vd., 2008). Duyguların ortaya çıkmasında, kişilerin içerisinde bulundukları ortam, yaş, cinsiyet ve hatta etnik köken gibi faktörlerin etkisi azımsanamayacak boyuttadır. Kişilerin yüz ifadelerinin tespitiyle duygularının yüksek doğruluk oranlarıyla yorumlanması için içerisinde bulundukları ortam koşullarının, kişilerin duruş pozisyonlarının ve arka plan faktörleri gibi birçok etkileşimsel durumların etkisi bulunmaktadır. Bireylere ait duygulara, başka bireylerin verdikleri tepkilerin kapsamlı bir şekilde anlaşılması iletişimi önemli ölçüde iyileştirerek artırmaktadır (Marsh vd., 2003). İnsanların yüzlerinde anlık olarak oluşan yüz ifadelerinin, içerisinde bulundukları zihinsel ve psikolojik durumların istemsiz bir yansıması olduğundan, görülen bu durum duyguların anlık analizi açısından çok önemli ve etkilidir. Yüz ifadeleri aracılığıyla ortaya çıkan bu duygular, bireyler arasında oluşan iletişim ve etkileşimin en etkili ve önemli yollarındandır.

Günümüzde yapay zekâ, insanlar ile bilgisayarlar arasındaki etkileşim için çok önemli bir faktördür. Bu etkileşimin doğru bir şekilde ilerlemesi, çağdaş teknolojilerin geliştirilerek ve bu yeniliklerin hızlı bir şekilde benimsenmesi ile olacaktır (Mollahosseini vd., 2014).

Birçok alanda yaygın olarak kullanılan yapay zekâ, insan zekasına oranla çok daha fazla iş kapasitesine, hızlı karar alabilme ve daha net sonuçlar elde etme yetisine sahiptir (Elmas, 2018). Gelişmiş teknoloji ve yapay zekâ tekniklerinin kullanıldığı alanlarda bulunan birçok problemin çözüme ulaştırılmasında performans değerleri oldukça yüksek bir konumdadır. Bu alanlardan bir tanesi de yüz ifadelerini tanıma sistemleridir (Marsh vd., 2003). Bu sistemlerde, hızlı bir şekilde gelişen teknolojinin ileri seviyelere ulaşmasıyla birlikte, kişiler ve yüzlerinde bulunan ifadeler, hızlı ve efektif bir şekilde tespit edilebilir hale gelmiştir. Bu sistemler sayesinde elde edilen veriler analiz edilerek kişilere ait ruh halleri belirlenebilmektedir (Jack vd., 2012).

Yüz ifadelerinden duygu tanıma işlemleri sayesinde, tıp, eğitim, güvenlik başlıca olmak üzere birçok alanda çeşitli işlemlerde kolaylık sağlanmaktadır (Akar ve Akgül, 2022). Sağlık alanında çeşitli fiziksel ve zihinsel hastalıkların tespit edilerek sağlıklı yaşam için doğrudan veya alternatif önerilerin verildiği platformlarda, eğitim alanında öğrencilerin anlık yüz ifadelerine ve verdikleri tepkilerle başarıya ulaşmada, güvenlik alanında soruşturmalarda yalan tespiti vb. durumlarda güvenlik ve adalet unsurunu sağlamak amacıyla kullanılması ve verilen bu örneklerle birçok sektörde başarı yüzdelerinin artırılması yönünde katkı sağlayacağı görülmektedir (Özdemir ve Karaman, 2017; Mehta vd., 2019). Bu nedenle, bu çalışma kapsamında birçok alana faydası olan yapay zekâ ile yüz ifadesi tanıma sistemi üzerinde çalışılmıştır.

Yüz ifadesi tanıma uygulamaları, öznitelik çıkarımı ve sınıflandırma olmak üzere temel iki adımdan oluşmaktadır (Turan ve Lam, 2018). Birçok alanda hibrit öznitelikler kullanılarak çok daha güçlü öznitelikler elde edilerek yüksek performans değerlerine ulaşılmıştır (Aydın, 2023). Güçlü özniteliklerin elde edilmesiyle birlikte sınıflandırıcı performansında önemli bir artış olmaktadır (Aydın vd., 2016). Bu çalışmalar genel olarak öznitelik çıkarımı ve klasik makine öğrenmesi yöntemleri veya derin öğrenme metotlarıyla birlikte kullanılmaktadır. Dolayısıyla belirtilen alanlara katkı sağlamak amacıyla bu tez çalışmasında gürbüz öznitelik kullanılarak daha başarılı bir sınıflandırma performansı elde edilmesi hedeflenmiştir. Gürbüz öznitelik elde etmek amacıyla veri seti üzerinde bazı deneyler gerçekleştirilmiştir ve öznitelik çıkarımıyla makine öğrenmesi yöntemleri kullanılarak, sınıflandırma işlemi gerçekleştirilmiştir. Çalışmanın performans değerlerini ölçmek için bu çalışmada veri seti olarak CK+48 veri seti kullanılmıştır. Bu

veri setinde, mutluluk, üzüntü, öfke, korku, şaşkınlık, iğrenme olmak üzere altı sınıf etiketi bulunmaktadır. Geliştirilen bu çalışma kapsamında, klasik makine sınıflandırıcıları, derin öğrenme metotları ve hibrit yaklaşımlar kullanılmıştır. Önerilen yöntemler sayesinde, sınıflandırma performansının arttığı deneysel sonuçlardan elde edilen veriler doğrultusunda görülmektedir.

Son yıllarda yüz tanıma ile ilgili çalışmalarda, derin öğrenme ve makine öğrenmesi yöntemleri sıklıkla kullanılmaktadır. Bölüm 2’de kullanılan teknikler ve gerçekleştirilen çalışmalar hakkında detaylı bilgiler verilmiştir.



2. KAYNAK ÖZETLERİ

Asfhar ve Ali Salah (2016) yapmış oldukları çalışmada, yüz ifadelerinden duyguları tanımlamak amacıyla daha gelişmiş ve yoğunlaştırılmış bir yörünge tanıma uygulaması geliştirmişlerdir. Geliştirilen uygulamada, geometrik öznitelik analizi ve yoğunlaştırılmış yörünge algoritmasını tercih etmişlerdir. Bu algoritmalar, Cohn-Kanade (CK+) ve EmotiW 2015 veri kümesi üzerinde test edilmiştir ve Çok yüksek başarı performansı ve daha hızlı bir eğitim süresi elde edilmiştir.

Bayrakdar vd. (2017) tarafından gerçekleştirilen çalışmada, bireylere ait 4 farklı duyguyu (üzüntü, mutluluk, şaşkınlık, nötr) tespit etmek amacıyla, önceden oluşturulmuş videolardan elde edilen dosyalar üzerinden analiz işlemi gerçekleştirilmiştir. Analiz sonucunda video dosyalarında bulunan görüntü karelerinin sayısı azaltılmıştır. İşlem gücü ve kapasitesi yüksek bilgisayarda birbirlerine paralel olarak bulunan iş parçacıkları sayesinde video dosyaları için gelişmiş bir yüz ifadesi tanıma sistemi geliştirmişlerdir.

Li vd. (2020) tarafından gerçekleştirilen çalışmada, dört aşamalı yeni bir model önerilmiştir. Gerçekleştirilen bu çalışma kapsamında, yerel ikili modeller kullanılarak görüntülere ait bilgiler çıkartılmıştır. Yüksek performans elde etmek amacıyla elde edilen öznitelikler geliştirilen dikkat mekanizmasıyla birleştirilmiştir. Çalışmada 35 farklı kişiye ait yedi farklı ifadeden oluşan veri seti oluşturulmuştur. Geliştirilen sistem, oluşturdukları veri seti ve diğer diğer veri setleri; JAFFE, CK+, FER2013, Oulu-CASIA kullanılarak uygulamaya ait performans değerlendirilmesi yapılmıştır. Geliştirilen yöntem sayesinde yüksek performans elde etmişlerdir.

Mukhopadhyay vd. (2020) yılında yapmış oldukları çalışmada, birebir aynı görüntüler yerine hareketli olarak oluşturulmuş görüntü kareleri üzerinden bir çalışma gerçekleştirerek duyguları birleştirmişler ve bu şekilde farklı bir yaklaşım elde ederek performans artışı elde etmişlerdir.

Chowdary vd. (2021) tarafından gerçekleştirilen çalışmada, önceden üzerinde çalışmalar yapılmış Resnet50, VGG19, Inception V3 yapıları kullanılmıştır. Eğitilmiş ConvNet içerisinde bulunan bağlı katmanlar birbirlerinden ayrılıp kaldırıldıktan sonra yerlerine

incelenen duygu sayılarına oranla yeni katmanlar eklenmiş ve daha iyi bir performans değeri elde edilmiştir.

Sadeghi vd. (2022) yapmış oldukları çalışmada, evrişimsel sinir ağına (CNN), derin histogram yapısıyla metrik öğrenmeyi kazandırarak yüz ifadesinden duygu analizi için bir yapı oluşturmuş ve bu yapı sayesinde performans değerlerinde iyileştirmeler yapılmıştır.

Funda ve Akgül (2022) derin öğrenme tekniklerinden birisi olan evrişimsel sinir ağını kullanarak bir model geliştirmiştir. Geliştirilen model, KDEF ve PICS veri setleri üzerinde test edilmiştir ve yüksek performans elde etmişlerdir.

Mukhopadhyay vd. (2023) tarafından gerçekleştirilen çalışmada, evrişimsel sinir ağı (CNN) eğitilmiştir. Yerel ikili, yerel üçlü ve yerel tanımlayıcı model gibi yapılar sayesinde görüntüler elde edilmiştir. Elde edilen görüntülere ait öznitelikler kullanılarak yüz ifadelerinden duygu analizi için yüksek başarı performansına sahip bir uygulama geliştirilmiştir.

Karnati vd. (2023) öznitelik çıkarma modüllerini, bölgesel ve yapısal olarak uygulamışlardır. Gerçekleştirilen bu işlem sonucunda ayırt edici öznitelikler tespit edilmiştir. Bu yöntem sayesinde kullanılan veri kümesi için yüksek performans değeri elde etmişlerdir.

Kumar vd. (2023) tarafından gerçekleştirilen çalışmada, evrişimsel sinir ağı ve yerel ikili modelleri kullanılmıştır. Bu modeller sayesinde, yedi evrensel duyguyu algılamak için yüz ifadesi tanıma uygulaması geliştirilmiştir. Görüntülere ait zıt ve benzer öznitelikleri işleyen bir yöntem geliştirmişlerdir. Geliştirilen yöntem sayesinde daha az bellek kullanımı ve yüksek doğruluk performansı elde etmişlerdir.

Kumar vd. (2023) tarafından gerçekleştirilen çalışmada, şekil ve doku görüntülerine ait öznitelikleri birleştirerek yeni bir öznitelik dağılımı oluşturmuşlardır. Yerel faz niceleme, yerel ikili model ve yönlendirilmiş degradelerin histogramını kullanarak yeni öznitelikleri belirlemişlerdir. Sınıflandırma için çok sınıflı destek vektör makinesi yöntemini ve veri seti olarak da CK+, KDEF ve JAFFE kullanmışlardır. Elde ettikleri verilere göre

performans verileri mevcut el yapımı öznitelik tabanlı yöntemlerden önemli ölçüde fazladır.

Alhussan vd. (2023) tarafından gerçekleştirilen çalışmada, destek vektör makinesi yöntemlerine dayanan bir yüz ifadesi tanıma sistemi geliştirilmiştir. Önerilen sistem; veri hazırlama, optimizasyon için ızgara araması ve kategorize etme aşaması olmak üzere üç ana temelden oluşmaktadır. Görüntüleri sınıflandırmak için doğrusal diskriminant analizini kullanmışlardır. Geliştirilen sistemi test etmek amacıyla AffectNet kullanmışlardır. Sonuç olarak, yüksek doğruluk ve başarı elde etmişlerdir.

Haq vd. (2024) tarafından gerçekleştirilen çalışmada, evrimsel sinir ağı (CNN), kullanılarak bireylere ait evrensel duygu durumları gerçek zamanlı olarak analiz edilmiştir. Yapılan bu çalışma sonucunda gerçek zamanlı olarak yapılan çalışmalara oranla daha yüksek bir performans elde etmişlerdir.

3. KURAMSAL TEMELLER

Yapay Zeka kavramı, 20. Yüzyılın ikinci yarısı itibariyle bilgisayarların düşünme yeteneğine sahip olup olmadığına ilişkin temel araştırmayla başlamıştır. Yapay zeka insanlara ait işlevlerin otonom olarak yapılmasını sağlama süreci olarak tanımlanabilmektedir. Yapay zeka, bir makinenin bilgisayar programlarını kullanarak verileri analiz ederek kalıpları belirleme ve sorunları çözmek için gelişmiş bilişsel yetenekleri kullanarak kendisini yeni koşullara uyarlama kapasitesini ifade etmektedir (John vd., 2006). Makine öğrenmesi, derin öğrenme ve diğer birçok tekniği içermektedir. Günümüzde kompleks sistemlerin yaygınlaşmasıyla birlikte yapay zeka popüler bir olgu olmuştur. Bilgisayarların hesaplama yetenekleriyle sınırlı olarak çözülebilen matematiksel algoritmalar ve çözülemeyen birçok kompleks işlem, yapay zekanın gelişmiş yetenekleri sayesinde hızlıca çözülebilir hale gelmiştir (Chollet, 2021). Bölüm 3’de yapay zeka kapsamında sıklıkla kullanılan ve bu tez kapsamında da gerçekleştirilen deneylerde kullanılan yöntemler detaylandırılarak anlatılmıştır.

3.1. Öznitelikler

SIFT, SURF, KAZE gibi öznitelikler, birbirlerinden farklı görüntülerden farklı sayılarda elde edilmektedir. Fakat klasik makine sınıflandırıcılarına giriş vektörü olarak verilen bu özniteliklerin her bir örnek için aynı boyutta olması gerekmektedir. Bu nedenle, belirtilen özniteliklerin klasik makine sınıflandırıcıları ile sınıflandırılabilmesi için kelimelerin çantası yönteminin (BoW) kullanılması gerekmektedir (Aydın, 2016). Alt başlıklarda SIFT, SURF, KAZE ve kelimelerin çantası yöntemi detaylandırılarak anlatılmıştır.

3.1.1. SIFT (Ölçeklemeden bağımsız öznitelik dönüşümü)

SIFT tanımlayıcısı (Lowe, 2004), belirli bir öznitelik noktasının yakınındaki her piksel için gradyan vektörünü hesaplamaktadır ve bu işlem sonucunda normalleştirilmiş gradyan yönlerine ait bir histogram oluşturmaktadır. SIFT tanımlayıcısı, her biri ayrı ayrı olarak 4×4 pikselden oluşan 16 alt bölgeye bölünmüş 16×16 boyutunda bir bölge oluşturmaktadır. SIFT algoritması, bir alt bölgedeki her piksele ait gradyan vektörünü, gradyan yönlerinin histogramına atayarak birleştirmektedir. Bu işlem, her yönelimi sekiz yönden birine kategorize ederek ve her vektörün büyüklüğünü, vektörün katlısının

ağırlığı şeklinde değerlendirilerek yapılmaktadır. Ayrıca, gradyan yönleri $\sigma = n/2$ ölçeğine sahip bir Gauss fonksiyonundan etkilenmektedir; burada n , bölgenin boyutudur. Elde edilen değerler, daha sonra üç doğrusal enterpolasyon kullanılarak bitişik bölmelere yayılmaktadır. Bu yayılma, örnekler, konumlar ve yönelimler arasında geçiş yaptığında sınır etkilerini en aza indirmeye yardımcı olmaktadır. SIFT özneliğini hesaplayabilmek için başlıca dört adım bulunmaktadır. Bunlar; ölçek uzayını belirleme, kilit noktalarını belirleme, yönelim belirleme ve kilit noktaları tanımlamadır (Aydın, 2016). Yapılan çalışmalarda SIFT'in alternatif yerel tanımlayıcılara göre daha iyi performans gösterdiği görülmektedir (Mikolajczyk ve Schmid, 2005). Denklem 3.1.'de farklı ölçeklerde hesaplanan iki Gaussian'ın farkının evrişimini gösteren denklem verilmiştir (Taren ve Saleem, 2018). Burada " $G(x, y, \sigma)$ " Gauss fonksiyonunu, " $I(x, y)$ " giriş görüntüsünü, " $D(x, y, \sigma)$ " ise k çarpı ölçeğinde olan iki görüntü arasındaki farkı ifade etmektedir.

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) \quad (3.1)$$

3.1.2. SURF (Hızlandırılmış gürbüz özneliği)

SURF (Bay vd., 2006), SIFT operatörüne benzer şekilde görüntü ölçekleme, döndürme, aydınlatma ve hatta afin dönüşümündeki değişikliklerden etkilenmeyen öznelikleri tespit etmeye yönelik bir öznelik algılama algoritmasıdır. Bu tanımlayıcı, belirlenen noktaların çevresinde bulunan alanlara ait piksel yoğunluklarının dağılımını kodlamaktadır. SURF, Gauss evrişimlerinin ikinci dereceden kısmi türevlerine ve integral görüntülerine yaklaşan kutu filtrelerinin kullanılması nedeniyle SIFT'te göre hesaplama açısından çok daha verimlidir (Simard vd., 1998; Viola ve Jones, 2001). Diğer birçok yöntem gibi SURF'de iki ardışık bileşenden oluşmaktadır, bunlar; öznelik noktası tespiti ve öznelik noktası açıklamasıdır. Denklem 3.2.'de " σ " ölçeğinde " $x = (x, y)$ " noktasındaki Hessian Matrisini temsil eden formül verilmiştir.

$$H(x, \sigma) = f(x) = \begin{cases} Lxx(x, \sigma), & Lxy(x, \sigma) \\ Lxy(x, \sigma), & Lyy(x, \sigma) \end{cases} \quad (3.2)$$

Denklem 3.2.'de " $Lxx(x, \sigma)$ ", Gauss ikinci dereceden türevin " x " noktasında " I " görüntüsü ile evrişimi verilmiştir. Aynı durum, " $Lxy(x, \sigma)$ ", " $Lyy(x, \sigma)$ " içinde geçerlidir.

3.1.3. KAZE

KAZE (Alcantarilla vd., 2012), doğrusal olmayan difüzyon filtreleme yolu ile doğrusal olmayan ölçek alanını kullanan bir yapı olarak 2012 yılında tanıtılmıştır. Bu yöntem, görüntülerin bulanıklaştırılmasının öznitelik noktalarına göre ayarlanmasına olanak sağlamaktadır, bu da gürültünün azaltılmasını ve görüntülerdeki bölgelerin sınırlarının korunmasını sağlamaktadır. KAZE, çeşitli ölçek seviyelerinde hesaplanan Hessian Matrisinin ölçek normalize edilmiş determinantını kullanmaktadır. Öznitelik noktaları, hareketli bir çerçeve içerisindeki dedektör tepkisinin en yüksek değerleri seçilerek tanımlanmaktadır. Tanımlanan her özelliği çevreleyen dairesel bir bölge içerisindeki birincil yönelim belirlenerek dönme değişmezliği kavramı ortaya koyulmaktadır. KAZE öznitelikleri rotasyona, ölçeğe ve sınırlı affine göre değişmezlik sergilemektedir (Taren ve Saleem, 2018). Aynı zamanda farklı ölçeklerde gelişmiş ayırt edicilik sağlamaktadır. Denklem 3.3’de doğrusal olmayan difüzyon formülü verilmiştir.

$$\frac{\partial L}{\partial t} = \text{div}(c(x, y, t) \cdot \nabla L) \quad (3.3)$$

Burada, “ c ” iletkenlik fonksiyonunu, “ div ” diverjansı, “ ∇ ” degrade operatörünü ve “ L ” ise görüntü parlaklığını ifade etmektedir.

3.1.4. Kelimelerin çantası yöntemi (BoW)

Kelimelerin çantası yöntemi ilk olarak metinleri sınıflandırmak amacıyla kullanılmıştır (Quinlan, 1993). Bu yöntemde, her metin bir kelime grubu olarak ele alınmaktadır ve kelimelere ait sıra dikkate alınmaksızın, incelenen tek faktör kelimelerin oluşum sıklığıdır. Metin içerisinde bulunan kelimelerin görülme sıklığına göre bir histogram oluşturulmaktadır. Daha sonra buna benzer bir yaklaşım olarak görsel öznitelikler kullanılarak görsel sınıflandırmada kullanılmıştır (Aydın, 2023).

Görüntülerde kelimelerin çantası yöntemini (BoW) uygulamanın, kodlama ve havuzlama olmak üzere başlıca iki adımı vardır. Kodlama, sınıflandırılması gereken görüntü parçalarına vektör nicelemesinin uygulanması sürecini ifade etmektedir. Görüntü yama seti üzerinde k-ortalamlar gibi bir sınıflandırma algoritması çalıştırıldıktan sonra, sınıflandırma işleminden oluşturulan ağırlık merkezleri tarafından temsil edilen bir


sözlük oluşturulmaktadır. Bu sözlük oluşturma işleminden sonra k tane temsili “görsel kelime” üretilmektedir. İkinci adım olan havuzlama ise bir görüntünün “görsel kelimelerden oluşan bir çantaya” dönüştürüldüğü aşamadır. Oluşturulan bu çanta, görsel kelimelerin temsilidir ve görüntü parçaları hakkında bölgesel bir bilgiye sahip değildir (Bosch vd., 2007). Kelimelerin çantası yöntemi sayesinde, görüntüdeki nesnelerin konumu ve yönü büyük ölçüde değişmemektedir ve görüntülerin içerdikleri nesnelere göre sınıflandırma performansı oldukça yüksektir. Lakin tespit edilen öznitelikler arasında konumsal bilgi bulunmaması da dezavantaj olarak görülebilmektedir (Maden, 2017).

3.2. Makine Öğrenmesi Yöntemleri

3.2.1. Destek vektör makineleri-DVM (Support vector machine-SVM)

Destek vektör makineleri (SVM), literatürde regresyon analizi ve sınıflandırma amacıyla kullanılmış olsa da yaygın olarak sınıflandırma prosedürlerinde kullanılan makine öğrenmesi tekniğidir. Bu yaklaşımın temeli denetimli öğrenme modeline dayanmaktadır. Algoritma yürütülürken işlenen verinin yapısı ve türüne bağlı olarak çekirdek fonksiyonlarda kullanılabilmektedir (Suthaharan vd., 2016; Gandhi vd., 2018). Bu nedenle doğrusal veya doğrusal olmayan sınıflandırma işlemleri SVM sayesinde yapılabilmektedir. Destek vektör makineleri, eğitimlere ait verileri maksimum kenar boşluğuna sahip bir şekilde ayırım yapan hiper düzlemi bulmaktadır ve öğrenilen hiper düzlem sayesinde örnekler sınıflandırılmaktadır. Yapısal risk minimizasyonu, azami kenar boşluklu hiper düzlemlerinin kullanımının temelini oluşturmaktadır (Dutta vd., 2020).

Şekil 3.1’de destek vektör makinelerine ait genel yapı görülmektedir.



Şekil 3.1. SVM genel yapısı (Uçak, 2012)

Kenar boşlukları sabit birincil optimizasyon problemi için doğrusal şekilde ayırım yapılabilen eğitime ait örnek; $S = ((\vec{X}_i, y_1) \dots, ((\vec{X}_i, y_i))$ ve hiper düzlem $(\vec{W}, b)$ olarak kabul edilirse, belirtilen bu problemin çözümü denklem 3.4. sayesinde çözülmektedir. Minimum çıkarma:

$$y_1 [\vec{W} \cdot \vec{X}_i + b] \geq 1, i = 1, \dots, l \quad (3.4)$$

Kenarlara ait alt düzlem bu sayede maksimum şekilde olmaktadır. Yukarıda verilen birincil optimizasyon problemi sayesinde, çekirdek kullanımı gerekli hale gelir ve yüksek boyutlara sahip öznelik uzayı kullanılmaktadır. Eğitime ait örnekler sadece içe ait ürünler olarak ikili yapıya girer ve bundan dolayı eğitim devam ettiği sürece kesinlikle öznelik vektörü olarak gösterilmesi gerekmemektedir ve bununla birlikte test aşamasında da gösterilmek zorunda değildir (Deisenroth vd., 2020).

Kenar boşlukları sabit ikincil optimizasyon problemi için doğrusal şekilde ayırım yapılabilen eğitime ait örnek; $S = ((\vec{X}_i, y_1) \dots, ((\vec{X}_i, y_i))$ ve $\vec{a}^*$ olarak kabul edilirse, belirtilen bu problemin çözümü aşağıdaki denklem sayesinde çözülmektedir. Maksimum çıkarma:

$$W(\vec{a}) = \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j a_i a_j \vec{x}_i \vec{x}_j \quad (3.5)$$


Sonra ağırlık vektörü $\vec{a}^* = \sum_{i=1}^l y_i a_i^* \vec{x}_i$ sayesinde, azami kenar boşluklarına sahip hiper düzlem elde edilmektedir.

3.2.2. Rassal orman-RO (Random forest-RF)

Rassal orman (Breinman, 2001), denetimli öğrenme teknikleri arasında yaygın olarak tercih edilen bir makine öğrenmesi yöntemidir. Hem sınıflandırma hem de regresyon uygulamalarında kullanılmaktadır (Liu vd., 2012). Algoritma, bulunan birçok sınıflandırıcıyı birleştiren bir yaklaşımdan oluşmaktadır ve sağlanan veri setine ait farklı alt kümeleri üzerinde karar ağaçlarını kullanır. Asıl çıktı, her ağaçtan gelen tahminlerin toplanmasıyla elde edilmektedir. N adet karar ağacının toplanmasıyla rassal orman oluşturulmaktadır ve her bir ağaç için tahmin işlemi gerçekleştirilerek sınıflandırma işlemi sonlandırılmaktadır (Çelik ve Özdemir, 2023). Ormanda bulunan ağaç sayısı arttırıldıkça başarı yüzdesi artmaktadır ve bu sayede aşırı uyum kaynaklı sorunların ortaya çıkması önlenmektedir (Jaiswal vd., 2017).

Rastgele orman modeli, sadece geleneksel tahmin yöntemlerine kıyasla üstün doğruluk performansı elde etmekle kalmamakta ve aynı zamanda mikro bilgi içeren veri kümelerini de işleyebilmektedir (Mbaabu, 2020). Rastgele orman yöntemi, son yıllarda önemli ilerlemeler göstermiş olup çeşitli alanlarda yaygın olarak kullanılmaktadır (Ballı, 2021).

Şekil 3.2’de rastgele orman algoritmasına ait genel yapı verilmiştir.




Şekil 3.2. Rastgele Orman algoritması genel yapısı

3.2.3. Lineer regresyon-LR (Linear regression-LR)

Lineer regresyon (Tharwat vd., 2017), bilinmeyen veri değerleri hakkında tahminler yapmak amacıyla bilinen veri değerlerini kullanan bir makine öğrenmesi tekniğidir. Halihazırda bilinen veya bağımsız faktörler ile bilinmeyen veya bağımlı faktörler arasında deterministik bir matematiksel korelasyon kurmaktadır. Bir önceki yıla ait mali durum incelenirken, bağımsız değişken olarak geliri, bağımlı değişken olarak ise giderler ele alınırsa, şu anda gelirin yarısını giderlerin oluşturduğu ve gelecek yıla ait gelirler hakkında bilgi sahibi olunduğu varsayılırsa, lineer regresyon ilkeleri kullanılarak gelecek yıla ait oluşacak giderlerin, gelirlerin yarısı kadar olacağı tahmin edilmektedir. Şekil 3.6.’de bulunan lineer regresyon grafiğinde görüldüğü üzere, lineer regresyon bağımlı ve bağımsız değişkenlere ait veri noktalarını gösteren doğrusal bir çizgi grafiği oluşturmayı amaçlamaktadır (Yao ve Li, 2014).

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3.6)$$

Tanımlanan bu denklem ile doğrusal bir model kurulabilmektedir. β_0 (kesim noktası), β_1 (doğruya ait eğim), ε (hata katsayısı) olarak ele alınmaktadır.



Şekil 3.3. Lineer regresyon yöntemine ait grafik (Tharwat vd., 2017)

3.2.4. XGBoost (XGB)

XGBoost yönteminin temeli, karar ağaçları kavramına dayanmaktadır (Shi vd., 2019). Bu teknik sayesinde, aşırı uyum problemi oluşma ihtimali azaltılarak sınıflandırma yapılmaktadır. Kayıp fonksiyona ait gerçekleşen her tahmin işlemi sonrasında tutarsızlık miktarı ele alınarak modelin eğitime devam edilmektedir. En yüksek tahmin değerini yakalayan model seçilmektedir. Sınırlı örneklerle verileri sınıflandırmak için yaygın olarak kullanılan denetimli öğrenme tekniğidir (Chen ve Guestrin, 2016).

3.3. Derin Öğrenme Yöntemleri

Derin öğrenme kavramı, yapay zekaya ait yeni bir alt alan olarak kullanılmaya başlanmıştır. Derin öğrenme sayesinde, tıp, eğitim, sanayi ve güvenlik sektörleri başlıca olmak üzere diğer birçok alanda da geliştirilen yeni uygulamalar sayesinde köklü değişiklikler olmuştur. Bahsedildiği üzere birçok alanda kullanılabilmesi ve bu alanlarda

yüksek performanslar elde edilmesi nedeniyle gerçekleştirilen yeni çalışmalarda, çoğunlukla tercih edilen popüler bir teknik olmaktadır (Ozun, 2022). Derin öğrenmenin amacı, karar verme yeteneklerine sahip makinenin belirli bir dizi kurala ve tek bir prensibe dayalı karar vermesine güvenmek yerine, birçok kapsamlı veri kümesini kullanarak üstün sonuçlar elde etmektir. Bu tür yazılımlara örnek olarak, yüz tanıma işlemleri, ses verilerini metne çevirme uygulamaları gibi uygulamalar verilebilmektedir.

Derin öğrenme yapısı gereği çok sayıda gizli katman bulundurmaktadır ve bu nedenle parametrelerin miktarı da oldukça fazla durumdadır (İnik ve Ülker, 2017). Belirtilen bu katmanların her bir adeti birbirlerine ardışık olarak konumlandırılmış çok sayıda eğitilebilir katman içerebilmektedir. Şekil 3.4’de derin öğrenmenin, makine öğrenmesi ve yapay zeka ile ilişkisi görülmektedir.




Şekil 3.4. Aralarındaki ilişkiyi temsil eden görüntü

3.3.1. Evrişimsel sinir ağı-ESA (Convolutional Neural Network-CNN)

Evrişimsel sinir ağı (CNN) (LeChun vd., 1998), ileri beslemeli şekilde çalışma prensibine sahip çok katmanlı algılayıcıların bir biçimidir. Hayvanlara ait görsel sistemin temel çalışma prensibine sahip bir metodolojiye dayanmaktadır. CNN, canlılara ait görüntü işleme sisteminde görülen süreçten ilham alınarak oluşturulmuştur ve girdiye ait verilerin özniteliklerinden doğrudan yararlanarak öğrenmeyi mümkün kılmaktadır (Hubel ve Wiesel, 1968). Üstün performans elde etmek için minimum ön işleme ve çok daha az

işlem gücüne ihtiyaç duymaktadır. CNN, bir veya daha fazla evrişimsel katman, alt örnekleme katmanı ve ardından tipik çok katmanlı bir sinir ağı gibi tek veya birçok birbirlerine bağlı katmandan oluşmaktadır (LeChun vd., 1989). CNN, derin öğrenme yöntemleri içerisinde sınıflandırma ve tespit uygulamaları amacıyla kullanılan en çok tercih edilen yöntemdir. Sınıflandırıcı katmanı, sınıflandırılacak öğelere ait öznitelikleri çıkarttıktan sonra elde edilen verilere göre sınıflandırma işlemini gerçekleştirmektedir. (Choi ve Yun, 2019). Şekil 3.5’de evrişimsel sinir ağına ait genel çalışma prensibi verilmiştir.



Şekil 3.5. Evrişimsel sinir ağına ait genel çalışma prensibi (Konca, 2020)

3.3.1.1. Evrişimsel sinir ağı katmanları

Bir evrişimsel sinir ağı mimarisinde, giriş, evrişim, havuzlama, düzleştirme, tam bağlantı ve sınıflandırma olmak üzere altı adet katman bulunmaktadır. Model içerisinde bulunan her bir katmanın farklı işlevleri vardır ve bulunan bu katmanların birbirleriyle sıralı bir şekilde bağlanmasıyla evrişimsel sinir ağı oluşmaktadır (Karadağ ve Özdemir, 2022). Evrişim ve havuzlama katmanları sayesinde öznitelikler belirlenmekte olup yumuşatma, tam bağlantı ve sınıflandırma katmanları sayesinde de sınıflandırma işlemleri gerçekleşmektedir. Evrişimsel sinir ağlarının yapısında bulunan ilk katmanlar düşük seviyeli öznitelikleri çıkartırken, sonlara doğru bulunan katmanlar ise yüksek seviyeli özniteliklerin çıkartılmasını sağlamaktadır. Katmanlar, başlangıçtan sonra doğru ilerledikçe gerçekleşen işlemlerin seviyesi arttığından dolayı çok daha keskin ve belirgin görüntüler elde edilmektedir (Büyükkıran, 2022).


3.3.1.1.1. Giriş katmanı

Evrişimsel sinir ağlarının ilk katmanı giriş katmanı olarak adlandırılmaktadır. Ham görüntü giriş katmanı sayesinde girdi vektörüne dönüştürülmektedir. Gerçekleşecek eğitime ait süre, girdi verisinin boyutuyla doğrudan ilişkilidir. Girdi görüntüsü tipik olarak Genişlik×Uzunluk×Renkli kanal formundadır (Tekerlek ve Yapıcı, 2022).

3.3.1.1.2. Evrişim katmanı

Evrişimsel sinir ağlarında özniteliklerin elde edilmesi için evrişim katmanı son derece önemli bir konumdadır. Girdi görüntüsü üzerindeki ayrıştırıcılar sayesinde öznitelikleri elde etmektedir. Evrişim katmanında, girdi görüntüsünden öznitelik elde etmek amacıyla filtreleme yapılmaktadır. Uygulanan filtre çoğunlukla hem birden çok boyutlu hem de piksel tabanlı değerler içermektedir. Girdi verilerinin filtrelenmesi sonucunda daha küçük verilere sahip bir matris elde edilmektedir. Seçilen bölgelerin tanımlanması amacıyla, bir matris görüntü üzerinde dolaşmaktadır (Ciresan vd., 2011). Tanımlanma işlemi sonucunda ortaya yeni bir matris çıkmaktadır ve yeni oluşturulan bu matrise öznitelik haritası adı verilmektedir. Derinlik, adım ve sıfır dolgu adı verilen üç farklı parametre sayesinde, çıkış matrisine ait boyut belirlenmektedir. Çıkış matrisine ait boyut hesaplaması aşağıdaki formül ile yapılmaktadır. Burada; $p = \text{sıfır dolgu}$, $s = \text{adım}$, $f = \text{filtre sayısı}$, $n = \text{görüntü boyutu}$ 'nu ifade etmektedir.

$$\frac{n+2p-f}{s} + 1 * \frac{n+2p-f}{s} + 1 \quad (3.7)$$




Şekil 3.6. Filtreleme işlemine ait örnek (Aggarwal, 2018)

İlk değişken giriş katmanında iletilen görüntüdür. Girdi görüntüsünden öznitelik çıkarımı yapılmasını sağlayan çekirdek de ikinci değişkendir. Çekirdek ile girdi görüntüsüne ait değerlerin çarpılıp toplanmasıyla evrişim katmanı elde edilmektedir.

3.3.1.1.3. Havuzlama katmanı

Bir önceki katmandan elde edilen çıktı havuzlama katmanına gönderilmektedir. Bu adımın öncelikli amacı bir sonraki evrişim katmanına hazırlık olarak görüntüye ait boyutların küçültülmesidir. Belirtilen bu boyut küçültme işlemi sıklıkla maksimum havuzlama tekniği kullanılarak gerçekleştirilmektedir. Maksimum havuzlama, bulunan her dikdörtgen bölge içerisindeki en yüksek değeri tespit ederek görüntüye ait boyutları azaltmaktadır (Goodfellow vd., 2016). Havuzlama katmanı sayesinde ağıdaki parametreler azalmaktadır ve bu doğrultuda işlem hacmi ile hesaplama miktarı azalmaktadır. Bu azalma sayesinde, ezberleme ihtiyacı en az seviyeye indirilerek hesaplama hızı ve anlamlı verilere ait oranlarda yükselme olmaktadır (Tekerlek ve Yapıcı, 2022). Şekil 3.7’de havuzlama katmanına ait örnek verilmiştir.



Şekil 3.7. Maksimum havuzlama tekniği örnek (Aggarwal, 2018)

3.3.1.1.4. Aktivasyon katmanı

Aktivasyon fonksiyonları, girdi sinyaline lineer olmayan ayarlamaların yapıldığı dönüşümlerdir. Bu işlem sonucunda değiştirilen çıktı değerleri bir sonraki aşamada girdi verisi olarak iletilmektedir. Aktivasyon fonksiyonları sayesinde girdi değerine, ağırlık ve sapma değerlerinin eklenmesiyle sonuç elde edilmektedir. Elde edilen bu sonuç, verinin bir sonraki aşamaya devam edip etmeyeceğini belirlemektedir (Rachapudi ve Lavanya,


2021). Lineer olmayan fonksiyonlar, modelin karmaşıklık durumunu arttırmaktadır. Gizli ve çıktı katmanları olmak üzere yalnızca bu iki katmanda kullanılabilmektedir. Bu iki katmanda aktivasyon fonksiyonu seçilirken gerçekleştirilecek olan tahmin yöntemi dikkate alınmaktadır. ReLu fonksiyonu, softmax fonksiyonu, tanjant hiperbolik fonksiyonu ve sigmoid fonksiyonu, aktivasyon fonksiyonuna örnek olarak verilebilmektedir (Yaşar, 2022).

3.3.1.1.5. Tam bağlı katman

Diğer katmanlar kendilerinden sonraki aşamada gelen katmanlara direkt bağlanmamışlardır lakin tam bağlı katman bir önceki katmana bağlanmaktadır. Tam bağlı katmanda, önceki aşamalarda bulunan evrişim ve havuzlama katmanlarında elde edilen verilere göre sınıflandırma yapılmaktadır ve olasılık değerlerinin tespit edilmesi sağlanmaktadır.

3.3.1.1.6. Düzleştirme katmanı

Evrişim ve havuzlama katmanlarındaki işlemler gerçekleştirildikten sonra elde edilen sonuç, ağıza ait derinliği arttırmak için ekstra olarak evrişim ve havuzlama katmanlarındaki işlemlere tekrardan tabi tutulabilmektedir. Bu yöntem sayesinde, birçok ardışık katman elde edilmektedir. Elde edilen katmanlar, çok boyutlu resimler üzerinde işlemler gerçekleştirilerek yeni öz nitelikleri elde etmeye devam etmektedir (İnik ve Ülker, 2017). Şekil 3.8.'de düzleştirme katmanına ait örnek verilmiştir.



Şekil 3.8. Düzleştirme katmanı örnek


3.3.1.1.7. Sınıflandırma katmanı

Sınıflandırma katmanı, işlem görmüş olan sınıf sayısı kadar çıktı verisi üretmektedir. Elde edilen bu çıktılar farklı sınıflara karşılık gelmektedir. Sınıflandırma katmanı son katman olduğundan dolayı verileri sınıflandırmak amacıyla softmax fonksiyonu sınıflandırıcı olarak kullanılmaktadır. Bu fonksiyon, çıktılar üzerinde bir olasılık işlemi gerçekleştirerek her sınıfa ait olasılığı hesaplamaktadır. Bu sayede, sınıflandırma katmanının çıktı değeri ve sınıf sayısı belirlenmektedir.

3.3.2. Standart evrişimli ağ mimarileri

3.3.2.1. VGG16


VGG16, Oxford Üniversitesinde bulunan görsel geometri grubu tarafından oluşturulmuştur (Simonyan ve Zisserman, 2014). Modelin tasarımında, evrişimsel sinir ağları temel olarak alınmaktadır ve oluşturulan yapı 13 evrişimsel katman ile 3 tam bağlantılı katmanı içermektedir. VGG16 mimarisi 21 katmandan oluşmaktadır. Giriş katmanı $224 \times 224 \times 3$ boyutlarında bir görüntü içerirken, evrişim katmanı ise 3×3 piksel filtre boyutuna sahiptir. Tam bağlantı katmanı sayesinde resim sınıflandırılması yapılmakta olup görüntünün ait olduğu spesifik sınıf belirlenmektedir. VGG16 mimarisi, önceden eğitilmiş ağırlıkların kullanılması nedeniyle görüntü sınıflandırma ve transfer öğrenme uygulamalarında sıklıkla tercih edilmektedir. Şekil 3.9.'da VGG16 mimarisi verilmiştir.



Şekil 3.9. VGG16 mimarisi (Khandelwal, 2020)

3.3.2.2. ResNet50

Geçmiş dönemlerde geliştirilen CNN mimarilerinin, katmanlarında değişiklik yapıldığında gradyan kaybolması sorunu ortaya çıkmaktadır ve katmanlar ölçeklendirilemez hale gelmektedir (Zhang vd., 2016). Bu problem sonucunda, ölçeklendirilemeyen katmanlar tekrar eden işlemler sonucunda eklenen her katman ile bir doyumluğa ulaşacak ve performansı kötüleşecektir. Bu problemi çözmek amacıyla, ResNet mimarisi, blokların katmanlar halinde birleştirilmesiyle oluşturulmuştur. ResNet, ağa ait derinlik değerlerini artırarak, giriş ile çıkış boyutları arasında farkı tespit ederek gradyanların kaybolmasını engellemektedir. ResNet mimarisinde, bağlantılara ait atlama veya tanımlama ismi verilen bir yöntem ile bağlantılar arası atlama yapılabilmektedir. Bu yöntem, geride bulunan katmana ait girdi değerini, arada bulunan diğer katmanları atlayarak ilerideki katmanın çıktı değerine eklemektedir. Bu yöntem sayesinde, arada bulunan bozulmuş katmanları ve fazlaca bulunan evrişim katmanları birbirlerine bağlanmaktadır (Zhang vd., 2016). Şekil 3.10.'da ResNet mimarisi verilmiştir.




Şekil 3.10. ResNet mimarisi

ResNet50, 34 katmandan oluşan ağda bulunan 2 katmanlı blokları, 3 katmanlı darboğaz bloğuyla değiştirilmesi sonucunda elde edilmektedir. Oluşturulan bu üç katmanlı yapı, 1×1 , 3×3 ve 1×1 'lik boyutlarındadır. 1×1 boyutlarına sahip katmanlar, boyutların değerlerini artırıp azaltarak değiştirmektedirler. 3×3 boyutuna sahip katmanda, girdi/çıkış için küçük boyutlu darboğaz oluşmaktadır. Bu sayede, her katmana ait eğitim hızı çok daha hızlı şekilde gerçekleşmektedir.


4. MATERYAL ve YÖNTEM

Bu tez çalışma kapsamında, yüz ifadelerinden duyguları tanımlamak amacıyla klasik makine sınıflandırıcıları, derin öğrenme metotları ve hibrit metotlar kullanılmıştır. Ele alınan hibrit metotlar kendi içerisinde iki alt kategoriye ayrılmaktadır. Hibrit yaklaşımlara ait ilk alt kategoride, Hessian dedektör ile SIFT tanımlayıcısı kullanılarak hibrit bir öznitelik elde edilmiştir. İkinci alt kategoride ise derin öğrenme ve klasik makine öğrenmesi metotları farklı kombinasyonlar ile birlikte kullanılmıştır. Klasik makine sınıflandırma metotları ile kullanılan SIFT, SURF, KAZE öznitelikleri klasik öznitelik olarak adlandırılmıştır. Açıklanan bu yapı, Şekil 4.1.'de verilmiştir.



Şekil 4.1. Sisteme ait yöntemleri gösteren yapı

Geliştirilen sistemde öznitelik çıkarmak amacıyla, ‘SIFT’, ‘SURF’, ‘KAZE’, ‘CNN’, ‘ResNet50’, ‘VGG16’, ‘HessianSIFT’ metotları, sınıflandırma aşamalarında da ‘CNN’, ‘SVM’, ‘XGB’, ‘RBF’ ve ‘LR’ yöntemleri kullanılmaktadır. Veri setinde bulunan görüntülerin girişi ile öznitelik çıkartılmış olup daha sonra sınıflandırıcı eğitilmektedir. Bu işlemden sonra, test verilerinden çıkarılan öznitelikler test verileri ile sınıflandırılmaktadır. Deneysel çalışmalara ait akış diyagramı Şekil 4.2’de verilmiştir.



Şekil 4.2. Deneyisel çalışmalara ait akış diyagramı


Şekil 4.2.'de görüldüğü üzere tez kapsamında kullanılan yöntemler üç ana başlık altında toplanmıştır. İlk başlık altında klasik öznitelikler olarak adlandırılan SIFT, SURF, KAZE öznitelikleri kelimelerin çantası yöntemi ile eşit boyutlu hale getirildikten sonra klasik makine sınıflandırıcılarından olan SVM, XGB, RF ve LR ile sınıflandırılmıştır. İkinci başlık altında derin öğrenme metotlarından olan CNN, ResNet50 ve VGG16 ile hem öznitelikler tespit edilmiş olup hem de sınıflandırma yapılmıştır. Yöntemlerin üçüncü başlığı altında ise hibrit metotlar ele alınmıştır. Bu hibrit metotlar kendi içlerinde ikiye ayrılmaktadır. Kombinasyonel deneyler altında ilk olarak derin öğrenme metotlarından ResNet50 ve VGG16 ile öznitelikler elde edilerek, klasik makine sınıflandırıcıları SVM, XGB, RF ve LR ile sınıflandırılmıştır. İkinci olarak ise klasik öznitelikler yani SIFT, SURF, KAZE öznitelikleri kelimelerin çantası yöntemi ile eşit boyutlu hale getirildikten sonra derin öğrenme metotlarından CNN ile sınıflandırılmıştır. Hibrit metotların ikinci alt başlığında ise hibrit olarak elde edilen HessianSIFT özniteliği kelimelerin çantası yöntemi ile eşit boyutlu hale getirildikten sonra klasik makine sınıflandırıcıları SVM, XGB, RF, LR ile sınıflandırılmıştır. Yapılan tüm bu deneylere ait sonuçlar Bölüm 5.3. başlığı altında başlığı altında verilmiştir.

5. BULGULAR

Bu çalışma kapsamında, insanlara ait yüz ifadelerinden duygu analizi yapabilmek amacıyla, klasik makine sınıflandırıcıları, derin öğrenme metotları ve hibrit metotlar kullanılmıştır. Kullanılan hibrit metotlar kendi içerisinde ikiye ayrılmaktadır. Çalışma kapsamında kullanılan veri seti, çalışmanın performans değerlerini elde etmek için ihtiyaç duyulan performans metrikleri ve son olarak da gerçekleştirilen deneylerden elde edilen deneysel sonuçlar aşağıda verilmektedir.

5.1. Veri Seti

Yüz ifadelerinden duygu analizi yapabilmek amacıyla ‘CK+48’ (Lucey vd., 2010), veri seti bu çalışmada kullanılmıştır. Bu veri setinde, insanlara ait altı duyguyu (mutluluk, üzüntü, öfke, korku, şaşkınlık, iğrenme) içeren görseller bulunmaktadır. ‘CK+48’ veri seti içerisinde, ‘981’ adet görüntü bulunmaktadır. Bu görüntüler 48×48 ’lik gri görüntülerden oluşmaktadır. Veri setinde bulunan görüntüler genel olarak video karelerinden elde edilmiş olup çok fazla değişikliğe uğramamıştır (Li ve Deng, 2020). Şekil 5.1.’de veri setine ait örnek görüntüler verilmiştir.



Şekil 5.1. CK+48 veri setine ait örnek görüntüler

5.2. Performans Metrikleri

Makine öğrenmesi yöntemleriyle elde edilen modeller genellikle iki bileşenden oluşmaktadır. Bunlar; eğitim ve test veri kümesidir. Elde edilen model, eğitim veri seti üzerinde eğitildikten sonra, test veri seti içerisinde bulunan ve görünmeyen veriler üzerinden değerlendirilmektedir.

Modelin performansı test sonuçlarına göre belirlenmektedir. Test sonuçları sayesinde elde edilen performans değerleri kullanılarak verilere ait sınıflandırma başarı oranı değerlendirilmektedir. Sınıflandırmanın doğruluğunu belirlemek için çeşitli kriterler ile karşılaştırma yapılması gerekmektedir. Bu metrikler, doğru pozitiflerin (TP), yanlış pozitiflerin (FP), yanlış negatiflerin (FN) ve doğru negatiflerin (TN) toplam sayı miktarına göre belirlenmektedir. Sınıflandırma parametreleri, doğruluk, kesinlik, duyarlılık ve F1 puanı kullanılarak değerlendirilmektedir (Özdemir ve Kunduracı, 2022). Yukarıda belirtilen metrikler açıklanırsa:

Doğru pozitif (TP): Pozitif olarak doğru şekilde tanımlanan değerleri ifade etmektedir. Modelin pozitif olarak tahmin ettiği doğru örnek sayısıdır.

Doğru negatif (TN): Negatif olarak doğru şekilde tanımlanan değerleri ifade etmektedir. Modelin negatif olarak tahmin ettiği doğru örnek sayısıdır.

Yanlış pozitif (FP): Yanlış olan ama pozitif olarak tanımlanan değerleri ifade etmektedir.

Yanlış negatif (FN): Yanlış negatif değerler olarak tanımlanmaktadır. Pozitif olarak tanımlanması gereken örneğin negatif olarak tanımlandığı örnek sayısıdır.

5.2.1. Doğruluk

Doğruluk, tam veri kümesinden elde edilen sonuçlara göre doğru olarak tahmin edilen verilere ait oranı gösteren bir ölçüdür. Elde edilen doğru tahminlerin, tüm tahmin sayısına oranlanmasıyla belirlenmektedir. Verilerden elde edilen doğruluk oranı, doğru şekilde tahmin edilen test etiketlerine sahip gözlemlerin sayısının toplam test gözlemleri sayısına bölünmesiyle hesaplanmaktadır. Bu değer aralığı 0 ile 1 arasında yer almaktadır ve değer arttıkça başarı oranı da aynı şekilde artış göstermektedir. Doğruluk değeri yüksek lakin

kesinlik ve duyarlılık değerine ait oranlar düşük kalıyorsa veri setinde dengesizlik olduğu gözlemlenebilmektedir (Amidi, 2018).

$$Doğruluk = \frac{TP+TN}{TP+TN+FP+FN} \quad (5.1)$$

5.2.2. Kesinlik

Kesinlik kavramı, veri kümesi üzerinden elde edilen doğru tahmin değerlerinin ne kadarının doğru sınıfa ait olduğunu belirleyen ölçümdür. Kavrama ait hesaplama işlemi, doğru pozitiflerin (TP), toplam pozitiflere (TP +FP) oranlanmasıyla gerçekleştirilmektedir.

$$Kesinlik = \frac{TP}{TP+FP} \quad (5.2)$$

5.2.3. Duyarlılık

Duyarlılık kavramı, pozitif olarak doğru bir şekilde tahmin edilen numune sayısının, pozitif olarak tahmin edilen toplam numune sayısına bölünmesiyle hesaplanmaktadır. Bu kavram sayesinde, algoritmaya ait hassasiyet verileri elde edilmektedir.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (5.3)$$

5.2.4. F1 değeri

Doğru bir karşılaştırma yapılabilmesi için yalnızca kesinlik ve duyarlılık kriterleri yeterli değildir. F1 kavramı sayesinde, belirtilen bu iki kriter birlikte değerlendirilebilmektedir ve bu sayede daha anlamlı veriler elde edilmektedir. Bu kavrama ait değer, kesinlik ve duyarlılık metriklerine ait değerlerin harmonik ortalaması alınarak elde edilmektedir, çünkü kesinlik ve duyarlılık değeri birbirine ters orantılı olarak hareket etmemelidir.

$$F1 \text{ Değeri} = \frac{Duyarlılık \times Kesinlik}{Duyarlılık + Kesinlik} \times 2 \quad (5.4)$$

5.3. Deneysel Sonular

Bu alıřma kapsamında nerilen ynteme ait deneysel sonular kategorize edildiėinde temel  kategori oluřmaktadır. Bu  kategori aıklanacak olursa, ilk kategoride; literatrde sıklıkla kullanılan znitelikler ve klasik makine sınıflandırıcıları ile gerekleřtirilen deneyler, ikinci kategoride; derin ėrenme metotları ile gerekleřtirilen deneyler, nc kategoride ise hibrit metotlar ile gerekleřtirilen deneyler olarak tanımlanabilmektedir. Hibrit yaklařımlar ise kendi ierisinde iki alt kategoriye ayrılmaktadır. İlk alt kategoride, derin ėrenme ve klasik makine ėrenmesi metotları kendi aralarında farklı kombinasyonlar oluřturularak kullanılmıřtır. İkinci alt kategoride ise Hessian detektr ile SIFT tanımlayıcı kullanılarak (HessianSIFT) hibrit bir znitelik elde edilmiřtir.

SIFT, SURF ve KAZE znitelikleri ve SVM, XGB, RG, LR sınıflandırıcıları literatrde sıklıkla kullanılmıř olup gerekleřtirilen bu alıřmada da performans kıyaslaması amacıyla kullanılmaktadır. Ayrıca yine literatrde sıklıkla kullanılan CNN, VGG16, ResNet50 metotları da bu alıřmada performanslara ait verileri elde etmek amacıyla kullanılmıřtır. Son olarak ise eřitli alanlarda hibrit yaklařımların kullanılmasıyla birlikte daha bařarılı sonular elde edildiėini belirtilen alıřmalardan ilham alınarak iki farklı hibrit yaklařım elde edilmiřtir (Aydın, 2024). İlkinde, derin ėrenme ve klasik makine sınıflandırıcılarında bulunan metotlar kendi aralarında farklı kombinasyonlarda kullanılmıřtır. Bu kombinasyonlar aıklanacak olursa, ResNet50, VGG16, derin ėrenme metotları kullanılarak znitelikler ıkartılmıřtır. Elde edilen znitelikler, SVM, XGB, LR ve RF sınıflandırıcılarıyla sınıflandırılmıřtır. Ayrıca SIFT, SURF, KAZE znitelikleri, sınıflandırma metodu olarak ise CNN derin ėrenme metodunun kullanıldıėı uygulamalar gerekleřtirilmiřtir. Hibrit yaklařımların ikinci ve son ařamasında ise HessianSIFT hibrit zniteliėi elde edilmiř olup, SVM, XGB, LR ve RF sınıflandırıcılarıyla sınıflandırılmıřtır. Tez kapsamında gerekleřtirilen deneyler řekil 5.2.'de ve deneylere ait sonular Blm 5.3.'de verilmiřtir.

SIFT	• SVM, XGB, RF, LR, CNN
SURF	• SVM, XGB, RF, LR, CNN
KAZE	• SVM, XGB, RF, LR, CNN
CNN	• CNN
ResNet50	• SVM, XGB, RF, LR, ResNet50
VGG16	• SVM, XGB, RF, LR, VGG16
HessianSIFT	• SVM, XGB, RF, LR

Şekil 5.2. Tez kapsamında gerçekleştirilen deneyler

5.3.1. Klasik öznitelikler ve klasik makine sınıflandırıcıları ile gerçekleştirilen deneyler


SIFT, SURF, KAZE özniteliklerinin klasik makine sınıflandırıcıları, SVM, XGB, RG, LR ile sınıflandırılmasıyla elde edilen veriler ve verilere ait grafikler Bölüm 5.3.1.'de detaylı olarak verilmiştir.

5.3.1.1. SIFT özniteliği ile klasik makine öğrenme sınıflandırıcılarına ait performans verileri

SIFT özniteliği ile klasik makine öğrenmesi yöntemlerinden olan SVM, XGB, RG, LR sınıflandırıcıları ile sınıflandırılmışlardır. SIFT özniteliği için en yüksek sınıflandırma performansı SVM sınıflandırıcısı ile %95,41 olarak elde edilmiştir. Deneysel sonuçlar, Tablo 5.1. ve Şekil 5.2.'de verilmiştir.

Tablo 5.1. SIFT Özniteliği – Klasik Makine Öğrenmesi Yöntemleri

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
SIFT	SVM	0,9567	0,9291	0,9407	0,9541
	XGB	0,9009	0,8784	0,8876	0,9042
	RF	0,9518	0,9057	0,9243	0,9348
	LR	0,8977	0,7537	0,7893	0,8573




Şekil 5.3. SIFT özniteliği ve klasik makine sınıflandırıcılara ait sınıflandırma performansları

5.3.1.2. SURF özniteliği ile klasik makine öğrenme sınıflandırıcılarına ait performans verileri

SURF özniteliği ile klasik makine öğrenmesi yöntemlerinden olan SVM, XGB, RG, LR sınıflandırıcıları ile sınıflandırılmışlardır. SURF özniteliği için en yüksek sınıflandırma performansı SVM sınıflandırıcısı ile %86,75 olarak elde edilmiştir. Deneysel sonuçlar, Tablo 5.2. ve Şekil 5.3.'de verilmiştir.

Tablo 5.2. SURF Özniteliği – Klasik Makine Öğrenmesi Yöntemleri

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
SURF	SVM	0,8574	0,8041	0,8248	0,8675
	XGB	0,6609	0,5789	0,6033	0,6748
	RF	0,8316	0,7709	0,7940	0,8165
	LR	0,8012	0,6391	0,6660	0,7737




Şekil 5.4. SURF özniteliği ve klasik makine sınıflandırıcılara ait sınıflandırma performansları

5.3.1.3. KAZE özniteliği ile klasik makine öğrenme sınıflandırıcılarına ait performans verileri

KAZE özniteliği ile klasik makine öğrenmesi yöntemlerinden olan SVM, XGB, RG, LR sınıflandırıcıları ile sınıflandırılmışlardır. KAZE özniteliği için en yüksek sınıflandırma performansı RF sınıflandırıcısı ile %93,07 olarak elde edilmiştir. Deneysel sonuçlar, Tablo 5.3. ve Şekil 5.4.'de verilmiştir.

Tablo 5.3. KAZE Özneliği – Klasik Makine Öğrenmesi Yöntemleri

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
KAZE	SVM	0,9029	0,8656	0,8811	0,9062
	XGB	0,8782	0,8371	0,8538	0,8818
	RF	0,9404	0,8960	0,9146	0,9307
	LR	0,8445	0,7103	0,7420	0,8257



Şekil 5.5. KAZE özneliği ve klasik makine sınıflandırıcılara ait sınıflandırma performansları

5.3.2. Derin öğrenme metotları ile gerçekleştirilen deneyler


CNN, ResNet50, VGG16 derin öğrenme metotları ile gerçekleştirilen deneylerden elde edilen veriler ve verilere ait grafik Bölüm 5.3.2.1.'de detaylı olarak verilmiştir.

5.3.2.1. Derin öğrenme metotları kullanılarak elde edilen öznitelik ile derin öğrenme sınıflandırıcılarına ait performans verileri

Derin öğrenme metotlarından, CNN, ResNet50 ve VGG16 kullanılarak elde edilen öznitelikler, derin öğrenme metotlarından olan CNN, ResNet50, VGG16 yöntemleri ile sınıflandırılmışlardır. DeneySEL sonuçlar, Tablo 5.4. ve Şekil 5.5.'de verilmiştir.

Tablo 5.4. Derin Öğrenme Öznitelik – Derin Öğrenme Sınıflandırma

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1
CNN	0,9191	0,9392	0,9281	0,9458
ResNet50	0,6435	0,6240	0,6232	0,7186
VGG16	0,9432	0,9570	0,9480	0,9525



Şekil 5.6. Derin öğrenme metotları tarafından elde edilen öznitelik ve derin öğrenme metotları sınıflandırma performansları

5.3.3. Hibrit metotlar ile gerçekleştirilen deneyler

Hibrit yöntemler iki alt kategoriden oluşmaktadır. İlk alt kategoride, derin öğrenme ve klasik makine öğrenmesi yöntemleri ile kombinasyonel olarak gerçekleştirilen deneyler verilmiştir. İkinci alt kategoride, HessianSIFT hibrit özniteliğine ait çalışmalar detaylı olarak anlatılmıştır.

5.3.3.1. Derin öğrenme ve klasik makine öğrenmesi yöntemlerine ait kombinasyonel deneyler


Derin öğrenme ve klasik makine öğrenmesi yöntemleri ile kombinasyonel olarak deneyler gerçekleştirilmiştir. Bu deneylerde kendi içerisinde ikiye ayrılmaktadır. İlk aşamada, derin öğrenme metotları ile elde edilen öznitelikler klasik makine öğrenmesi sınıflandırıcıları ile sınıflandırılmıştır. İkinci aşamada ise klasik öznitelikler, derin öğrenme metotları ile sınıflandırılmıştır. Hibrit metotlarla gerçekleştirilen deneylerin son aşamasında ise Hessian detektör ile SIFT tanımlayıcısı kullanılarak hibrit bir öznitelik elde edilmiştir. Elde edilen bu öznitelik, klasik makine öğrenmesi sınıflandırıcılarıyla sınıflandırılmıştır. Gerçekleştirilen deneylere ait veriler Bölüm 5.3.3.1.'de detaylı olarak verilmiştir.

5.3.3.1.1. ResNet50 tarafından elde edilen öznitelik ile klasik makine sınıflandırıcılarına ait performans verileri

ResNet50 kullanılarak elde edilen öznitelikler, klasik makine öğrenmesi yöntemlerinden olan SVM, XGB, RG, LR sınıflandırıcıları ile sınıflandırılmışlardır. ResNet50 yöntemi kullanılarak elde edilen öznitelikler için en yüksek sınıflandırma performansı SVM sınıflandırıcısı ile %100 olarak elde edilmiştir. Deneysel sonuçlar, Tablo 5.5. ve Şekil 5.7.'de verilmiştir.

Tablo 5.5. ResNet50 Öznitelik – Klasik Makine Öğrenmesi Yöntemleri

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
Resnet50	SVM	1	1	1	1
	XGB	0,9566	0,9376	0,9462	0,9562
	RF	0,9644	0,9419	0,9516	0,9551
	LR	0,9757	0,9795	0,9774	0,9817




Şekil 5.7. ResNet50 tarafından elde edilen öznetelik ve klasik makine sınıflandırıcılara ait sınıflandırma performansları

5.3.3.1.2. VGG16 tarafından elde edilen öznetelik ile klasik makine sınıflandırıcılarına ait performans verileri

VGG16 kullanılarak elde edilen öznetelikler, klasik makine öğrenmesi yöntemlerinden olan SVM, XGB, RF, LR sınıflandırıcıları ile sınıflandırılmışlardır. VGG16 yöntemi kullanılarak elde edilen öznetelikler için en yüksek sınıflandırma performansı LR sınıflandırıcısı ile %99,49 olarak elde edilmiştir. Deneysel sonuçlar, Tablo 5.6. ve Şekil 5.8.'de verilmiştir.

Tablo 5.6. VGG16 Öznetelik – Klasik Makine Öğrenmesi Yöntemleri

Öznetelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
VGG16	SVM	0,9908	0,9846	0,9875	0,9908
	XGB	0,9848	0,9794	0,9817	0,9847
	RF	0,9872	0,9714	0,9787	0,9837
	LR	0,9943	0,9903	0,9922	0,9949




Şekil 5.8. VGG16 tarafından elde edilen öznitelik ve klasik makine sınıflandırıcılara ait sınıflandırma performansları

5.3.3.1.3. Klasik yöntemler kullanılarak elde edilen öznitelik ile derin öğrenme sınıflandırıcılarına ait performans verileri

SIFT, SURF, KAZE kullanılarak elde edilen öznitelikler, derin öğrenme metotlarından olan CNN yöntemi ile sınıflandırılmıştır. DeneySEL sonuçlar, Tablo 5.7. ve Şekil 5.9.'de verilmiştir.

Tablo 5.7. Klasik Öznitelik – Derin Öğrenme Sınıflandırma

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
SIFT	CNN	0,8987	0,8385	0,8599	0,8915
SURF	CNN	0,7241	0,6965	0,6994	0,7627
KAZE	CNN	0,8754	0,7860	0,8086	0,8678




Şekil 5.9. Klasik metotlar tarafından elde edilen öznitelik ve derin öğrenme metotları sınıflandırma performansları

5.3.3.2. HessianSIFT hibrit özniteliğine ait deneyler

Hessian detektör ile SIFT tanımlayıcısı kullanılarak hibrit bir öznitelik elde edilmiştir. Elde edilen bu öznitelik, klasik makine öğrenmesi yöntemlerinden olan SVM, XGB, RG, LR sınıflandırıcıları ile sınıflandırılmışlardır. HessianSIFT hibrit özniteliği için en yüksek sınıflandırma performansı SVM sınıflandırıcısı ile %98,67 olarak elde edilmiştir. Deneysel sonuçlar, Tablo 5.8. ve Şekil 5.10.'da verilmiştir.

Tablo 5.8. HessianSIFT Hibrit Özniteliği – Klasik Makine Öğrenmesi Yöntemleri

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
HessianSIFT	SVM	0,9667	0,9267	0,9367	0,9867
	XGB	0,9128	0,9065	0,9127	0,9348
	RF	0,9514	0,9398	0,8978	0,9684
	LR	0,8512	0,8821	0,8765	0,9042



Şekil 5.10. Hibrit metotlar tarafından elde edilen HessianSIFT öznitelik ve klasik makine sınıflandırıcılara ait sınıflandırma performansları

5.4. Deneysel sonuçlar özet

Bu bölümde, CK+48 veri seti üzerinde gerçekleştirilen deneysel çalışmalardan elde edilen bütün sonuçlar verilmiştir. SIFT, SURF, KAZE, ResNet50, VGG16 ve HessianSIFT yöntemleri ile elde edilen öznitelikler, SVM, XGB, RF, LR sınıflandırıcılarıyla sınıflandırılmıştır. ResNet50 ve VGG16 metotlarıyla öznitelikler elde edilerek kendi içlerinde sınıflandırılmıştır. Ayrıca, SIFT, SURF, KAZE öznitelikleri derin öğrenme yöntemleri ile sınıflandırılmıştır.

Deneysel sonuçlara göre hibrit metotlardan, ResNet50, VGG16 ve HessianSIFT özniteliklerinin klasik makine sınıflandırıcılarıyla kullanılması sonucunda yüksek doğruluk oranı elde edildiği görülmektedir. Tez kapsamında gerçekleştirilen bütün bu çalışmalara ait deneysel sonuçlar Tablo 5.9.'da verilmiştir

Tablo 5.9. Deneyisel Sonuçlar

Öznitelik	Sınıflandırıcı	Kesinlik	Duyarlılık	F1	Doğruluk
SIFT	SVM	0,9567	0,9291	0,9407	0,9541
	XGB	0,9009	0,8784	0,8876	0,9042
	RF	0,9518	0,9057	0,9243	0,9348
	LR	0,8977	0,7537	0,7893	0,8573
SURF	SVM	0,8574	0,8041	0,8248	0,8675
	XGB	0,6609	0,5789	0,6033	0,6748
	RF	0,8316	0,7709	0,7940	0,8165
	LR	0,8012	0,6391	0,6660	0,7737
KAZE	SVM	0,9029	0,8656	0,8811	0,9062
	XGB	0,8782	0,8371	0,8538	0,8818
	RF	0,9404	0,8960	0,9146	0,9307
	LR	0,8445	0,7103	0,7420	0,8257
CNN	CNN	0,9191	0,9392	0,9281	0,9458
ResNet50	ResNet50	0,6435	0,6240	0,6232	0,7186
VGG16	VGG16	0,9432	0,9570	0,9480	0,9525
Resnet50	SVM	1	1	1	1
	XGB	0,9566	0,9376	0,9462	0,9562
	RF	0,9644	0,9419	0,9516	0,9551
	LR	0,9757	0,9795	0,9774	0,9817

Tablo 5.10. (Devam)

VGG16	SVM	0,9908	0,9846	0,9875	0,9908
	XGB	0,9848	0,9794	0,9817	0,9847
	RF	0,9872	0,9714	0,9787	0,9837
	LR	0,9943	0,9903	0,9922	0,9949
SIFT	CNN	0,8987	0,8385	0,8599	0,8915
SURF	CNN	0,7241	0,6965	0,6994	0,7627
KAZE	CNN	0,8754	0,7860	0,8086	0,8678
HessianSIFT	SVM	0,9667	0,9267	0,9367	0,9867
	XGB	0,9128	0,9065	0,9127	0,9348
	RF	0,9514	0,9398	0,8978	0,9684
	LR	0,8512	0,8821	0,8765	0,9042

6. SONUÇLAR

Bu çalışmada, insanlara ait yüz ifadelerinden duygu analizi yapmak amacıyla yeni bir hibrit yaklaşım kullanılmıştır. Yüz ifadelerinden duygu tespit işlemi gerçekleştirilirken, CK+48 veri seti üzerinde, klasik öznitelikler olan SIFT, SURF, KAZE, derin öğrenme metotlarından CNN, ResNet50, VGG16 ve hibrit olarak elde edilen HessianSIFT özniteliği ile klasik makine sınıflandırıcıları ve derin öğrenme metotları kullanılarak deneyler gerçekleştirilmiştir. Deneysel sonuçlardan elde edilen verilere göre;

SVM sınıflandırıcısı, SIFT ile kullanılması sonucunda %95,41, SURF ile kullanılması sonucunda %86,75, KAZE ile kullanılması sonucunda %90,62, ResNet50 ile kullanılması sonucunda %100, VGG16 ile kullanılması sonucunda %99,08 ve HessianSIFT ile kullanılması sonucunda %98,67 doğruluk oranı elde edilmiştir. XGB sınıflandırıcısı, SIFT ile kullanılması sonucunda %90,42, SURF ile kullanılması sonucunda %67,48, KAZE ile kullanılması sonucunda %88,18, ResNet50 ile kullanılması sonucunda %95,62, VGG16 ile kullanılması sonucunda %98,47 ve HessianSIFT ile kullanılması sonucunda %93,48 doğruluk oranı elde edilmiştir. RF sınıflandırıcısı, SIFT ile kullanılması sonucunda %93,48, SURF ile kullanılması sonucunda %81,65, KAZE ile kullanılması sonucunda %93,07, ResNet50 ile kullanılması sonucunda %95,51, VGG16 ile kullanılması sonucunda %98,37 ve HessianSIFT ile kullanılması sonucunda %96,84 doğruluk oranı elde edilmiştir. LR sınıflandırıcısı SIFT ile kullanılması sonucunda %85,73, SURF ile kullanılması sonucunda %77,37, KAZE ile kullanılması sonucunda %82,57, ResNet50 ile kullanılması sonucunda %98,17, VGG16 ile kullanılması sonucunda %99,49 ve HessianSIFT ile kullanılması sonucunda %90,42 doğruluk oranı elde edilmiştir. Derin öğrenme metotlarından, CNN, VGG16 ve ResNet50'nin kendi içlerinde sınıflandırılmasıyla, CNN ile %94,58, ResNet50 ile %71,86 ve VGG16 ile %95,25 doğruluk oranı elde edilmiştir. Klasik öznitelikler olan SIFT, SURF, KAZE'nin derin öğrenme metotlarından CNN ile sınıflandırılmasıyla, SIFT ile %89,15, SURF ile %76,27 ve KAZE ile %86,78 doğruluk oranı elde edilmiştir.

CK+48 veri seti kullanılarak gerçekleştirilen çalışmaların doğru sınıflandırma performansları karşılaştırıldığında hibrit yöntemler olarak gerçekleştirilen çalışmalardan ResNet50, VGG16 ve HessianSIFT özniteliklerinin SVM sınıflandırıcısı ile

sınıflandırılması sonucunda çok yüksek doğruluk oranları elde edilmiş olup ResNet50 ile SVM yöntemlerinin birleştirilmesiyle gerçekleştirilen çalışma sonucunda %100 doğruluk oranı elde edilmiştir.

Tez kapsamında, yüz ifadelerinden duygu tespiti için geliştirilen metotların, benzer hedefler için gerçekleştirilmiş ve aynı veri setinin kullanılmasıyla yapılan çalışmalara göre daha üstün başarı oranları sağladığı görülmektedir. Elde edilen bu üstün başarı oranının başlıca sebebi çalışma kapsamında geliştirilen hibrit yöntemler ile yeni metotlar ortaya koyarak birçok deneysel çalışma yapılmasıdır.

Gelecek çalışmalarda elde edilen öznelilikler ve sınıflandırma yöntemlerinin farklı veri setleri üzerinde performans değerlendirilmesi yapılarak geliştirilen bu uygulamanın daha geniş kapsamlı bir hale getirilmesi planlanmaktadır.

KAYNAKLAR

- Akar F., & Akgül, İ. (2022). Derin Öğrenme Modeli ile Yüz İfadelerinden Duygu Tanıma. *Journal of the Institute of Science and Technology*, 12(1), 69-79.
- Afshar, S., & Ali Salah, A. (2016). Facial expression recognition in the wild using improved dense trajectories and fisher vector encoding. In Proceedings of the *IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 66-74).
- Aggarwal, C. C. (2018). Neural networks and deep learning (Vol. 10, No. 978, p. 3). *Cham: springer*.
- Alcantarilla, P. F., Bartoli, A., & Davison, A. J. (2012). KAZE features. *In Computer Vision–ECCV 2012: 12th European Conference on Computer Vision, Florence, Italy, October 7-13, 2012*, Proceedings, Part VI 12 (pp. 214-227).
- Alhussan, A. A., Talaat, F. M., El-kenawy, E. S. M., Abdelhamid, A. A., Ibrahim, A., Khafaga, D. S., & Alnaggar, M. (2023). Facial Expression Recognition Model Depending on Optimized Support Vector Machine. *Computers, Materials & Continua*, 76(1).
- Angie, A. D., Connelly, S., Waples, E. P., & Kligyte, V. (2011). The influence of discrete emotions on judgement and decision-making: A meta-analytic review. *Cognition & Emotion*, 25(8), 1393-1422.
- Aydın, Y. (2016). Dengesiz veri setlerinde trafik işaretlerini tanıma, Yüksek Lisans Tezi, *Atatürk Üniversitesi, Fen Bilimleri Enstitüsü*, Erzurum.
- Aydın, Y. (2023). Sentiment Analyzing from Tweet Data's Using Bag of Words and Word2Vec. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12(2), 412-417.
- Aydın, Y. (2023). A Comparative Analysis of Skin Cancer Detection Applications Using Histogram-Based Local Descriptors. *Diagnostics*, 13(19), 3142.

- Aydın, Y. (2024). Automated identification of copy-move forgery using Hessian and patch feature extraction techniques. *Journal of Forensic Sciences*, 69(1), 131-138.
- Aydın, Y., Özeyer, G. T., & Özdemir, D. (2016). Traffic sign recognition using scale invariant feature transform and bagging based ensemble. In 2016 **24th Signal Processing and Communication Application Conference (SIU)** (pp. 605-608). IEEE.
- Ballı, Ç. (2021) Doğal dil işleme ile Türkçe içerikli paylaşımlardan sosyal medya kullanıcılarının duygu analizi, Yüksek Lisans Tezi, *Ankara Üniversitesi, Fen Bilimleri Enstitüsü*, Ankara.
- Bayrakdar, S., Akgün, D., & Yücedağ, İ. (2017). Video dosyaları üzerinde yüz ifade analizi için hızlandırılmış bir yaklaşım. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 23(5), 602-613.
- Bay, H., Tuytelaars, T., & Van Gool, L. (2006). Surf: Speeded up robust features. *In Computer Vision–ECCV 2006: 9th European Conference on Computer Vision, Graz, Austria, May 7-13, 2006*. Proceedings, Part I 9 (pp. 404-417).
- Bosch, A., Munoz, X., & Marti, R. (2007). Which is the best way to organize/classify images by content?. *Image and vision computing*, 25(6), 778-791.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Büyükarıkan., B., (2022). Aydınlatmanın Görüntü İşleme Problemlerine Etkisinin Yapay Zeka Teknikleri Kullanılarak Analizi. Doktora Tezi, *Konya Teknik Üniversitesi*, Konya
- Chen, H. Y., Huang, C. L., & Fu, C. M. (2008). Hybrid-boost learning for multi-pose face detection and facial expression recognition. *Pattern Recognition*, 41(3), 1173-1185.
- Chen, D., Ren, S., Wei, Y., Cao, X., & Sun, J. (2014). Joint cascade face detection and alignment. *In Computer Vision–ECCV 2014: 13th European Conference*,

Zurich, Switzerland, September 6-12, 2014, Proceedings, Part VI 13 (pp. 109-122). Springer International Publishing.

Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, (pp. 785-794).

Choi, H. H., & Yun, B. J. (2019). Illumination estimation for color constancy using convolutional neural network (CNN). *International Journal of Signal Processing*, 4.

Chollet, F. (2021). **Deep learning with Python**. Simon and Schuster.

Ciresan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J. (2011). Convolutional neural network committees for handwritten character classification. *In 2011 International conference on document analysis and recognition*, (pp. 1135-1139). IEEE.

Çelik, S., & Özdemir, D. (2023). Rastgele orman regresyon algoritması ile bitcoin fiyat tahmini. *Journal of Scientific Reports-B*, (008), 55-64.

Das, D. ve Chakrabarty, A. (2016) Emotion recognition from face dataset using deep neural nets, *2016 International Symposium on INnovations in Intelligent SysTems and Applications (INISTA)*, August, IEEE, 1-6.

Deisenroth, M. P., Faisal, A. A., & Ong, C. S. (2020). Mathematics for machine learning. *Cambridge University Press*.

Dhall, A., Ramana Murthy, O. V., Goecke, R., Joshi, J., & Gedeon, T. (2015). Video and image based emotion recognition challenges in the wild: EmotiW 2015. *In Proceedings of the 2015 ACM on international conference on multimodal interaction*, (pp. 423-426).

Dutta, S., & Bandyopadhyay, S. K. (2020). Early breast cancer prediction using artificial intelligence methods. *Journal of Engineering Research and Reports*, 13(2), 48-54.

- Elmas, Çetin. (2018), Yapay Zeka Uygulamaları, *Seçkin Yayıncılık 4.Baskı*, Ankara, s:25-104.
- Gandhi, R. (2018). Support vector machine introduction to machine learning algorithms. *Towards Data Science*, 7(06).
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. *MIT press*.
- Haq, H. B. U., Akram, W., Irshad, M. N., Kosar, A., & Abid, M. (2024). Enhanced Real-Time Facial Expression Recognition Using Deep Learning. *Acadlore Trans. Mach. Learn*, 3(1), 24-35.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (pp. 770-778).
- Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1), 215-243.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Jack, R. E., Garrod, O. G., Yu, H., Caldara, R., & Schyns, P. G. (2012). Facial expressions of emotion are not culturally universal. *Proceedings of the National Academy of Sciences*, 109(19), 7241-7244.
- Jaiswal, J. K., & Samikannu, R. (2017). Application of random forest algorithm on feature subset selection and classification and regression. *In 2017 world congress on computing and communication technologies (WCCCT)*, (pp. 65-68). IEEE.
- John, M., Marvin, L. M., Nathaniel, R., & Claude, E. S. (2006). *A proposal for the Dartmouth summer research project on artificial intelligence*, August 31, 1955.

- Karadağ, C., & Özdemir, D. (2022). Böbrek Tümörü Tespiti İçin Derin Öğrenme Yöntemlerinin Karşılaştırmalı Analizi. *Journal of Scientific Reports-B*, (006), 10-23.
- Karnati, M., Seal, A., Jaworek-Korjakowska, J., & Krejcar, O. (2023). Facial expression recognition in-the-wild using blended feature attention network. *IEEE Transactions on Instrumentation and Measurement*.
- Khandelwal, V. “The Architecture and Implementation of VGG-16”, <https://pub.towardsai.net/the-architecture-and-implementation-of-vgg-16-b050e5a5920b>. Son erişim tarihi: 29.06.2024.
- Konca, MS. “Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN)”, <https://mustafaserdarkonca.medium.com/evrişimli-sinir-ağları-convolutional-neural-networks-cnn-74b3d4a567f9>. Son erişim tarihi: 29.06.2024.
- Kumar HN, N., Kumar, A. S., Prasad MS, G., & Shah, M. A. (2023). Automatic facial expression recognition combining texture and shape features from prominent facial regions. *IET Image Processing*, 17(4), 1111-1125.
- Kumar, S., Sagar, V., & Punetha, D. (2023). A comparative study on facial expression recognition using local binary patterns, convolutional neural network and frequency neural network. *Multimedia Tools and Applications*, 82(16), 24369-24385.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, J., Jin, K., Zhou, D., Kubota, N., & Ju, Z. (2020). Attention mechanism-based CNN for facial expression recognition. *Neurocomputing*, 411, 340-350.

- Li, S., & Deng, W. (2020). A deeper look at facial expression dataset bias. *IEEE Transactions on Affective Computing*, 13(2), 881-893.
- Liu, Y., Wang, Y., & Zhang, J. (2012). New machine learning algorithm: Random forest. In Information Computing and Applications: *Third International Conference, ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings 3*, (pp. 246-252). Springer Berlin Heidelberg.
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60, 91-110.
- Lucey, P., Cohn, J. F., Kanade, T., Saragih, J., Ambadar, Z., & Matthews, I. (2010). The extended cohn-kanade dataset (ck+): A complete dataset for action unit and emotion-specified expression. *In 2010 ieee computer society conference on computer vision and pattern recognition-workshops*, (pp. 94-101). IEEE.
- Maden, M. (2017). Face detection using structure aware bag of words method, Yüksek Lisans Tezi, *Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü*, İstanbul.
- Marsh, A. A., Elfenbein, H. A., & Ambady, N. (2003). Nonverbal “accents” cultural differences in facial expressions of emotion. *Psychological Science*, 14(4), 373-376.
- Mbaabu, O. (2020). Introduction to random forest in machine learning. *Engineering Education (EngEd) Program Section*.
- Mehta, D., Siddiqui, M. F. H., & Javaid, A. Y. (2019). Recognition of emotion intensities using machine learning algorithms: A comparative study. *Sensors*, 19(8), 1897.
- Mikolajczyk, K., & Schmid, C. (2005). A performance evaluation of local descriptors. *IEEE transactions on pattern analysis and machine intelligence*, 27(10), 1615-1630.
- Mollahosseini, A., Graitzer, G., Borts, E., Conyers, S., Voyles, R. M., Cole, R., & Mahoor, M. H. (2014). Expressionbot: An emotive lifelike robotic face for face-

- to-face communication. In **2014 IEEE-RAS International Conference on Humanoid Robots**, (pp. 1098-1103). IEEE.
- Matsumoto, D., Keltner, D., Shiota, M. N., O’Sullivan, M. A. U. R. E. E. N., & Frank, M. (2008). **Facial expressions of emotion. Handbook of emotions**, 3, 211-234.
- Oliver, N., Pentland, A., & Bérard, F. (2000). LAFTER: a real-time face and lips tracker with facial expression recognition. **Pattern recognition**, 33(8), 1369-1382.
- Ortony, A. (2022). Are all “basic emotions” emotions? A problem for the (basic) emotions construct. **Perspectives on psychological science**, 17(1), 41-61.
- Ozdemir, D., & Kunduraci, M. S. (2022). Comparison of deep learning techniques for classification of the insects in order level with mobile software application. **IEEE Access**, 10, 35675-35684.
- Ozun. T. A., (2022). Akciğer Kanserinin Tespit Edilmesinde Derin Öğrenme Algoritmalarının Kullanılması. **Yüksek Lisans Tezi, Isparta Uygulamalı Bilimler Üniversitesi, Fen Bilimleri Enstitüsü**, Isparta.
- Özdemir, D., & Karaman, S. (2017). Investigating Interactions Between Students With Mild Mental Retardation And Humanoid Robot in Terms of Feedback Types. **Eğitim ve Bilim**, 42(191).
- Patel, D., Hong, X., & Zhao, G. (2016). Selective deep features for micro-expression recognition. In **2016 23rd international conference on pattern recognition (ICPR)**, (pp. 2258-2263). IEEE.
- Petrovici, A., & Dobrescu, T. (2014). The role of emotional intelligence in building interpersonal communication skills. **Procedia-Social and Behavioral Sciences**, 116, 1405-1410.
- Quinlan, J. R. (1993). **Program for machine learning**. C4. 5.

- Rachapudi, V., & Lavanya Devi, G. (2021). Improved convolutional neural network based histopathological image classification. *Evolutionary Intelligence*, 14(3), 1337-1343.
- Riggio, R. E., & Lee, J. (2007). Emotional and interpersonal competencies and leader development. *Human Resource Management Review*, 17(4), 418-426.
- Sanfey, A. G., Rilling, J. K., Aronson, J. A., Nystrom, L. E., & Cohen, J. D. (2003). The neural basis of economic decision-making in the ultimatum game. *Science*, 300(5626), 1755-1758.
- Shi, X., Wong, Y. D., Li, M. Z. F., Palanisamy, C., & Chai, C. (2019). A Feature Learning Approach Based On Xgboost For Driving Assessment And Risk Prediction. *Accident Analysis & Prevention*, 129, 170-179.
- Simard, P., Bottou, L., Haffner, P., & LeCun, Y. (1998). Boxlets: a fast convolution algorithm for signal processing and neural networks. *Advances in neural information processing systems*, 11.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Suthaharan, S., & Suthaharan, S. (2016). Support vector machine. *Machine learning models and algorithms for big data classification: thinking with examples for effective learning*, 207-235.
- Tareen, S. A. K., & Saleem, Z. (2018). A comparative analysis of sift, surf, kaze, akaze, orb, and brisk. *In 2018 International conference on computing, mathematics and engineering Technologies*, (pp. 1-10).
- Tekerek, A., & Yapici, M. M. (2022). A novel malware classification and augmentation model based on convolutional neural network. *Computers & Security*, 112, 102515.
- Tharwat, A., Gaber, T., Ibrahim, A., & Hassanien, A. E. (2017). Linear discriminant analysis: A detailed tutorial. *AI communications*, 30(2), 169-190.

- Turan, C., & Lam, K. M. (2018). Histogram-based local descriptors for facial expression recognition (FER): A comprehensive study. *Journal Of Visual Communication And Image Representation*, 55, 331-341.
- Uçak, K. (2012). Destek Vektör Regresyonu ile PID Kontrolör Tasarımı. *Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü*, İstanbul.
- Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *In Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition*. CVPR 2001 (Vol. 1, pp. I-I). Ieee.
- Yao, W., & Li, L. (2014). A New Regression Model: Modal Linear Regression. *Scandinavian Journal of Statistics*, 41(3), 656-671.
- Yaşar, H, (2022). Covid-19 Hastalığının Derin Öğrenme Yöntemleri Kullanılarak Tespiti. Doktora Tezi, *Konya Teknik Üniversitesi, Fen Bilimleri Enstitüsü*, Konya.

EKLER

Ek-1. Tez Çalışması Süresince Yapılan Akademik Çalışmalar

Turkes, M.K., & Aydın, Y. (2024). A New Facial Expression Recognition Methods Based On Hybrid Feature. *In Proceedings of the 8th International Conference on Computational Mathematics and Engineering Sciences*, (pp. 83).

