



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



ÖĞRENME YÖNETİM SİSTEMİ ÇEVİRİMİÇİ
SINAVLARINDA YÜZ TANIMA VE GÖZ
HAREKETLERİ TAKİBİ İLE USULSÜZLÜK
TESPİTİ

İbrahim AKYAYLA

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Ocak - 2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

İbrahim Akyayla tarafından hazırlanan “Öğrenme Yönetim Sistemi Çevrimiçi Sınavlarında Yüz Tanıma ve Göz Hareketleri Takibi ile Usulsüzlük Takibi” adlı tez çalışması 25/01/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Mustafa Servet KIRAN
(Konya Teknik Üniversitesi)

.....

Danışman

Prof. Dr. Gülay TEZEL
(Konya Teknik Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Ayşe Merve ACILAR
(Necmettin Erbakan Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İbrahim AKYAYLA

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

ÖĞRENME YÖNETİM SİSTEMİ ÇEVİRİMİÇİ SINAVLARINDA YÜZ TANIMA VE GÖZ HAREKETLERİ TAKİBİ İLE USULSÜZLÜK TESPİTİ

İbrahim Akyayla

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Gülay TEZEL

2024, 64 Sayfa

Jüri
Prof. Dr. Gülay TEZEL
Prof. Dr. Mustafa Servet KIRAN
Dr. Öğr. Üyesi Ayşe Merve ACILAR

Son yıllarda, uzaktan eğitim, küreselleşen dünyada teknolojinin yükselmesi ve pandeminin de etkisiyle hızla yaygınlaşmıştır. Eğitim öğretim faaliyetlerinin dijital ortama taşınmasıyla da uzaktan eğitimle ilgili çeşitli gereksinimler ortaya çıkmıştır. Bu gereksinimlerden en önemlileri, uzaktan eğitimde kimlik doğrulama işlemi, güvenlik ve adil bir ölçme değerlendirmenin yapılmasıdır. Bu çalışmada, OKİNAR olarak adlandırılmış olan ve bu tez kapsamında geliştirilen uzaktan eğitim sistemi (Learning Management System-LMS) ile bu gereksinimlerin karşılanması hedeflenmiştir. Bu sistemde, öğrencilerin eğitim kurumuna kaydı yapılırken diğer bilgileri yanında yüz görüntüleri de LMS sistemine eklenmektedir. LMS sisteminde, öğrencilerin sınavlarına başlamadan önce kameralarını açarak eğitim kurumu tarafından tanımlanmış sınavlara katılabildikleri video konferans odaları bulunmaktadır. Bu sistemde, ayrıca, sınav güvenliğinin sağlanabilmesi için sınav sürecinde kameradan görüntüleri video dosyası olarak kaydedilmektedir. Kaydedilen videolarda katılımcıların kimlik doğrulaması yapıldıktan sonra, ekran dışındaki yerlere baktığı yönleri analiz edilerek, sınavda usulsüzlük yapma ihtimali bulunan katılımcıların listesi çıkartılmaktadır. Diğer bir ifadeyle, bu çalışmada yüz tanıma teknolojisi ile sınavda usulsüzlük tespitini kolaylaştıracak bir çözüm geliştirilmiştir. Bu listenin online sınavlarda usulsüzlük yaparken, gözden kaçan durumları yeniden değerlendirmeye katkı sağlayacağı, çok katılımcının olduğu sınavlarda takibin kolaylaşacağı varsayılmıştır. Geliştirilen bu sistem ile, yapılan denemeler sonucunda 250 öğrenciden 234 tanesinin usulsüzlük yapmadığı, 16 öğrencinin ekran dışındaki alanlar ile ilgilendiği, 16 öğrenciden 9 unun usulsüzlük yaptığı, 7 öğrencinin değerlendirmeye uygun pozisyon almadığı tespit edilmiştir.

Anahtar Kelimeler: Göz Takibi, Kimlik Doğrulama, Ölçme Değerlendirme, Uzaktan Eğitim, Yüz Tanıma

ABSTRACT

MS THESIS

IRREGULARITY DETECTION WITH FACE RECOGNITION AND EYE MOVEMENTS TRACKING IN LEARNING MANAGEMENT SYSTEM ONLINE EXAMS

İbrahim AKYAYLA

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. Gülay TEZEL

2024, 64 Pages

**Jury
Prof. Dr. Gülay TEZEL
Prof. Dr. Mustafa Servet KIRAN
Dr. Öğr. Üyesi Ayşe Merve ACILAR**

In recent years, distance education has become rapidly widespread in the globalizing world due to the rise of technology and pandemic outbreaks. With the transfer of education and training activities to the digital environment, various requirements related to distance education have emerged. The most important of these requirements are authentication, security and fair assessment and evaluation in distance education. This study aims to meet these requirements with the Learning Management System (LMS), which is called OKİNAR and developed within the scope of this thesis. In this system, face images are added to the LMS system along with other information when students are registered to the educational institution. In the LMS system, there are video conferencing rooms where students can participate in exams defined by the educational institution by turning on their cameras before starting their exams. In this system, the images from the camera are also saved as video files during the exam process to ensure exam security. After the participants are authenticated in the recorded videos, a list of participants who are likely to commit irregularities in the exam is compiled by analyzing the directions in which they look at places other than the screen. In other words, in this study, a solution has been developed to facilitate the detection of exam irregularities with face recognition technology. It is thought that this list will contribute to the re-evaluation of situations that are overlooked while making irregularities from the camera in online exams, and will facilitate follow-up in exams with many participants. With this system, as a result of the trials, it was determined that 234 out of 250 students did not commit irregularities, 16 students were interested in areas other than the screen, 9 out of 16 students committed irregularities, and 7 students did not take a position suitable for evaluation.

Keywords: Eye tracking, Authentication, Assessment and evaluation, Distance Learning, , Face Recognition

ÖNSÖZ

Günümüz teknolojisi ile hızla yaygınlaşan uzaktan eğitim teknolojilerinin eğitim gereksinimlerini karşılaması ile birlikte sınav güvenliğinin sağlanması da önemli bir konu haline gelmektedir. Bu sebeple online sınavda yapılabilecek usulsüzlüklerin, uzaktan eğitim uygulaması üzerinden de yapılabileceği açıktır.

Bu tez kapsamında uzaktan eğitim platformlarında online sınav güvenliğini sağlamak, usulsüzlük oranı yüksek çıkan katılımcıları listelemek, güvenlik kontrolü zafiyetini minimize etmek amaçlanmıştır.

Bu çalışmam boyunca bilgi ve desteğini benden hiçbir zaman esirgemeyen danışman hocam Sayın Prof. Dr. Gülay Tezel'e, tez savunmasında eleştirileri ile tezin iyileştirilmesine katkı sunan tez savunma jüri üyeleri Prof. Dr. Mustafa Servet Kıran ve Dr. Öğr. Üyesi Ayşe Merve Acılar'a teşekkür ederim. Ayrıca bu süreçte hiçbir zaman desteğini esirgemeyen, her konuda yanımda olan canım aileme teşekkür ederim.

İbrahim AKYAYLA
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM.....	15
3.1. Veri Seti	16
3.2. Learning Management System (LMS)	17
3.3. Video Konferans Sistemleri	19
3.4. Bulut Bilişim Modelleri	22
3.5. Yüz tanıma teknolojinde kullanılan Metotlar	23
3.5.1. OpenCV (Open Source Computer Vision)	24
3.5.1.1. Haar Cascade Sınıflandırıcısı	24
3.5.2. FFmpeg Kütüphanesi	26
3.5.3. Deepface Kütüphanesi	26
3.5.4. Mediapipe Kütüphanesi	34
3.5.5. Gaze Algoritması	35
4. GELİŞTİRİLEN UYGULAMA VE BULGULAR	36
4.1. Kullanıcı Girişi	36
4.2. Yüz Fotoğrafının Kaydedilmesi.....	37
4.3. Video Konferans Ortamı.....	38
4.4. Sınava Giriş.....	38
4.5. Render Süreci.....	39
4.6. Kimlik Doğrulama	39
4.7. Göz Takibi Analizi.....	40
4.8. Bulgular	44
5. SONUÇLAR VE ÖNERİLER	48
5.1. Öneriler	49
KAYNAKLAR	51

SİMGELER VE KISALTMALAR

Kısaltmalar

BigBlueButton	: BBB
Bakış Açısı Puanı	: BAP
Bakış Tolerans Değeri	: BTD
Derin Öğrenme	: DÖ
Evrişimli Katman	: EK
Evrişimsel Sinir Ağı	: CNN
Frame Per Second, Saniyedeki Kare Sayısı	: FPS
Giriş Katmanı	: GK
Havuzlama İşlemi	: Hİ
Havuzlama Katmanı	: HK
İkili Transfer Öğrenmesi	: İTÖ
Learning Management System (Öğrenme Yönetimi Sistemi)	: LMS
Makine Öğrenmesi	: MÖ
Normalizasyon Katmanı	: NK
Öğretmenlikte Alan Bilgisi Testi	: ÖABT
Rektifiye Lineer Birim	: ReLU
Sınıflandırma Katmanı	: SK
Sigmoid Aktivasyon Fonksiyonu	: SAF
Software as a Service	: SaaS
Tam Bağlı Katman	: TBK
Uzun Kısa Süreli Bellek	: LSTM
Yapay Sinir Ağı	: YSA
Yüzdeki Duygu Tanıma	: YDT
Yapay Zeka	: YZ

1. GİRİŞ

Günümüzde teknolojinin hızla ilerlemesiyle birlikte, birçok alanda yenilikçi çözümler ortaya çıkmaktadır. Eğitim sektörü de bu gelişmelerden nasibini alarak, öğrenci performansının değerlendirilmesinde ve sınav güvenliğinin sağlanmasında çeşitli teknolojik araçlara başvurmaktadır. Bu bağlamda, yüz tanıma teknolojisi, sınav ortamlarında usulsüzlük tespiti konusunda önemli bir rol oynamaktadır. Yüz tanıma teknolojisi, bireylerin yüz özelliklerini analiz ederek benzersiz bir tanıma süreci gerçekleştirir. Bu teknoloji, sınav süreçlerinde öğrencilerin kimliklerini doğrulamak ve usulsüzlükleri önlemek amacıyla kullanılmaktadır. Özellikle sınavlarda başkasının yerine sınava giren öğrencilerin tespiti, yüz tanıma teknolojisinin sunduğu güçlü algoritmalar sayesinde daha etkili bir şekilde gerçekleştirilebilmektedir. Yüz tanıma teknolojisinin sınav ortamlarında kullanımı, öğrenci haklarına saygı çerçevesinde gerçekleştirilmeli, öğrencinin bilgileri gizli tutularak sadece yüz özelliklerinin analiz edilmesi, mahremiyetin korunmasına yönelik önlemler alınmalıdır. Bu sayede, sınav sürecinde öğrencinin kimlik doğrulaması yapılırken, kişisel verilerin güvenliği de sağlanmış olmaktadır. Manuel kimlik doğrulama süreçleri, büyük sınav grupları için zaman alıcı olabilirken, yüz tanıma teknolojisi anlık olarak tanıma işlemini gerçekleştirerek süreci hızlandırmaktadır. Bu da sınavların daha düzenli ve verimli bir şekilde yönetilmesine olanak tanımaktadır. Ancak, her teknolojik çözümde olduğu gibi yüz tanıma teknolojisinin kullanımı da beraberinde bazı etik ve hukuki soruları gündeme getirmektedir. Öğrenci mahremiyeti, veri güvenliği ve kullanıcı izni gibi konuların titizlikle ele alınması, bu teknolojinin etkin ve adil bir şekilde kullanılmasını sağlamak için önemlidir (Keskin ve ark., 2015).

Yüz tanıma teknolojileri, bireylerin yüz özelliklerini analiz ederek tanıma ve kimlik doğrulama işlemlerini gerçekleştiren teknolojik sistemlerdir. Bu teknolojiler, genellikle kameralar ve özel algoritmalar kullanarak yüzün anatomik özelliklerini, yüz hatlarını, gözlerin konumunu, burun ve ağız yapısını inceleyerek kişiyi benzersiz bir biyometrik özelliklerle tanımlar. (Keskin ve ark., 2015, Ahdid ve ark.,2016, Özdemir ve ark. 2020, Yılmaz 2021, Koç 2022)

Yüz tanıma teknolojisinde biyometrik tanıma kavramı ile her bireyin yüzü benzersiz olduğundan, kimlik doğrulama ve güvenlik uygulamalarında kullanılır. Genellikle yüksek çözünürlüklü kameralar, derinlik sensörleri veya termal kameralar gibi çeşitli sensörleri kullanır. Bu sensörler, yüzün detaylı bir şekilde yakalanmasını sağlar. Yüz tanıma teknolojisinde kullanılan algoritmalar yüzdeki belirli noktaları ve

özellikleri belirleyerek bunları matematiksel bir modele dönüştürür. Bu algoritmalar, genellikle Yapay Zeka (YZ) tekniklerinden Derin Öğrenme (DÖ) tekniklerini içerir. Birçok modern cep telefonu, yüz tanıma teknolojisini kullanarak kilidi açma veya ödeme onayı gibi işlemleri gerçekleştirmek için bu teknolojiyi entegre etmiştir. Bazı gelişmiş sistemler, yüz ifadelerini değerlendirerek kullanıcının duygusal durumunu analiz edebilir. Bu özellik, pazarlama araştırmalarında veya eğitim uygulamalarında kullanılabilir. Yüz tanıma sistemleri kullanıcı verilerini güvence altına almak ve mahremiyeti korumak adına çeşitli güvenlik önlemleri içerir. Ancak, bu konuda dikkat edilmesi gereken etik ve hukuki sorunlar bulunmaktadır. Yüz tanıma teknolojileri, birçok farklı sektörde kullanılmakta olup, güvenlik, erişim kontrolü, otomasyon ve kişiselleştirilmiş hizmetler gibi birçok uygulama alanına sahiptir (Keskin ve ark., 2015, Koç 2022, Özdemir ve ark. 2020, Yilmazer 2021, Kohli ve ark.202).

DÖ, özellikle yüz tanıma teknolojisi üzerinde önemli bir etki yaratmış, güvenlik sistemlerinden cep telefonlarına kadar birçok alanda kullanılmaya başlanmıştır. DÖ, YZ alanında kullanılan bir alt dal olan Makine Öğrenmesinin (MÖ) bir dalıdır. Yüz tespiti ile sınavdaki usulsüzlük tespiti için DÖ kullanımı ile ilgili genel tanımlamalar ve dikkat edilmesi gereken hususlar maddeler halinde aşağıda verilmiştir. (Çalışkan ve ark., 2022)

- **Yüz Tanıma Modeli Geliştirme:** DÖ algoritmaları, yüz tanıma modelleri oluşturmak için kullanılabilir. Bu modeller, öğrencilerin yüz özelliklerini analiz ederek benzersiz biyometrik özelliklerini tanıyabilir.
- **Kamera İle Yüz Tarama:** Sınav sırasında, öğrencilerin bilgisayar kameraları kullanılarak yüzleri taranabilir. Bu, DÖ modeline gerçek zamanlı olarak yüz verilerini sağlamak için kullanılabilir.
- **Kimlik Doğrulama ve Takip:** DÖ algoritmaları, sınavda doğru öğrencinin sınavı yapmasını sağlamak için kimlik doğrulama süreçlerini uygulayabilir. Bu, öğrencilerin yüzlerini tanıyarak sınav boyunca kimliklerini doğrulamak anlamına gelir.
- **Dikkat Analizi:** DÖ, öğrencilerin dikkatini izleyerek sınav sürecinde dikkat dağınıklıklarını veya şüpheli davranışları tespit edebilir. Örneğin, sürekli göz teması kopmaları veya anormal davranışlar, usulsüzlük belirtileri olabilir.
- **Veri Analizi ve Karşılaştırma:** DÖ, sınav sırasında toplanan verileri analiz edebilir ve öğrencilerin daha önceki yüz verileriyle karşılaştırarak usulsüzlük

tespiti yapabilir. Örneğin, bir öğrencinin başka bir kişinin yerine sınavı yapmaya çalışması durumunda bu tür bir anormalliği tespit edebilir.

Yüz tespiti ile sınavdaki usulsüzlük tespiti için DÖ kullanarak model oluşturma aşamaları aşağıda maddeler halinde gösterilmiştir. (Çalışkan ve ark., 2022)

- **Veri Toplama:** DÖ modelinin etkili bir şekilde çalışabilmesi için geniş bir veri setine ihtiyaç vardır. Bu aşamada, farklı yüzleri içeren geniş bir veri seti toplanır.
- **Veri Ön İşleme:** Toplanan veriler, modelin daha iyi öğrenmesi için önceden işlenir. Yüzler, belirli özelliklere (gözlerin konumu, burun şekli vb.) odaklanan özellik vektörlerine dönüştürülür.
- **Ağ Mimarisi Oluşturma:** DÖ modeli için uygun bir Yapay Sinir Ağı(YSA) mimarisi seçilir. Yüz tanıma için genellikle Evrişimsel Sinir Ağları (CNN) kullanılır.
- **Eğitim:** Model, önceden işlenmiş veri seti üzerinde eğitilir. Bu süreçte, model, özellikleri belirleme ve yüzleri tanıma yeteneğini geliştirir.
- **Tanıma ve Sınıflandırma:** Model eğitildikten sonra, gerçek zamanlı olarak yüzleri tanıma ve sınıflandırma yapılabilir.

Uzaktan eğitimde kimlik doğrulama önemli bir problemdir. Uzaktan eğitimde kimlik doğrulama konusunda literatürde farklı yöntemlerle yapılmış çok sayıda çalışma mevcuttur (Zhao ve ark. 2010, Salamh ve ark. 2022, Tejada ve ark. 2022). Aynı zamanda, uzaktan eğitim alan öğrenciler arasında adaleti koruyabilmek adına sınav güvenliğinin sağlanabilmesi için doğru kontrol mekanizmalarının geliştirilmesi de önemlidir. Uzaktan eğitim sistemlerinde mülakat veya sınavlar esnasında katılımcının kötü niyetli ve usulsüz davranışlarını tespit etmek konusunda teknolojik uygulamalara ihtiyaç vardır. Çünkü katılımcı sınav esnasında kameranın açısı dışında kalan bir alandan aldığı kopya veya destek ile kendisine haksız yardım sağlayabilir. Bu durum, sınav veya mülakat yapan kurum ve kuruluşları zora sokacak ve denetimde yetersiz olabilecekleri haksız başarı durumlarına sebep olabilir. Genelde katılımcının bu usulsüz ve haksız yardım alması sırasında göz hareketleri ve kafa hareketlerinde değişiklikler olmakta ve bu yardımlar kağıt, kitap, gibi dökümanlar veya ek monitörler ile gerçekleştirilmektedir.

Kimlik doğrulama çalışmalarında çoğunlukla tercih edilen yöntem yüz tanıma yöntemidir. Sınav güvenliğinin sağlanması amacıyla hem kimlik doğrulama yapıp hem

de öğrencilerin sınav anındaki hareketlerinin değerlendirilmesine dayanan bir çalışmaya rastlanmamıştır. Bu nedenle, bu tez çalışmasında literatürde yapılmış çalışmalardan farklı olarak, kimlik doğrulamaya ek olarak geliştirilen yüz tanıma teknolojisi ile entegre edilmiş görüntülerden anlam çıkarma yöntemleri ile sınav anında haksız yardım alma tespiti amacıyla uzaktan eğitim karar destek sistemi geliştirilmiştir. Böylece, geliştirilen model ile, uzaktan eğitim sistemlerinde yüz tanıma teknolojisi ile kimlik doğrulama sonrası, öğrenci davranışlarının da analizi yapılarak uzaktan eğitimin daha sağlıklı yürütülebilmesi ve sınav güvenliğinin artırılmasına büyük katkı sağlamıştır. Çalışmada kimlik doğrulama için OpenCV, Haar Cascade, Deepface kütüphaneleri ve sınav güvenliğinin tespiti için Mediapipe, Drawface, gaze kütüphaneleri kullanılmıştır. Tüm kütüphaneler bu çalışma için gerçekleştirilen LMS yazılımı ile bütünleşik çalışacak şekilde oluşturulmuştur.

2. KAYNAK ARAŞTIRMASI

Bu bölümde literatür taramasına ilişkin ayrıntılar yer almaktadır. Literatür taraması, yüz tanıma merkezli, duygu analizi, bulut tabanlı bilgi işlem ve duyuru sistemleriyle ilgili konuları kapsamaktadır.

Görüntü işleme ve bilgisayarlı görme uygulamaları günümüzde hayatımızın birçok alanında yaygın olarak kullanılmaktadır. Literatürde son yıllarda yapılan araştırmalara bakıldığında özellikle güvenlik alanında yapılan pek çok çalışmaya rastlamak mümkündür (Kohli ve ark. 2021, Genemo 2022, Hussein ve ark. 2022, Alsabhan 2023).

Zheng ve ark. (2009) uzaktan eğitim sistemi için görüntü tanıma teknolojilerinde öğrencinin yüzünü inceleyerek dikkatini ölçmeyi amaçlamıştır. Gauss'un görüntü işleme teknolojisi, Susan operator algoritması ve bulanık küme teorisi algoritmaları ile öğrencinin dikkatli olup olmadığı, sadece doğru cevapları elde etme olasılık durumu ile hesaplanmıştır.

Zhao ve ark. (2010), OpenCV kütüphanesi ile uzaktan eğitimde kimlik doğrulaması çalışması yapmışlardır. Kullanıcılar oturum açmak istediklerinde Yüzdeki Duygu Tanıma YDT algılama ve tanıma modülü ile yüzün konumu ve özellik çıkarma işlemleri yapıldıktan sonra yüzün veritabanında bir kimliğe karşılık gelip gelmediği tespit edilmiştir. Sistemde toplanan yüz görüntülerinin işlenmesi bir Intel şirketi tarafından gerçekleştirilmiştir. Deneyde farklı ifadeler ve farklı aydınlatmalar kullanılarak 30 farklı görüntü ile yapılan testte tanıma oranı %96.3'e ulaşmıştır. Ön işlemler yapıldığında sistemin daha yüksek tanıma oranına sahip olduğunu görülmüştür. Yüz öznitelik çıkarımı önerilmiş ve kısmen gizli 2d Markov Modeli (P2D-HMM) 'nin YDT yaklaşımı kullanılmıştır.

Tenekeci ve ark. (2014) çalışmalarında, hareketli ve sabit görüntülerdeki insanların psikolojik durumları belirlemek amacıyla görüntüden OpenCV ile duygu analizi yapmışlardır. Bunun için görüntü üzerindeki yüz tespit edildikten sonra tespit edilen yüz görüntüsünden gözler ve ağız yerleri belirlenmektedir. Sonuçta üç farklı ifade göz önünde bulundurmaktadır. Bu ifadeler “Mutlu”, “Üzgün” ve “Doğal” yüz ifadeleridir. Bu çalışmada psikolojik analizi gerçekleştirilirken yüz bölgelerinin ve analiz için kullanılacak olan gözler ve ağız bölgesinin belirlenmesi için OpenCV kütüphanesinde bulunan Haar Cascade fonksiyonları kullanmışlardır. Elde edilen görüntü, C++ ortamında geliştirilen haar cascade yüz tanıma algoritması ile analiz etmişlerdir. Çalışma sonunda elde edilen sonuçların doğruluk oranları oldukça yüksek

sevilerde olduğu görülmüştür. Bu uygulama 15 resim üzerinde denenmiş ve 11 resimde doğru sonuca ulaşmıştır. Görüntülerin çözünürlük ve parlaklık değerleri uygulamayı olumsuz etkilemiştir.

Ahdid ve ark.(2016) yapmış oldukları çalışmadaki iki boyutlu bir yüz tanıma modeli geliştirmişlerdir. Yüzdeki özellik noktalarını algılama ve bir mesafe hesaplaması yapılması amaçlanmıştır. Mesafe hesaplamalarında Öklid ve Jeodezik algoritmaları kullanılmıştır. Veriseti olarak ORL ve Yale yüz veritabanları kullanılmıştır. Sınıflandırma adımı için K-En Yakın Komşu algoritması (kNN) , Yapay Sinir Ağları (ANN) ve Destek Vektör Makinaları (SVM) kullanılmıştır. SVM açısından ANN ve kNN algoritması sınıflandırıcılarından daha yüksek test başarısı olduğu görülmüştür.

Jayalekshmi ve ark. (2017) YDT ve duygu analizi için SVM, rastgele orman algoritması ve kNN kullanılarak sınıflandırma sistemi çalışması yapmışlardır. Çalışmada, otomatik olarak çalışacak bir sistem önerilmektedir. Bu çalışmada görüntüden yüz ifadesinin çıkarılması ve çıkarılan yüzün sınıflandırılmasına odaklanılmıştır. Sistem, basitleştirilmiş yüz elde etmek için Viola Jones Yüz Algılama algoritması ve yüz özellikleri çıkarmak için Zernike momentleri, LBP ve DCT dönüşümü yöntemlerini ve etkin özellikler için özellik seçim algoritması kullanmıştır. Deneyler JAFFE veri seti üzerinde gerçekleştirilmiş ve ROC eğrisi için elde edilen başarı % 90.14 bulunmuştur.

Ko (2018) yapmış olduğu çalışmada YDT için bir araştırma yapmıştır. Son yıllarda YDT ile ilgili çok fazla çalışma yapılmıştır ancak DÖ algoritmaları ile kombinasyonu sayesinde YDT'nin performansı önemli ölçüde iyileştirilmiştir. YDT iki bölümde incelenebilir. Birincisi yüz ve yüz mimik tespiti, ikincisi ise özellik çıkarma ve ifade sınıflandırmasıdır. Standart YDT'de kullanılan sınıflandırma algoritmaları genellikle SVM, Adaboost ve rastgele orman algoritmalarıdır. Bir DÖ algoritması olan CNN, öğrenilen modelin anlaşılmasına yardımcı olmak için giriş görüntülerini görselleştirir ve duyguları anlayabilmek için daha önce eğittiğimiz ağların kapasitelerini göstermektedir. YDT, duyguları bilgisayarlarda daha anlamlı hale getirdiği için, gelecekteki uygulamaları ile ilgili bir çok çalışmanın yapılması, en büyük avantajı haline getirmektedir. YDT, için gelecekteki beklenti Nesnelerin İnterneti (Nİ) sensörleri ile birlikte birleşirse anlık mikro ifadeler de dahil olmak üzere mevcut tanıma oranının insanlarla aynı seviyeye çıkmasıdır.

Mehendale (2020) yapmış olduğu çalışmada CNN kullanarak yüzdeki duyguları tanımayı amaçlamıştır. Çalışmada kullanılan CNN modeli iki bölümlü CNN'yı temel

olarak almıştır. Birinci bölümde resimden arka planın kaldırılması ve ikinci bölümde yüz özellik vektörünün çıkarılması sağlanmıştır. Çalışmada Cohn-Kanade veri seti kullanılmıştır. Çalışmada 750 binden fazla görüntü kullanılmıştır ve test edilmiştir. Çalışmada görüntü sayısı arttıkça doğruluk oranının düştüğü keşfedilmiş olup CNN modelinin doğru çalışması için ideal görüntü sayısının 2000-10000 görüntü olduğu bulunmuştur. Çalışmada önerilen modelin doğruluğu %96 olarak hesaplanmıştır.

Özdemir ve ark. (2020) uzaktan eğitimde yüz tanıma teknolojisi ile üniversiteye öğrenci katılım oranını belirleme üzerine çalışma yapmışlardır. Görüntülere özel filtreler uygulanmış, görüntü sayısı artırıldığında başarı oranının %80 i aştığı görülmüştür. Önerilen tasarım modeli Visual Studi.Net platformunda geliştirilmiş ve C# dili kullanılmıştır. Veritabanı yönetim sistemi olarak SQL server ve imaj için EmguCV kütüphanesi kullanılmıştır. Sunulan modelin uzaktan eğitimde devam durumuna çözüm sağlaması hedeflenmiştir.

Dang ve ark. (2020) DÖ ile duygu analizinde karşılaştırmalı bir çalışma yapmışlardır. Verimlilik ve duygu analizinin doğruluğu, doğal ortamlarda karşılaşılan zorluklar tarafından engellenmektedir. DÖ modellerinin NLP zorluklarına çözüm olduğu bilinmektedir. Veri kümelerinde kelime yerleştirme ve TF-IDF kullanılmıştır. Veriler DÖ modellerine girmeden önce dönüştürülmüştür. DNN, CNN, RNN için analiz yapılmıştır. Duygu analizi için DÖ modellerini kullanmak, bu modelleri metinle birleştirmek ve ön işleme teknikleri geniş bir perspektif sunmuştur. DNN ve CNN hibrit yaklaşımlar olarak tanımlanmıştır. CNN, RNN ve LSTM gibi ortak tekniklerin ayrı ayrı test edilmesi gerektiği görülmüştür. CNN in diğer modellerden daha iyi performans gösterdiği ortaya konmuştur. RNN güvenilirliği CNN den fazla ancak hesaplama süresi çok daha uzun olduğu görülmüştür.

Safali ve ark. (2021) DÖ ve YDT'yi bir araya getirdi. Bu araştırma, DÖ tabanlı yüz ifadesi tanıma ve yüz ifadesi tanıma yöntemlerini test etti. VGG-16, AlexNet ve ZF Net mimarileri ile eğitilmiş modellerin başarı oranları karşılaştırılmıştır. VGG-16 mimarisi referans alınarak geliştirilen model %92,03 başarı oranına sahipti. Modelin giriş katmanındaki girdi boyutlarına göre eğitim kümesinin oluşturulması, başarı oranını etkileyen en önemli faktörlerden biridir. Veri kümesi oluştururken kişilerin çeşitli poz ve çözünürlükteki fotoğraflarının kullanılması da başarı oranını artırmıştır. Alex Net, VGG-16 ve ZF Net mimarileri kullanılarak inşa edilen modellerin başarı oranları ve eğitim adımlarının sayısı arttıkça arttı. Diğer modellere kıyasla VGG-16 ve YDT modelleri başarılı oldu.

Kohli ve ark.(2021) yapmış oldukları çalışmada bilimsel sınav sahteciliğini tespit etmek için yeni bir yaklaşım sunmaktadırlar. Çalışmada kullanılan veri seri 7638 görüntüden oluşmaktadır. Sunulan yöntemde üç boyutlu CNN modeli, OpenCV ve Google Tensorflow kullanılmıştır. Çalışmanın başarı oranı %95 olarak hesaplanmıştır.

El Barachi ve ark. (2021) hibrit makine öğrenmesi yaklaşımı ile kısmen odaklanmış yüzlerin duygu analizi üzerine çalışma yapmışlardır. Yapılan çalışma doğru duyguyu elde etmek için, doğrudan alınmamış görüntülerden, kısmen kapatılmış yüzler, farklı açılar ve çözünürlüklerden oluşan görüntüler kullanılmıştır. MÖ algoritması olarak CNN ve SVM kullanılmıştır. Modelde 25400 yüz içeren 4690 resim kullanılmıştır. Yüz duyarlılığı için %89,9, yedi duygu için (öfke, üzüntü, şaşkınlık, korku, mutluluk, kahkaha, gülümseme,) ayırım yaparken %87,4 doğruluk elde edilmiştir.

Yılmaz (2021) çalışmasında bulut bilişim tabanlı yüz tanıma teknolojisi ile akıllı duyuru sistemi tasarımı uygulaması yapmıştır. Bu uygulamada bulut servisleri ve yüz tanıma ise Viola Jones, Özyüz ve Fisher yüz algoritması kullanılmıştır. Yapılan anket ile bu sistemi, katılımcıların %85'i faydalı bulduğu sonucuna varılmıştır.

Singh ve ark. (2021) yapmış oldukları çalışmada bir kişinin farklı yüz ifadelerini tespit etmek için bir yaklaşım sunmayı amaçlamışlardır. Çalışmada FER-2013 veri seti kullanılmıştır ve veri seti içerisinde farklı duyguların yer aldığı 35887 görüntü yer almaktadır. Çalışmada çeşitli aktivasyon fonksiyonları kullanılmıştır. Aktivasyon fonksiyonlarının karşılaştırmalı bir çalışması yapılmıştır.

Baffour ve ark.(2022) yüzlerdeki duygu tespiti ve tanınmasında DÖ algoritmaları üzerine bir araştırma yapmışlardır. Yüzden Duygu Tanıma (YDT) insanlar ve bilgisayarlar arasındaki duygu aktarımının %55'ini oluşturmaktadır. Çalışmada kullanılan CNN mimarisi, SVM gibi bilinen diğer mimariler üzerinde üstünlük elde etmiştir.

Borgalli ve ark.(2022) çalışmalarında CNN kullanarak YDT için bir DÖ modeli geliştirmeyi amaçlamışlardır. Çalışmada kullanılan veri setleri FER13, CK+ ve JAFFE olup veri seti eğitimi için K-katlı çapraz doğrulama yöntemi kullanılmıştır. Çalışmada kullanılan 7 farklı duygu (öfke, korku, tiksinti, tarafsızlık, üzüntü, mutsuzluk ve şaşkınlık) için % 91.58'lik bir başarı elde edilmiştir.

Tejada ve ark. (2022) yapmış oldukları çalışmada YDT için bir yüz ifadesi görüntüsünün oluşturulması ve doğrulanması üzerine araştırma yapmışlardır. Ancak kültürel bağlama uyum sağlamak ve karmaşık duyguların tanınması YDT'de zorluğa

sebeptir. Veri seti oyunculuk deneyimi olmayan kişilerden arka planı açık renkli ve üstten aydınlatmalı bir ortamda kaydedilen görüntülerden oluşmaktadır. Çalışmada SVM kullanılmıştır. SVM sınıflandırıcısını geliştirmek için OpenCV, Dlib ve Scikit-learn Python kütüphanelerinin bir kombinasyonları kullanılmıştır. Çalışmada karmaşık duyguları değerlendirmek için kültürlerarası yüz ifadeleri ve açık kaynaklı çözümler kullanıldığından, veri seti farklı araştırma bağlamında da faydalı olabileceğine inanılmaktadır.

Mohanta ve ark. (2022) çalışmalarında YDT görüntü analizindeki eğilimler ve zorlukları üzerine bir inceleme yapmışlardır. Çalışmanın amacı YDT sürecine genel bir bakış sunmanın yanında bazı yöntemlerin karşılaştırılmasını sağlamaktır. Ayrıca bu çalışmada PRISMA model gösterimi de ele alınmıştır. Sonuç olarak çalışmada kullanılan PRISMA model YDT alanında bir çok zorluğu daha kolay çözmeye olanak sağlamaktadır.

Singhal ve ark. (2022) çalışmalarında Makine Öğrenmesi (MÖ) tabanlı bir model kullanılarak YDT yapmayı amaçlamışlardır. Yüz üzerinde yer alan dudak hareketleri, kaş hareketleri, gözler vb. ile YDT yapılmıştır. Çalışmada CNN modeli kullanılmıştır. Çalışmada FER-2013 veri seti kullanılmıştır ve yaklaşık 30000 görüntü içermektedir. Eğitim verisi için 28709 görüntü ve test verisi için 3589 görüntü kullanılmıştır. Önerilen model sonucunda %92 başarı elde edilmiştir.

Salamh ve ark. (2022) çevrim içi görüntülü arama yöntemi ile derslerin işlendiği bir sistemde DÖ kullanarak kimlik doğrulama çalışması yapmıştır. Yüz tanımayı iyileştirmede SVM kullanmışlar ve avantajlı olduğu görülmüştür. Çalışmada yüz veritabanı Essex Üniversitesi, Bilgisayar Görme Bilimi Araştırma Projeleri'nde dört veri klasörü (Faces94, Faces95, Faces96, Faces) temin edilmiştir. Öğrencilerin çoğu 18 ila 20 yaş arasındadır. Görüntüler 180 x 200 piksel çözünürlüğe sahiptir. Deneyde 5 katlı çapraz doğrulama kullanılmıştır. Face94 ve Grimace veri kümeleri için %100 doğrulukla diğer yöntemler ve Face95 için %99.86'ya ulaşır. Face96 durumunda model iyi bir doğruluk elde ediyor. Resnet50 ve densenet201 ile karşılaştırıldığında 99.54 doğruluk veriyor. Sonuç olarak Inceptionv3'un en etkili yöntem olduğunu görülmüştür. Gelecek çalışmalarda YDT modeli kullanmak, öğrenme süreçleri üzerinde önemli bir etki sağlayabilir.

Akar ve ark. (2022) DÖ modeli ile yüz ifadelerinden YDT üzerine çalışma yapmışlardır. Çalışmada, KDEF ve PICS veri setlerini kullanmış, öznetelik çıkarımı için CNN kullanılarak yeni bir model geliştirilmiştir. PICS veri setinde 322 görüntü ve

KDEF veri setinde 4900 görüntü bulunmaktadır. Veri artırma yöntemi, yüksek başarı için büyük veri gerektiğinden, PICS veri setindeki görüntüler için kullanılmıştır. PICS 4830'da görüntülenmiştir. Bu iki veri seti ayrı ayrı eğitildi. VGGNet modeli uygulandı. Veri setinde yedi farklı duygu sınıfı incelenmiştir: korku, öfke, iğrenme, mutluluk, nötr, üzüntü ve şaşkınlık. KDEF veri setinde %97.44 ve PICS veri setinde %98.24 doğruluk değeri elde edildiğinden, yüksek bir başarı oranı elde edildi. Duygusal ifade içeren daha büyük veri setleriyle veya duygusal ifade içermeyen farklı veri setleriyle modelin eğitilmesinin yararlı olacağı öngörülmüştür.

Subudhiray ve ark.(2023) yapmış oldukları çalışmada İkili Transfer Öğrenmesi(İTÖ) ve SVM kullanılarak YDT yapılmasını amaçlamışlardır. Çalışmada VGG16, ResNet50, Inception ResNet, Inception ResNet, AlexNet gibi CNN tabanlı algoritmalar kullanılmıştır. Her Transfer Öğrenmesi (TÖ) özellik vektörleri, farklı İTÖ çiftlerini elde etmek için sıralanır ve bir SVM sınıflandırıcısına girdi olarak beslenmektedir. Çalışmada kullanılan İTÖ'yü doğrulamak için Japon Kadın Yüz İfadesi, Genişletilmiş Cohn-Kanade Veri Kümesi, Karolinska Yönlendirilmiş Duygusal Yüzler ve FER 2013 veri setleri kullanılmıştır. Sonuçlara göre çalışmada sunulan İTÖ modeli YDT için başarılı olduğu görülmüştür.

Gupta ve ark. (2023) çalışmalarının amacı Derin Öğrenme (DÖ) modelleri kullanılarak çevrimiçi öğrenme kapsamındaki yüz ifadelerini ve öğrenci katılımını tespit etmektir. Çalışmada Inception-V3, VGG19 ve ResNet-50 gibi DÖ algoritmaları kullanılmıştır. Çalışmada kullanılan veri setleri FER-2013, CK+ ve RAF-DB gibi çeşitli veri setleri olarak belirlenmiş ve karşılaştırmalar yapılmıştır. Sonuçlar, önerilen model, karşılaştırılan veri setleri ve kendi oluşturdukları veri seti üzerine karşılaştırma yapıldığında, Inception-V3 algoritmasında %89.11, VGG19 algoritmasında %90.14, ResNet-50 algoritmasında % 92.32 doğruluk elde edilmiştir. Çalışmada önerilen model için en yüksek başarıyı ResNet-50 vermiştir.

Kotsiantis ve ark. (2004) uzaktan eğitim sisteminde kayıtlı öğrenciler üzerinde yaptığı çalışmada öğrencilerin demografik bilgilerinden ve birkaç yazılı ödev notundaki performansından eğitim seti oluşturmuşlardır. Oluşturdukları eğitim setinde en iyi performansı vermesi için 6 algoritma ile iki deney yapılmıştır. Çıkan sonuç ile Naive Bayes algoritmasından en iyi sonucu aldıkları görülmüş ve tatmin edici bir yazılım destek aracı oluşturmuşlardır. Yeni öğrencilerin performansını tahmin edebilecek bir sonuca ulaşılmıştır.

Zainuddin ve ark. (2017) uzaktan eğitimde şifre ile öğrencinin doğrulanamama sorununa karşı Linear Discriminant Analysis (LDA) algoritması ile yetkili kişileri tanıyabilen bir sistem geliştirmişlerdir. İstemci sunucu tarafında iki farklı programlama dili php ve java kullanılmıştır. 10 katılımcı her biri 8 resim ile oturum açma testleri gerçekleştirir. Sistemde kayıtlı olmayan yüzlerde %93 e varan doğruluk seviyesi bulunmuştur.

Peng ve ark. (2017) Çince Duygu Analizi Araştırmasına Bir Bakış çalışması yapmıştır. İngiliz dilinde duygu analizi büyük gelişmeler göstermişken, Çin duygu analizi araştırması bununla birlikte Çin e-iş ve e-pazarlarının katlanarak büyümesine rağmen önemli ölçüde gelişmiştir. Bu çalışmanın amacı Çin duygu analizinin geçmişini, bugününü ve geleceğini, hem tek dilli hemde çok dilli bakış açıları ile incelemektir. Çince'de üç farklı sınıflandırma çerçevesi aracılığıyla duygu sınıflandırması yapılmıştır. Son olarak, çok dilli yaklaşıma dayalı duygu sınıflandırması tanıtılır.

Hussein ve ark. (2018) yapmış olduğu duygu analizi zorlukları üzerine bir anket çalışması gerçekleştirmiştir. Bu çalışma, duygunun önemi ve etkilerini tartışmaktadır. Kırk yedi gazete arasındaki iki karşılaştırmaya dayanarak duyarlılık değerlendirmesindeki zorluklar analiz edilmiştir. İlk karşılaştırmaya göre duygu inceleme yapısı ile duygu analizi zorlukları arasındaki ilişkiye dayanarak analiz yapılmıştır. İkinci karşılaştırma, duygu analizi zorluklarının doğruluk oranına dayanmaktadır. Elde ettikleri sonuçlar, duyguların değerlendirilmesinde duyarlılık zorluklarının önemini ve doğruluğu artırmak için uygun sınavın nasıl seçileceğini ortaya koymaktadır.

Zhang ve ark. (2018) tarafından duyarlılık analizi için DÖ anket çalışması yapılmıştır. DÖ, verilerin çok katmanlı sunumlarını veya özelliklerini öğrenen ve en gelişmiş tahmin sonuçlarını üreten güçlü bir MÖ tekniği olarak ortaya çıkmıştır. Birçok uygulama alanında DÖ başarısının yanı sıra, DÖ son yıllarda duyarlılık analizinde de kullanılmaktadır. Bu çalışmada DÖ ilgili bir genel bakış sunulmaktadır ve sonra onun duyarlılık analizindeki mevcut uygulamaları hakkında kapsamlı bir anket sunulmaktadır. Duygu analizlerine DÖ uygulamak, son zamanlarda popüler bir araştırma konusu haline geldi. Bu çalışmada çeşitli örnekler sunulmuştur. Bu DÖ tekniklerinin çoğu, duyarlılık analizi görevleri için son teknoloji sonuçlarını göstermiştir.

Xu ve ark. (2019) BiLSTM'ye Dayalı Metinlerde Yorumun Duygu Analizi çalışmasını yapmışlardır. Duyguda analiz çalışmalarında daha çok dağıtık kelime

gösterimi kullanılmaktadır. Ancak, dağıtılmış sözcük gösterimi sadece kelimenin anlam bilgisini dikkate alır, ancak kelimenin duygu bilgisini yok sayar. Burada kağıt, duyarlılığın katkısını bütünleştiren gelişmiş bir kelime temsil yöntemi önerilmiştir. Bilgiyi geleneksel TF-IDF algoritmasına dönüştürür ve ağırlıklı kelime vektörleri üretir. Ağırlıklı kelime vektörleri, bağlam bilgisini yakalamak için çift yönlü uzun kısa süreli belleğe (BiLSTM) girilir ve yorum vektörleri daha iyi temsil edilir. Yorumun duygu eğilimi, ileri beslemeli SA sınıflandırıcısı ile elde edilmiştir. Aynı koşullar altında, önerilen duyarlılık analiz yöntemi, RNN, E , LSTM ve NB'nin duygu analizi yöntemleri ile karşılaştırılmıştır. Bu deneysel sonuçlar, önerilen duygu analizi yönteminin daha yüksek kesinlik, hatırlama ve F1'e sahip olduğunu göstermektedir. Yöntemin, yorumlarda yüksek doğrulukla etkili olduğu kanıtlanmıştır.

Yue ve ark. (2019) çalışmalarında sosyal medyada duygu analizi anketi yapmışlardır. Çalışmada duygu analizinde kullanılan farklı veri ve araç türleri incelenmiştir. Yapılan anket duyguları kategorize edip sınıflandırmıştır. Çoklu perspektiften analiz ve araştırmaları, görev odaklı, ayrıntı odaklı ve metodoloji odaklıdır. Farklı veri ve araç türleri araştırılmıştır. Bu sonuçlar ile başarıları ve sınırlamaları hakkında öneride bulunabilme yeterliliği kazanılmıştır. Çok modlu duygu analizinde (MSA) genel bir bakış sunulmuştur. MSA yöntemleri genel olarak duygu analizinde yaygın olarak kullanılmadığından NLP araştırma alanının gelecekte yapılacak araştırmalar için önemli olduğu görülmüştür.

Artsin ve ark.(2020), kitlesel açık çevrimiçi derslerde öğrencilerin kendi kendine öğrenme becerilerini inceleme çalışması yapmışlardır. Araştırma, nicel tarama modelini kullanarak yürütüldü. Anadolu Üniversitesi'nin AKADEMA adlı kitlesel açık çevrimiçi ders platformundan toplanan veriler kullanılmıştır. Kendi Hızında Öğrenmeye Dayalı Derslerde Öz-Yönetimli Öğrenme Becerileri Ölçeği, veri toplama sürecinde kullanılmıştır. 2136 öğrenci bu ölçeğe cevap verdi. Araştırma, yaş aralığı, ders tamamlama durumu, cinsiyet ve eğitim düzeyi dahil olmak üzere çeşitli değişkenlerin fark analizlerini içeriyordu. Araştırmaya göre, kadınların erkeklerden daha iyi özyönetimli öğrenme becerileri olduğu gösterilmiştir. Araştırmanın sonuçları, öğretim tasarımcıları, eğitimciler, uygulayıcılar ve karar vericilere tavsiyelerde bulunabilir.

Genemo (2022) sınavlarda kopya çekimini izlemek için şüpheli etkinlik tanımlama çalışması yapmıştır. Çalışma için önerilen modelde 63 katman derinliğinde CNN modeli önerilmiştir ve "L4-BranchedActionNet" olarak adlandırılmıştır. Önerilen modelde CIFAR-100 veri seti üzerine ayrıca test edilmiştir. % 89. 80 doğruluk

göstermiştir. Çalışmada elde edilen özellikler optimize edilebilmesi için karınca kolonisi sistemi kullanılmıştır. Ardından SVM algoritması kullanılmıştır ve %93'lük bir doğruluk elde edilmiştir.

Hussein ve ark.(2022) MÖ teknikleri kullanılarak otomatik hile tespiti çalışması yapmışlardır. Bu çalışma sayesinde sınava giren öğrencilerin izlenmesi ve hilelerin tespiti kolaylaşacaktır. Çalışmada kullanılan veri seti Canon 70D sensörlü kamera ile çekilen Haşimi Üniversitesi Bilgi Teknolojileri Fakültesi'ndeki bir sınıfta görüntülenen görüntülerden oluşmaktadır. Sensör saniyede 24 görüntü kaydetmiştir. Görüntülerin boyutu 1920×1080 pikseldir. Çalışmada K-ortalama kümelemesi algoritması kullanılmıştır. Eğitim verisi için 1000 görüntü ve test verisi için 500 görüntü çekilmiştir. Sonuç olarak geliştirilen model % 91 doğruluk başarısı elde etmiştir.

Dursun ve ark. (2022) göz bebeklerinin yüksek doğrulukta belirlenmesi için bir çalışma yapmışlardır. Önerilen yöntemde düşük kalitedeki görüntülerden de yaptıkları iyileştirmeler ile göz bebeği tespiti sağlanabilmiştir. Geliştirilen algorithmada göz bebeğinin daire şekli ve gözün gradyan bilgilerine dayalı yöntem kullanmışlardır.

Rodríguez-Villalobos ve ark. (2023) yaptıkları çalışmada uzaktan eğitim sınavlarında izleme yöntemleri ve öğrenci performansını araştırmışlardır. Çalışmada uzaktan eğitim kapsamında test izlemenin üç yöntemini izlemiştir. Bu yöntemler gözetmensiz, yüzyüze ve yazılım kullanarak şeklindedir. Çalışmada toplam 296 öğrenci verisi kullanılmış ve notları test edilmiştir. İki değişkenli çoklu doğrusal regresyon modeli kullanılarak her yöntem için öğrencilerin akademik performansı üzerine etkisi ölçülmüştür. Çalışmada elde edilen sonuçlara göre, gözetmensiz yapılan sınavlar yüzyüze yapılan sınavlara göre 7 puan daha düşük olduğu gözlemlenmiştir.

Alsabhan (2023) yapmış olduğu çalışmada MÖ yöntemleri ve Uzun-Kısa Süreli Bellek (LSTM) kullanılarak yükseköğretimde kopya çekmeyi tespit eden bir model geliştirmiştir. Çalışmada kullanılan veri seti açık olarak erişilebilen ve üniversite ortamındaki öğrenci davranışlarına ilişkin bilgileri içeren 7WiseUp veri setidir. Çalışmada kullanılan algoritmalar CNN, Tekrarlayan Sinir Ağı (TSA), UKSB olarak belirlenmiştir. Çalışmada önerilen modelin başarı oranları CNN mimarisi için %84.52, LSTM mimarisi için %81 ve CNN mimarisi için %86 olarak elde edilmiştir.


Kaynakda bulunan çalışmalarda yüz tanıma, yüzden duygu analizi gibi belirli konulara odaklanılmış olduğu görülmektedir. Güncel teknolojiler ile göz takibi, yüz tanıma ve yüz takibi gibi özelliklerin , bu tez çalışması kapsamında geliştirilen öğrenme

yönetim sisteminde Okinar LMS ile birlikte uygulaması gerçekleştirilmiştir. Veri seti Okinar LMS sisteminde eğitim gören öğrencilerin katılımı ile oluşturulmuştur.



3. MATERYAL VE YÖNTEM

Bu tez çalışması, kimlik doğrulama ve usulsüzlük tespiti olmak üzere iki aşamada gerçekleştirilmiştir: Kimlik doğrulama için yüz tanıma aşamasında Python OpenCV ve Deepface kütüphaneleri kullanılmıştır. Sınavda gerçekleştirilebilecek önemli usulsüzlüklerden biri de sınava bir başkasının girmesi olduğu için yüz tanıma işlemi de bakış açısı puanı (BAP) kadar önemlidir. Bu nedenle, öğrencinin sınavlarda usulsüz davranışlarda bulunup bulunmadığının tespit edilmesinde, kopya çekme teşebbüsleri öğrencilerin sınav anındaki görüntülerinden yüz tespitinden sonra, göz tespiti ve göz bebeği tespitinde Mediapipe Gaze kütüphanesi kullanılmıştır. Uzaktan eğitim sistemlerinde tüm bu süreçlerin birlikte yürütülmesi oldukça kapsamlı bir konu olduğu için, bu çalışmada yeni bir model eğitilmemiş, dünya genelinde kullanılan, yüksek başarı oranına sahip modeller kullanılarak modüllerin bir arada, yüksek doğruluk oranı ile sonuçlar vermesi için çalışmalar gerçekleştirilmiştir. Çalışmaların akış diyagramı Şekil 3.1’de gösterilmiştir. Öğrenci LMS sistemine katılım sağladıktan sonra video konferans salonuna girer ve kamerasını açar, sonrasında sınav başlatarak görüntüsü kayıt altında iken sınavı çözmeye başlar. Video konferans kapatıldıktan sonra toplanan kamera görüntüleri sistemde video dosyasına dönüştürülerek saklanır. Bu video görüntülerinden yüz tanıma ile kişi tespit edilir ve kimlik doğrulaması yapılır. Video görüntüsünden BAP ile elde edilen puan sonuçlar bölümüne iletilir.



Şekil 3.1. Çalışmanın akış diyagramı

3.1. Veri Seti

Bu tez çalışmasında, veri setini oluşturmak için yerli imkanlar ile geliştirilmiş Okinar LMS yazılımı kullanılmıştır. Eğitim sektöründe 2020 yılından beri kullanılan Okinar'ın Öğretmen ve Öğrencilerden oluşan kitlesi tez çalışmasında kullanılacak veriler için anonim olarak destek vermişlerdir (Okinar, 2024).

Okinar, uzaktan eğitim çözümleri sunan bir Software as a Service (SaaS) girişimi olarak Hacettepe Teknokent'te kurulmuştur. Bu yazılım, öğretmen ve öğrencinin aynı yerde olmadığı, örgün öğretimin yürütülemediği durumlarda, uzaktan eğitimin sağlıklı biçimde yürütülebilmesini sağlamaktadır. 2023 yılı sonu itibarı ile aktif öğrenci sayısı 10000'e ulaşmıştır. Web tabanlı bir projedir, PHP dili ve MYSQL veri tabanı kullanılarak geliştirilmiştir. Bu LMS sistemi öğrencilerin video konferans yöntemiyle çevrimiçi derslere, sınavlara katılmalarını sağlamakta, ölçme ve değerlendirme süreçlerinde eğitim kurumlarına çözümler sunmaktadır. Okinar yazılımında canlı dersler için, video konferans sistemi olarak açık kaynak bir teknoloji olan BigBlueButton (BBB) yazılımı kullanılmıştır. Uzaktan eğitim kurumları Okinar LMS yazılımı ile Canlı dersler ve video derslerini aktif olarak yürütebilmektedir. Öğrencilerin yarısı Öğretmenlik Alan Bilgisi Testi (ÖABT), yarısı farklı eğitim kurumlarından eğitim alan öğrencilerden oluşmaktadır. Bu çalışmada ÖABT öğrencilerinin eğitim aldığı bir eğitim kurumunda kullanılan LMS ile kurumun öğrencilerinden aydınlatma metni onayı alınarak, KVKK kapsamında veriler temin edilmiştir. Öğrencilerin kimlik doğrulaması için kamera görüntüsü ve sınavdaki ekranda bakma görüntüsü, canlı derslere katılımı, ders kayıtlarına erişimi, sınav sonuçları, sınavda kalma süreleri veri tabanında tutulmaktadır.

Seminer çalışmasında ön çalışma olarak, Okinar LMS yazılımı ile öğrencilerin sınav sonuçları KNN ve Lojistik Regresyon algoritmaları ile öğrencilerin sınav süreleri ve doğru yanlış sayılarına göre sınavda usulsüzlük yapıp yapmadıkları değerlendirilmiştir. Öğrencilerin sınav süresi ve doğru sayısına göre usulsüzlük yapıp yapmadığı hakkında veriler uzman eğitimciler tarafından LMS üzerinden değerlendirilmiş ve bu bilgiler eğitim setini oluşturmuştur. KNN algoritmasının daha yüksek doğruluk oranı ile sonuç verdiği karar destek mekanizması ile sınavda usulsüz davranmış olma ihtimali yüksek öğrenciler belirlenmiştir.

Öğrencilerin yüz ve diğer tüm verileri Okinar uzaktan eğitim yazılımından, öğrencinin veri girişi yöntemi ile toplanmaktadır. Toplanan veriler veri ön işleme

adımlarından geçtikten sonra saklanmaktadır. Bu veriler KVKK saklama koşullarına uygun olarak kaydedilmektedir.

Bu çalışmada kullanılan veri seti için LMS yazılımı üzerinden öğrencilerin görüntüleri fotoğraf ve video formatında toplanmıştır. Test veri seti için 250 öğrencinin yüz görüntüsü toplanmıştır. Yüz görüntüsü öğrencinin sisteme kaydolması aşamasında, öğrencinin profil sayfasına girip kamerasını açıp kendisini kaydetmesi ile alınmaktadır. Sınav anındaki göz takibi ile ekran dışındaki yerlere odaklanma analizi videosu, video konferans odasında kameralar açılıp, sınav başlatıldıktan sonra kaydedilmektedir. Profil fotoğraflarında 256x256 boyutunda kırpma işlemi uygulanmaktadır. Dlib kütüphanesi ile yüz algılamak için 68 yüz noktası verisinin bulunduğu "shape_predictor_68_face_landmarks modeli kullanılmıştır.. Şekil 3.2’de Dlib 68 yüz noktasını içeren görüntü verilmiştir.



Şekil 3.2. Dlib 68 yüz noktası

3.2 Learning Management System (LMS)

LMS, "Learning Management System" (Öğrenme Yönetim Sistemi) kelimelerinin kısaltmasıdır. Bir LMS, çevrimiçi eğitim ve öğrenme süreçlerini yönetmek ve desteklemek için kullanılan bir yazılım veya web tabanlı bir platformdur. LMS'ler, eğitim kurumları, işletmeler, öğrenme ve geliştirme departmanları, eğitim sağlayıcıları ve çevrimiçi eğitim sunan diğer kuruluşlar tarafından kullanılır. Bu sistemler, eğitim materyallerini sunma, öğrencilerin kaydolması, kurs içeriklerini

yönetme, takip etme, değerlendirme ve iletişim gibi bir dizi özelliği destekler (Furgon ve ark., 2023).

Bir LMS'nin temel işlevleri arasında kurs ve içerik yönetimi vardır. Eğitim materyallerini yüklemek, düzenlemek ve sunmak için bir arayüz sağlar. Öğretmenler veya eğitmenler, ders içeriklerini oluşturabilir ve düzenleyebilir. Öğrenciler, bu içeriklere erişebilir ve takip edebilir. Öğrenci yönetimi: Öğrencilerin kaydolmasını, kurslara katılmasını ve kurs ilerlemelerini takip etmesini sağlar. Notlandırma, değerlendirme ve sınav sonuçları gibi öğrenci verilerini depolar ve yönetir. İletişim ve işbirliği, öğrencilerle, öğretmenlerle veya diğer öğrencilerle iletişim kurmayı sağlayan araçlar sağlar. Tartışma forumları, canlı sohbet, e-posta veya mesajlaşma gibi iletişim yöntemlerini destekleyebilir. Değerlendirme ve geri bildirim: Sınavlar, quizler, ödevler veya projeler gibi öğrenci performansını değerlendirmek için araçlar sunar. Öğretmenler, öğrencilere geri bildirim sağlayabilir ve performanslarını takip edebilir. Raporlama ve izleme: Kullanıcı aktiviteleri, kurs ilerlemesi, sınav sonuçları gibi verileri izler ve raporlar oluşturabilir. Bu raporlar, öğretmenlerin veya yöneticilerin öğrenci performansını izlemesine yardımcı olur. LMS'ler, çevrimiçi eğitimi kolaylaştırır, öğrenme süreçlerini izler ve yönetir, öğrenci-öğretmen etkileşimini destekler ve öğrenme deneyimini zenginleştirir. Eğitim süreçlerinin daha etkili ve verimli hale getirilmesine yardımcı olurlar (Pieńczykowski, 2020).

Yaygın olarak kullanılan LMS yazılımlarından bazıları aşağıda kısaca özetlenmiştir.

Moodle, özellikle eğitim kurumları tarafından yaygın olarak kullanılan açık kaynaklı bir LMS'dir. Esneklik, özelleştirme seçenekleri ve geniş topluluk desteği gibi avantajlarıyla bilinir.

Canvas, özellikle yüksek öğrenim kurumları ve işletmeler arasında popüler olan bir LMS'dir. Kullanıcı dostu arayüzü, zengin özellikleri ve entegrasyon yetenekleriyle tanınır.

Blackboard Learn, birçok kolej ve üniversite tarafından kullanılan bir LMS'dir. Kurs yönetimi, içerik oluşturma, değerlendirme ve iletişim araçları gibi çeşitli özelliklere sahiptir.

Sakai, yüksek öğrenim kurumları ve işletmeler arasında yaygın olarak kullanılan açık kaynaklı bir LMS'dir. Esneklik, özelleştirme imkanları ve işbirliği araçlarıyla tanınır.

Schoology, özellikle ilköğretim ve ortaöğretim kurumları arasında popüler olan bir LMS'dir. Kurs yönetimi, içerik paylaşımı, iletişim ve değerlendirme araçlarına sahiptir.

Google Classroom, özellikle eğitim kurumları arasında sıkça kullanılan bir LMS'dir. Google G Suite ile entegre çalışır ve öğretmenlerin materyalleri paylaşmasını, öğrencilerle iletişim kurmasını ve atama yönetimini kolaylaştırır (Bulut, 2021).

Bu çalışma kapsamında geliştirilen Okinar ise özellikle Türkiye’de uzaktan eğitim kurumları tarafından kullanılan özel bir SaaS ürünüdür. İçeriğinde BBB video konferans sistemini barındırarak canlı ve video ders imkanı sunmaktadır.

3.3. Video Konferans Sistemleri

Video konferans sistemleri, kullanıcıların uzaktan iletişim kurmasını sağlayan teknolojilerdir. Bu sistemler, kullanıcıların farklı yerlerde bulunmalarına rağmen sesli ve görüntülü iletişim kurmalarını sağlar. İş dünyasında, eğitimde, sağlık sektöründe ve diğer birçok alanda yaygın olarak kullanılmaktadır (Longline, 2021).

Video konferans sistemlerinin temel özellikleri aşağıda maddeler halinde listelenmektedir.

- **Sesli ve Görüntülü İletişim:** Video konferans sistemleri, kullanıcılara gerçek zamanlı olarak sesli ve görüntülü iletişim kurma imkanı sağlar. Bu sayede, katılımcılar birbirleriyle yüz yüze gibi iletişim kurabilirler.
- **Ekran Paylaşımı:** Bu özellik, kullanıcıların ekranlarını diğer katılımcılarla paylaşmalarını sağlar. Bu, sunum yaparken veya belge paylaşırken kullanışlı olabilir.
- **Metin Sohbeti:** Video konferans sistemleri, kullanıcılara metin tabanlı sohbet özelliği sunar. Katılımcılar, toplantı sırasında anlık Mesajlaşma yapabilir veya sorularını, yanıtlarını paylaşabilirler.
- **Çoklu Katılımcı:** Video konferans sistemleri, birçok katılımcının aynı toplantıya katılmasını sağlar. Bu, işbirliği projeleri, toplantılar veya eğitim etkinlikleri gibi durumlarda farklı kişilerin bir araya gelmesini kolaylaştırır.
- **Kayıt ve Yayın:** Bazı video konferans sistemleri, toplantıları kaydetme ve daha sonra izleme imkanı sunar. Ayrıca, canlı yayın özelliği sayesinde daha büyük bir izleyici kitlesine ulaşılabilir.

- **Güvenlik ve Gizlilik:** Video konferans sistemleri, güvenlik ve gizlilik önlemleri sunar. Şifreleme, kimlik doğrulama ve toplantıya sadece davetli kişilerin erişmesini sağlama gibi özellikler, kullanıcıların iletişimlerini korumalarına yardımcı olur.
- **Entegrasyon:** Video konferans sistemleri, diğer yazılımlar veya platformlarla entegre olabilme özelliğine sahiptir. Örneğin, e-posta veya takvim uygulamalarıyla entegrasyon, toplantıların daha kolay planlanmasını ve yönetilmesini sağlar.

Popüler video konferans sistemleri arasında Zoom, Microsoft Teams, Google Meet, Cisco Webex, Skype ve BBB gibi platformlar bulunmaktadır. Bu sistemler, kullanıcılara farklı özellikler, kullanım kolaylığı ve ölçeklenebilirlik sunar. Seçilecek video konferans sistemi, kullanıcı ihtiyaçlarına, bütçeye ve özelliklere bağlı olarak değişebilir.

Zoom, video konferans ve çevrimiçi toplantılar için popüler bir platformdur. Özellikle iş dünyasında, eğitimde ve kişisel kullanımda yaygın olarak tercih edilen bir araçtır. Zoom, kullanıcılara gerçek zamanlı sesli ve görüntülü iletişim imkanı sağlar ve farklı yerlerde bulunan insanları bir araya getirir (Hayat, 2020).

Microsoft Teams, Microsoft'un işbirliği ve iletişim platformudur. İş dünyasında, eğitimde ve diğer çeşitli sektörlerde kullanılan bir araçtır. Microsoft Teams, kullanıcılara ekip çalışması, toplantılar, sohbetler ve dosya paylaşımı gibi bir dizi işbirliği özelliği sunar. Aynı zamanda, Microsoft Office 365 veya Microsoft 365 aboneliği olan kullanıcılara ücretsiz olarak sunulur (Gökçakıl, 2022).

Google Meet, Google tarafından sunulan bir video konferans platformudur. İşletmeler, eğitim kurumları ve bireyler tarafından çevrimiçi toplantılar için yaygın olarak kullanılır. Google Meet, kullanıcılara yüksek kaliteli ses ve görüntü iletişimi sağlar ve farklı yerlerde bulunan kişileri bir araya getirir.

Cisco Webex, Cisco Systems tarafından sunulan bir video konferans ve işbirliği platformudur. İşletmeler, eğitim kurumları ve diğer çeşitli organizasyonlar tarafından kullanılır. Cisco Webex, kullanıcılara gerçek zamanlı sesli ve görüntülü iletişim, ekran paylaşımı ve işbirliği özellikleri sağlar.

Skype, Microsoft tarafından sunulan bir iletişim platformudur. İnsanlar arasında sesli ve görüntülü görüşmeler yapma, anlık Mesajlaşma ve dosya paylaşımı gibi iletişim özellikleri sunar. Skype, bilgisayarlar, akıllı telefonlar, tabletler ve diğer cihazlar üzerinden kullanılabilir.

BBB, 2009 yılında piyasaya sürülen, açık kaynaklı bir web tabanlı video konferans ve uzaktan eğitim platformudur. Özellikle eğitim kurumları, öğretmenler ve öğrenciler için tasarlanmıştır. BBB, gerçek zamanlı iletişim, canlı sunumlar, paylaşım araçları ve işbirlikli çalışma özellikleri sağlar. Kullanıcılar, sesli ve görüntülü iletişim kurabilir, sunumlar yapabilir, içerik paylaşabilir, metin tabanlı sohbet yapabilir, anketler ve sınavlar düzenleyebilir, kayıt yapabilir ve canlı yayın yapabilirler. Ayrıca, BBB ölçeklenebilir bir yapıya sahiptir ve özelleştirilebilir (Ukoha, 2022).

BBB video altyapısı, gerçek zamanlı iletişim ve çoklu kullanıcı katılımını desteklemek üzere tasarlanmıştır. Platform, WebRTC (Web Gerçek Zamanlı İletişim) teknolojisini kullanarak ses ve video akışını sağlar. WebRTC, web tarayıcıları aracılığıyla yüksek kaliteli ses ve görüntü iletişimi için bir standarda dayanan bir teknolojidir.

Canlı video akışı ve kayıtları için gerçek zamanlı olarak videoları renderleme işlemi yapar. Renderleme aşaması, kaydedilen bir oturumu işleyerek çıktı olarak kullanılabilir bir video oluşturmayı içerir. Oturum sırasında kullanıcıların video ve ses akışlarını kaydeder. Bu kaydedilen veriler, daha sonra renderleme aşamasında kullanılır. Renderleme işlemi, kaydedilen verilerin işlenerek bir video dosyasına dönüştürülmesini içerir ve aşağıda verilen özelliklere sahiptir:

- **Veri İşleme:** Kaydedilen veriler, renderleme sürecinde işlenir. Bu adımda, kullanıcıların video ve ses akışlarından gelen veriler düzenlenir, sıkıştırılır ve işlenir. Ses ve video senkronizasyonu sağlanır ve gerekli düzenlemeler yapılır.
- **Sıkıştırma:** Veriler, renderleme sürecinde sıkıştırılır. Bu adım, video dosyasının boyutunu küçültmek ve daha hızlı yükleme ve paylaşma için optimize etmek amacıyla yapılan bir işlemdir. Sıkıştırma genellikle video codec'leri kullanılarak gerçekleştirilir.
- **Video Formatı ve Kalitesi Belirleme:** Renderleme aşamasında, oluşturulan video dosyasının formatı ve kalitesi belirlenir. Farklı video formatları ve çözünürlükleri tercihe bağlı olarak seçilebilir.
- **Oluşturma ve Dış Aktarma:** Renderleme işlemi tamamlandığında, işlenen veriler kullanılarak video dosyası oluşturulur ve dışa aktarılır. Bu aşamada, oluşturulan video dosyası genellikle bir uyumlu medya formatında sunucuya kaydedilir veya başka bir depolama ortamına aktarılır.

Jitsi, açık kaynaklı bir video konferans platformudur. Jitsi, kullanıcıların web tarayıcıları üzerinden gerçek zamanlı olarak sesli ve görüntülü iletişim kurmalarını sağlamak için geliştirilmiştir. Jitsi projesi, Jitsi Meet adlı bir web tabanlı uygulama ve Jitsi Videobridge adlı bir medya yönlendirme sunucusuyla birlikte gelir.

Jitsi Meet, kullanıcıların toplantılar oluşturmaya, toplantılara katılmasına ve diğer kullanıcılarla etkileşimde bulunmasına olanak tanır. Kullanıcılar, tarayıcılarını kullanarak bir toplantı odası oluşturabilir ve bu odanın bağlantı bağlantısını diğer katılımcılarla paylaşabilir. Diğer katılımcılar, paylaşılan bağlantıyı kullanarak toplantıya katılabilir ve görüntülü veya sesli iletişim kurabilir. Jitsi Meet, birçok kullanışlı özelliğe sahiptir, örneğin ekran paylaşımı, sohbet, kayıt, toplantıya katılımcıları davet etme vb.

Bu çalışmada kullanılan video kontrollü sınav sistemi Şekil 3.3. de gösterildiği gibidir.



Şekil 3.3 Video kontrollü sınav sistemi

3.4. Bulut Bilişim Modelleri

Ulusal Standartlar ve Teknoloji Enstitüsü (National Institute of Standards and Technology-NIST) tarafından yapılan bulut bilişim tanımına göre dört farklı kurulum modeli bulunmaktadır: Genel Bulut, Özel Bulut, Topluluk Bulutu, Hibrit Bulut.

Genel Bulut, Bulut bilişim hizmetleri, altyapıyı oluşturan ve bu hizmetleri internet üzerinden sağlayan Google, Amazon ve Microsoft gibi bulut hizmet sağlayıcıları tarafından sağlanmaktadır. Sağlayıcılar bu hizmetleri kullandıkça öde ya da ücretsiz olarak sunabilmektedir. Model kamuya açık bir ağ üzerinden sağlandığı için genellikle bireysel kullanıcılar ve kurumlar tarafından gizli olmayan belgelerin paylaşımı için tercih edilmektedir (Yazır, 2018).

Özel Bulut hizmetleri genellikle veri güvenliği nedeniyle dış dünyaya kapalı olan şirket ve holding gibi kullanıcılar için sağlanmaktadır. Maliyet açısından genel bulutlara göre daha pahalıdır ancak kurum ve kuruluşlar için yatırım maliyetleri

açısından avantajlar sunarlar. Bu hizmet modeli şirketlere sistem kaynaklarının yönetiminde kontrol imkanı sunar.

Topluluk Bulutu, aynı amaca yönelik güvenlik, politika, gizlilik gibi özellikleri benzer olan ve birlikte hareket eden kurum veya kuruluşlara paylaştırılmış sistemlerdir.

Hibrit Bulut ise birden fazla modelin bir araya getirildiği bir bulut ortamıdır. Özel ve genel bulutun birleşimidir. Kuruluşlar genellikle özel hizmetleri ve dosyaları paylaşmak ve diğer şirketler tarafından sağlanan hizmetlere erişmek için bu model yapısını tercih ederler. Bu yapı esnek ve dolayısıyla maliyet etkin bir yapıdır. Bu yapıların bir diğer avantajı ise tüm verilere her yerden erişilebilmesidir (Yazır, 2018).

Microsoft Azure Bilişsel Hizmetler, Microsoft tarafından geliştirilen, 140 ülkede 54 farklı hizmet sağlayıcısı ile birçok bilgi işlem alanında hizmet sunan bulut bilişim tabanlı bir çalışma ağıdır. Microsoft Cognitive Services, bir Azure platform altında barındırılan yapay zeka alanındaki çeşitli problemleri çözmeyi amaçlayan bir algoritma kütüphanesidir. Dil işleme, MÖ, arama ve görüntü işleme gibi hizmetleri içerir. Alanında uzman olmasalar bile yazılım geliştiricilerin erişimine açık olması amaçlanmıştır. Bu hizmetler yazılım geliştiriciler için API'ler ve SDK'lar olarak sağlanmaktadır. Yazılım geliştiriciler bu hizmetleri mevcut uygulamalardaki sorunları çözmek veya uygulamaları daha akıllı hale getirmek için kullanabilir. Bu API'ler uygulamanın nasıl kullanılacağını açıklar, ancak arka planda çalışan yöntemleri içermez. Görme hizmetlerine ilişkin bilgiler aşağıda sunulmuştur.

Google Cloud Platform, son yıllarda, MÖ teknikleri bilgisayarla görmeye, özellikle de görsel sınıflandırma problemlerine odaklanmıştır. Makine öğrenmesi yöntemlerinin insanlarınkini bile aşabilen başarısı, talebi artırmıştır. MÖ geliştirecek ve kolaylaştıracak hizmetler Microsoft, Amazon ve Google gibi şirketler tarafından sunulmaktadır.

Google Cloud, müşterilerine uygulamalarına entegre edilebilecek bir dizi hizmet sunuyor. Google'ın görüntü analizi için CloudVision API'si etiketleri okuyabilir ve görüntülerdeki yüzleri tanımlayabilir. Duygu tanımlama, yüz tanıma uygulamaları tarafından gerçekleştirilebilir. Ayrıca görüntü içeriğinin uygunsuzluğunu da belirleyebilir.

3.5. Yüz tanıma teknolojinde kullanılan Metotlar

Bu çalışmada geliştirilen LMS sistemiyle entegre OpenCV, Deepface, Mediapipe, Kütüphaneleri kullanılmıştır. Bu bölümde kütüphanelerin teknolojileri ve modellerinden bahsedilmektedir. Deepface kütüphanesi

3.5.1. OpenCV (Open Source Computer Vision)

OpenCV (Open Source Computer Vision) açık kaynak kodlu görüntü işleme kütüphanesidir. 1999 yılında Intel tarafından geliştirilmeye başlanmış ve Itseez, Willow, Nvidia, AMD, Google gibi şirket ve toplulukların desteği ile gelişim süreci hala devam etmektedir. İlk sürüm olan OpenCV alfa 2000 yılında piyasaya çıkmıştır. İlk etapta C programlama dili ile geliştirilmeye başlanmış ve daha sonra birçok algoritması C++ dili ile geliştirilmiştir. Open source yani açık kaynak kodlu bir kütüphanedir ve BSD lisansı altında geliştirilmektedir. BSD lisansına sahip olması bu kütüphaneyi istediğiniz projede ücretsiz olarak kullanabileceğiniz anlamına gelmektedir. OpenCV platform bağımsız bir kütüphanedir, bu sayede Windows, Linux, FreeBSD, Android, Mac OS ve iOS platformlarında çalışabilmektedir. C++, C, Python, Java, Matlab, EmguCV kütüphanesi aracılığıyla da Visual Basic.Net, C# ve Visual C++ dilleri ile topluluklar tarafından geliştirilen farklı wrapperlar aracılığıyla Perl ve Ruby programlama dilleri ile kolaylıkla OpenCV uygulamaları geliştirilebilir (Tenekeci ve ark., 2014).

3.5.1.1. Haar Cascade Sınıflandırıcısı

OpenCV kütüphanesi içinde bulunan haarcascade sınıflandırıcısı; Paul Viola ve Micheal Jones tarafından, bu soruna çözüm için oluşturulmuştur. Aynı zamanda Viola and Jones object detection framework (Viola ve Jones nesne bulma yapısı) olarak da bilinir. En temel manada belirli bir algoritmaya göre bulunması istenen nesneler önce bilgisayara tanıtılır ve daha sonra ona benzer şekillerin bulunduğu resimler veya video kareleri taranarak o nesne bulunmaya çalışılır. Eğitim için içerisinde aranılan nesnenin bulunduğu pozitif resimlere ve içerisinde o nesnenin bulunmadığı negatif resimlere ihtiyaç vardır. Sınıflandırıcı eğitimde, pozitif resimlerdeki nesneleri aşağıdaki gibi belirli büyüklüklerde ayarlanmış çerçevelerle tarayarak çerçeve içerisinde bulunan siyah bölgedeki piksel değerleri toplamı ile beyaz bölgedeki piksel değerleri toplamlarından karanlık aydınlık değerler kontrol edilerek belirli hedef değerler oluşturulur. Feature denilen bu çerçevelere zayıf sınıflandırıcılar denilmektedir. Çünkü tek başına doğru bir

sınıflandırıcı olamazlar. Bir nesnede bu zayıf sınıflandırıcılardan birçoğu olacaktır ve bu zayıf sınıflandırıcıların toplandığı noktada büyük doğruluk oranıyla aranılan nesne var demektir. Sınıflandırıcı, en temel mantığıyla bu şekilde çalışmaktadır. Çerçeveler örnek pozitif resimler üzerinde taranır. Aynı zamanda göz bölgesinin beyaz ile gösterilen alt bölgeden daha karanlık olması da bu özelliklerden bir tanesidir. Haarcascade sınıflandırıcısında, buna benzer birçok özellikler içinde nesnenin bulunduğu resimler üzerinden geçirilerek değerler oluşturulur. Örneğin yüz taramasında ağız, burun, alın, saç gibi bölgelerde birçok karanlık aydınlık özellikleri oluşturulacaktır. Bunların her birinden hedef değerler oluşturulmaktadır. Ve bu işlem çerçeve büyüklükleri değiştirilerek diğer aşamalarda tekrar edilmektedir. Bu çerçeveler (zayıf sınıflandırıcılar) her resim boyutu için düşünüldüğünde yüz binlerce çekirdek oluşacaktır. Negatif resimler üzerinde tarama yapılarak içinde nesne bulunmadığı için kullanılmayacak olan çerçevelerin büyük çoğunluğu elenecektir. Pozitif resimlerde nesne seçilerek nesnedeki kullanılacak çerçeveler belirlenecektir. Bunun için eğitim sırasında pozitif resimlerde nesnenin milimetrik seçimine dikkat edilmelidir. Pozitif ve negatif resim örneklerinin çok olması istenilen nesnede daha iyi sonuçlar almak için önemlidir. Bu işlemlerin hem eğitimde hem de nesnelerin bulunmasında bilgisayarı çok yoracağı ve işlemlerin uzun süreceği düşünülebilir. Reel time görüntü işlemede hız çok önemlidir. Haar cascade sınıflandırıcısında öncelikle resimlerin integralleri alınır. Böylelikle piksel değerlerinin tek tek toplamaları hesaplanmak yerine integralle hesaplanmış olmaktadır. Böylelikle bilgisayardan büyük bir işlem gücü kaldırılacaktır. Ayrıca nesnelerin bulunması aşamasında da her bir büyüklükteki çerçeve tarafından tekrar tekrar taranmak yerine sadece önceki aşamalarla eşleşme olan kısımlar taranarak bir işlem yükü de oradan azaltılmaktadır. Bu açılarından ve yaptığı iş açısından oldukça hızlı oldukları söylenebilir de uygulama aşamasında reel time çalışıldığında alınan görüntüyü belirli oranda yavaşlattığı görülmektedir. Bu hız, sınıflandırıcının eğitilme şekli, örnek sayısı gibi durumlara göre değişmektedir. İstenilen nesnelerin bulunabilmesi için sınıflandırıcının referans alacağı min hit rate ve max false alarm rate değerleri vardır. sınıflandırıcı eğitimde her seferinde belirli eğitim algoritması ile bu değerlere ulaşmaya çalışır. Minhitrate minimum isabet oranını ve max false alarm rate ise hangi hata oranındaki nesnelerin gösterileceğini ifade eder (Koç, 2015).

3.5.2. FFmpeg Kütüphanesi

FFmpeg Kütüphanesi, ses ve video dosyalarını işlemek, dönüştürmek, kodlamak ve oynatmak için kullanılan bir açık kaynaklı çoklu ortam çerçevesidir. FFmpeg, bir dizi işlev ve araç seti sunarak birçok farklı multimedya formatını destekler. Bir komut satırı aracı olarak kullanılabileceği gibi, aynı zamanda bir C kütüphanesi olarak da kullanılabilir. Bu kütüphane, geliştiricilere çok çeşitli multimedya işleme görevlerini gerçekleştirmeleri için işlevler sağlar. FFmpeg, ses ve video dosyalarını okuma, yazma, kodlama, çözme, dönüştürme, ölçeklendirme, filtreleme ve daha pek çok işlemi gerçekleştirebilir.

FFmpeg, birçok popüler video ve ses codec'ini destekler. Buna H.264, H.265, VP9, AAC, MP3, WAV, MPEG-2, MPEG-4 ve daha birçok format ve codec dahildir. FFmpeg ayrıca filtreleme işlevleri sağlar, bu da ses ve video işleme süreçlerinde çeşitli efektlerin uygulanabilmesini sağlar. Örneğin, ses düzeyi ayarlama, video kesme, döndürme, yeniden boyutlandırma, renk düzeltme gibi işlemler FFmpeg ile gerçekleştirilebilir.

FFmpeg, birçok işletim sistemi üzerinde çalışabilen taşınabilir bir çerçevedir. Linux, Windows, macOS ve diğer birçok platformda kullanılabilir. FFmpeg, C dilinde yazılmıştır ve C veya C++ ile geliştirme yaparken kullanılabilir.

FFmpeg, çok sayıda özelliği ve karmaşık bir yapıya sahip olduğu için öğrenme eğrisi biraz dik olabilir. Ancak, FFmpeg'in geniş kullanım alanı ve güçlü işlevleri, multimedya işleme projeleri için önemli bir çözümdür (Ünyildiz, 2023).

3.5.3. Deepface Kütüphanesi

Deepface Kütüphanesi, Python tabanlı bir derin öğrenme kütüphanesidir ve yüz tanıma ve yüz analizi için önceden eğitilmiş modelleri kullanmayı sağlar. DeepFace, yüz tanıma, duygusal analiz, yüz öznitelikleri çıkarımı, yaş tahmini ve cinsiyet tahmini gibi bir dizi yüz tabanlı görevi gerçekleştirmek için kullanılabilir.


2014 yılında Deepface 9 katmanlı modeli ile %97,35 doğruluk oranında iken DÖ tabanlı çalışmalar ile 3 yıl içerisinde başarı oranını %99,80 üzerine çıkarmıştır (Wang ve ark., 2021).

DeepFace, OpenCV ve Keras gibi popüler Python kütüphanelerini kullanarak yüz tanıma işlemlerini gerçekleştirir. Ayrıca, VGG-Face ve Facebook tarafından geliştirilen DeepFace modeli gibi önceden eğitilmiş derin öğrenme modellerini kullanır. DeepFace kütüphanesinin temel özelliklerinden bazıları şunlardır:

- **Yüz Tanıma:** DeepFace, verilen bir görüntüdeki yüzleri tanımlamak için kullanılabilir. Önceden eğitilmiş bir modeli kullanarak, bir yüzü belirli bir kişiyle eşleştirebilirsiniz.
- **Duygusal Analiz:** DeepFace, bir yüzdeki duyguları analiz etmek için kullanılabilir. Örneğin, bir yüzün neşeli, üzgün, kızgın veya şaşkın olduğunu tespit edebilir.
- **Yüz Öznitelikleri Çıkarımı:** DeepFace, yüzlerdeki önemli öznitelikleri çıkarabilir. Örneğin, gözlerin konumu, burun şekli veya dudakların durumu gibi özellikleri belirleyebilir.
- **Yaş Tahmini:** DeepFace, bir yüzün tahmini yaşını belirlemek için kullanılabilir. Bu, bir yüzün genç, orta yaşlı veya yaşlı olduğunu tahmin etmek için kullanılabilir.
- **Cinsiyet Tahmini:** DeepFace, bir yüzün cinsiyetini belirlemek için kullanılabilir. Erkek veya kadın olduğunu tahmin etmek için kullanılabilir.

DeepFace, kolay kullanımı ve önceden eğitilmiş modellerin kullanılabilirliği nedeniyle yüz tanıma ve yüz analizi görevlerini gerçekleştirmek için popüler bir seçenektir. DeepFace kütüphanesini kullanarak, yüz tanıma uygulamaları, sosyal medya analizi, güvenlik sistemleri ve daha fazlası gibi birçok farklı alanda yüz tabanlı analizler yapılabilmektedir (Saaisri, 2022).

Şekil 3.4'den de anlaşılacağı üzere DeepFace 1990'lı yılların başında matematiksel yöntemlere dayalı çözüm üretirken son yıllarda CNN algoritmalarından biri olan VGG algoritmasını kullanarak derin öğrenmeyle çözüm üretmeye başlamıştır. Tanıma performansı zaman içinde de %60'lardan %97'ye kadar ulaşmıştır. Bu nedenle de yüz tanımada iyi bir çözüm olarak görülmüştür.



Şekil.3.4. Yıllara Göre Deepface Başarısı (Wang ve ark. 2021)

3.5.3.1 Evrişimsel Sinir Ağları (CNN)

CNN, bir tür YSA'dır. Veri girişlerine göre öğrenme kapasitesine sahiptir. CNN'lar, birçok farklı veri türünü işleyebilir ve çeşitli görevlerde kullanılabilir, ancak en sık kullanım alanları sürekli veya kararsız verilerin tahmini ve sınıflandırılmasıdır.

CNN, bir tür yapay YSA ve veri girişlerine göre öğrenme kapasitesine sahiptir. CNN'lar, birçok farklı veri türünü işleyebilir ve çeşitli görevlerde kullanılabilir, ancak en sık kullanım alanları sürekli veya kararsız verilerin tahmini ve sınıflandırılmasıdır.

CNN'lar, giriş verilerine göre öğrenir ve çıktı verilerini tahmin etmeye çalışır. Öğrenme sırasında, CNN'lar bir düzgün giriş-çıkı ilişkisi oluşturmaya çalışır ve bu ilişkiyi kullanarak gelecekteki giriş verilerine göre çıktı verilerini tahmin etmeye çalışır.

CNN'lar, öğrenme sırasında ağırlık değerlerini değiştirerek giriş verilerinden çıktı verilerine doğru bir ilişki oluşturmaya çalışır. CNN'lar, diğer YSA'dan farklı olarak, giriş verilerine göre sürekli olarak öğrenme kapasitesine sahiptirler. Bu, CNN'ların dinamik veri setlerinde daha iyi performans göstermelerine yardımcı olur ve bu nedenle, sürekli olarak değişen veri setlerinin tahmini ve sınıflandırılması gibi görevlerde sıklıkla kullanılır. Görsellerdeki özellikleri yakalayan ve onları sınıflandıran bu algoritma çok sayıda katmandan oluşmaktadır. Bu katmanlar, Evrişimli Katman (EK), Havuzlama Katmanı (HK) ve Tam Bağlı Katman (TBK)'dır (Lecun ve ark., 2015).

EK, bir DÖ modelinde bulunan girdi verilerine göre öğrenme gerçekleştirerek öznitelikleri (özellikleri) çıkarmaya yardımcı olur. Öznitelikler, girdi verilerinde bulunan anlamlı ve önemli bilgilerdir ve genellikle daha sonraki katmanlarda kullanılırlar. Bu katman, görüntülerdeki öznitelikleri belirlemek için görüntüler üzerinde belirli bir şablondan (filtre) oluşan bir matris kullanır. Bu filtre, görüntünün üzerinde hareket ederek görüntünün farklı bölgelerini tarar ve bu bölgeler üzerinde işlemler gerçekleştirir. Bu işlemler sonucunda, filtre görüntünün özniteliklerini belirler ve bu öznitelikler bir sonraki katmana geçirilir. EK'nın kullanılması, DÖ modellerinde görüntüler üzerinde işlem yaparken öznitelik çıkarmayı hızlandırır ve doğru sonuçlar elde etme olasılığını artırır. Bilindiği üzere görseller aslında içlerinde belirli değerler taşıyan piksellerden oluşan matrislerdir. EK da orijinal görsel boyutlarından daha küçük bir filtre görselin üzerinde gezer ve bu görsellerden belirli özellikleri yakalamaya çalışır (Ergin, 2018). Şekil 3.5'te görüldüğü üzere 3×3 'lük bir filtre, 5×5 'lik bir görsel üzerinde gezdiriliyor. Çıkan sonuçlar eşitliğin sağ tarafındaki yeni matrisimiz olan

Operation	Filter	Convolved image
Identity	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	
Edge Detection	$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
	$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	
Sharpen	$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	
Box blur (normalized)	$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	
Gaussian blur (approximation)	$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$	

Şekil 3.6. Örnek filtreler (Ergin, 2018)

EK da önemli olan bir diğer parametre dolgu parametresidir. Bir görsel filtre uygulandığında boyutlardan dolayı çıktı orijinal görselden daha küçük olur. Bunu önlemek için kullanılabilecek yöntem ise dolgulamadır. Dolgulama işleminde görsel adeta bir çerçeve olacakmış gibi dört taraftan da sıfırlar eklenir. Filtrenin boyutuna göre bu sıfır eklenen katmanlar artırılabilir (Ergin, 2018).


HK, DÖ sürecinde kullanılan bir yapıdır. HK, girdi verisini ön işleme yapmak için ve genellikle bir EK'nın ardından kullanılır.

HK, girdi verisini daha az özellikli bir çıktıya dönüştürürler. Bu, verinin özelliklerini özetler ve ağırlık öğrenme sürecini hızlandırır. Ayrıca, HK, girdi verisinin ölçeklerini azaltır ve bu da ağırlık öğrenme sürecinde aşırı uyum riskini azaltır.

Maksimum havuzlama ve ortalama havuzlama olarak ikiye ayrılır (Şekil 3.7). Maksimum havuzlama, girdi verisinin bir bölgesindeki en büyük değerleri seçerken, ortalama havuzlama girdi verisinin bir bölgesindeki değerlerin ortalamasını alır.

HK, genellikle resim sınıflandırma, metin sınıflandırma ve ses tanıma gibi görevlerde kullanılır.

TBK, SA modelinde kullanılan bir katmandır. Bu katman, girdi verisiyle tam olarak bağlantılıdır ve girdi verisinden çıkan tüm özelliklerin ağırlıklandırılması ve birleştirilmesi için kullanılır. TBK, genellikle çoklu SA katmanlarından sonra kullanılır ve çıktı verisini üretebilirler.



Şekil 3.7. Maksimum Havuzlama ve Ortalama Havuzlama (Ergin, 2018)

TBK, SA modelinde çeşitli görevleri yerine getirebilir. Örneğin, bir TBK, önceden öğrenilen özellikleri birleştirir ve bu özellikleri kullanarak öğrenilmemiş verileri sınıflandırır veya tahmin etmeye çalışır. Ayrıca, bir TBK, SA modelinin aşırı uyumunu önlemek için de kullanılabilir.

Bir SA modelinde kullanılan diğer katmanlardan farklı olarak, her bir nöron girdi verisinden gelen tüm özellikleri alır ve bu özellikleri ağırlıklandırarak birleştirir. Bu nedenle, TBK, diğer katmanlar gibi belirli bir özellik alanına odaklanmazlar ve daha genel bir görüş sağlarlar.


TBK, SA modellerinde çok yaygın olarak ve genellikle birkaç tane kullanılır. Bu katmanların sayısı ve güçleri, modelin performansını doğrudan etkilemektedir ve bu nedenle, SA modelinin tasarımı sırasında dikkatli bir şekilde seçilmelidir (Ergin, 2018).

Günümüzde en çok kullanılan CNN mimarileri LeNet, AlexNet, VGGNet, GoogLeNet, ResNet ve ZFNet olarak sıralanabilir. Bu algoritmalarından LeNet, AlexNet ve VGGNet ile sınav anındaki görüntüler kullanılarak kopya çekme teşebbüsleri tespit edilecektir.

LeNet, AT&T Bell Laboratuvarlarında araştırmacı olan Yann LeCun tarafından görüntülerdeki el yazısı rakamları tanımak amacıyla tanıtıldı. Bu çalışma, teknolojiyi geliştiren on yıllık bir araştırmanın doruk noktasını temsil ediyordu. 1989'da LeCun'un ekibi, geri yayılma yoluyla CNN'leri başarılı bir şekilde eğitmek için ilk çalışmayı yayınladı. O zamanlar LeNet, SVM' nin performansı ile eşleşen olağanüstü sonuçlar elde etti, ardından basamak başına %1'den daha az bir hata oranı elde ederek denetimli öğrenmede baskın bir yaklaşım oldu. LeNet sonunda ATM makinelerinde para yatırma işlemleri için rakamları tanıyacak şekilde uyarlandı. Bugüne kadar bazı ATM'lerde,

Yann LeCun ve meslektaşı Leon Bottou'nun 1990'larda yazdığı kodu kullanılmıştır (Lecun ve ark., 1998).

Yüksek düzeyde, LeNet (LeNet-5) iki bölümden oluşmaktadır: iki EK'dan oluşan bir evrişimli kodlayıcı; ve tamamen birbirine bağlı üç katmandan oluşan yoğun bir blok. Mimari, Şekil 3.8'de özetlenmiştir. Şekil 3.2.1.1.'de, girdi elle yazılmış bir rakam, çıktı ise 10 olası sonucun üzerinde bir olasılıktır.



Şekil 3.8. LeNet'te veri akışı (Zhang ve ark., 2021)

Her evrişim bloğundaki temel birimler, bir EK, bir sigmoid aktivasyon fonksiyonu ve müteakip bir ortalama havuzlama işlemidir. EK bir çekirdek ve bir sigmoid aktivasyon işlevi içerir. Bu katmanlar, uzamsal olarak düzenlenmiş girdileri, tipik olarak kanal sayısını artırarak bir dizi iki boyutlu özellik haritasına eşler. Birinci EK 6 çıkış kanalına sahipken, ikinci katman 16 çıkış kanalına sahiptir. Havuzlama işlemi (adım 2) boyutsallığı mekansal alt örnekleme yoluyla azaltır. Evrişimli blok, verilen şekle sahip bir çıktı yayar (alt örneklerin sayısı, kanal sayısı, yükseklik, genişlik) (Zhang ve ark., 2021).

2014 yılında VGGNET adlı bir DÖ modeli geliştirilmiştir. Bu DÖ modeli ImageNet 2014 yarışmasında %7.3 hata oranı ile iyi bir sonuç göstermiştir. Oxford Üniversitesi tarafından Simonyan ve Zisserman tarafından tasarlanan bu mimari için altı farklı mimari ortaya çıktı (Simonyan ve Zisserman, 2014).

GoogLeNet, Google tarafından 2014 yılında yayınlanan bir DÖ ağıdır. GoogLeNet, ImageNet veri kümesinde yapılan birçok yarışmada üstün performans göstermiştir ve hala günümüzde de sıklıkla kullanılmaktadır. GoogLeNet, CNN olarak tasarlanmıştır ve "inception" mimarisi adı verilen bir mimariyi kullanmaktadır. Bu mimari, CNN'lardaki katmanların birleştirilmesiyle oluşturulan bir yapıdır ve daha önce


kullanılmamış bir şekilde düşük çözünürlüklü girdileri kullanarak, daha iyi özellikler çıkarma amacını taşımaktadır. GoogleNet, aynı zamanda birçok öğrenme modülüne sahiptir ve bu modüller arasında birçok bağlantı vardır. Bu sayede, GoogleNet, girdi verilerini çeşitli derecelerde işler ve daha doğru tahminler yapmayı amaçlar. GoogleNet, güncel olarak hala birçok resim tanıma ve sınıflandırma uygulamasında kullanılmaktadır ve genellikle yüksek doğruluk oranları ile öne çıkmaktadır (Szegedy ve ark., 2015).

ResNet (Residual Network) bir DÖ modelidir ve günümüzde sıklıkla görüntü tanıma, ses tanıma ve doğal dil işleme gibi uygulamalarda kullanılır. ResNet, DÖ modellerinin derinliklerini artırmak için tasarlanmıştır. Böylece daha fazla özellik çıkarma ve daha iyi performans elde edilebilmiştir.

ResNet, DÖ modellerinde "yol ekleme" kavramını kullanır. Bu, ağın derinliklerine ek bir yol ekleyerek ağın öğrenme kapasitesini arttırmayı amaçlar. Bu yol ekleme, ağın öğrendiği özelliklerin yanı sıra ağın giriş verilerine doğrudan bağlı olarak verilen bir girdi ve çıktı arasındaki farkın (ya da "kalan") öğrenilmesine yardımcı olur. Bu, ağı giriş verilerine doğrudan bağlı olarak öğrendiği özellikleri saklamasına ve daha iyi generalizasyon (yeni verilere uygulanırken daha iyi performans gösterme) sağlamasına yardımcı olur.

ResNet, ağı derinliklerine ek yol eklerken, ağı derinliklerinin bazılarını atlamaya veya "atlamaya" yardımcı olur. Bu, ağı öğrendiği özellikleri daha iyi saklamasına ve daha iyi genelleştirme sağlamasına yardımcı olur. 2015 yılında ResNet, Jian Sun, Kaiming He, Shaoqing Ren ve Xiangyu Zhang tarafından yayınlanan "Deep Residual Learning for Image Recognition" adlı bir çalışmada tanıtıldı ve o zamandan beri sıklıkla kullanılmaktadır (He ve ark., 2016).

ZFNet, AlexNet'in ImageNet yarışmasını kazanmasından sonra bu mimariden esinlenerek geliştirilen, 2013 yılında ImageNet yarışmasını kazanan algoritmadır (Zeiler ve ark., 2014). ZFNet mimarisi 7 katmandan oluşmaktadır Şekil 3.7'de gösterilmiştir.



Şekil 3.7. ZfNet Mimarisi (Zeiler ve ark., 2014)

3.5.4. Mediapipe Kütüphanesi

Mediapipe Kütüphanesi, Google tarafından geliştirilen açık kaynaklı bir kütüphanedir ve çeşitli görsel işleme ve MÖ uygulamalarında kullanılabilir. Python dilinde kullanılabilen bu kütüphane, görüntü ve video verileri üzerinde gerçek zamanlı olarak çeşitli görevleri gerçekleştirmek için tasarlanmıştır.

Mediapipe, farklı işlevselliklere sahip bir dizi pre-trained model ve API'lar sunar. Aşağıda, Mediapipe kütüphanesinin bazı temel bileşenlerini ve kullanım alanlarını bulunmaktadır.

Görüntü ve Video İşleme: Mediapipe, görüntü ve video verileri üzerinde çeşitli işlemler gerçekleştirmek için kullanılabilir. Örneğin, yüz tespiti, yüz hatları çıkarma, el tespiti, el hareketleri analizi, beden tespiti, nesne takibi ve daha fazlası gibi işlevler sunar. Bu işlevler, gerçek zamanlı uygulamalarda kullanılabilir ve çeşitli endüstrilerde kullanılan uygulamaların geliştirilmesine olanak tanır.

Pose Estimasyonu: Mediapipe, insan vücut pozisyonunu tahmin etme işlevselliği sunar. Bu, bir kişinin vücut duruşunu ve pozisyonunu tespit etmek için kullanılabilir. PoseNet olarak bilinen bir pre-trained model kullanarak, insan vücudunun eklemlerini ve kemiklerini tahmin edebilir ve gerçek zamanlı olarak takip edebilirsiniz. Bu, egzersiz uygulamaları, hareket analizi, oyunlar ve benzeri uygulamalarda yaygın olarak kullanılır.

Ortam Akışı İşleme: Mediapipe, kamera akışı gibi sürekli veri akışlarını işlemek için tasarlanmıştır. Bu, gerçek zamanlı işlemler yapılmasına, veriyi anlık olarak işlemek ve sonuçların anında alınmasına olanak tanır. Örneğin, bir kamera akışında yüz tespiti veya el hareketi analizi gerçekleştirebilir ve sonuçlar hemen kullanılabilir.

Özelleştirme ve Genişletilebilirlik: Mediapipe, kullanıcıların kendi modellerini ve işlevlerini entegre etmelerine olanak tanır. Önceden eğitilmiş modelleri kullanmanın yanı sıra, kendi veri setimizi oluşturarak özel işlevlerde kullanabiliriz.

Mediapipe gaze kütüphanesi göz takibi, kamera kaynağından gelen görüntüler üzerinde çalışır ve gözlerin konumunu ve hareketlerini tahmin etmeye odaklanır. Bu özellik, gözlerin nokta bulutu ve vektörlerle temsil edildiği bir koordinat sistemi kullanarak göz izleme yapar. Göz Takibi Özelliği Adımları aşağıda verildiği gibidir:

Göz Tespiti: İlk adımda, Mediapipe, görüntüdeki gözleri tespit etmek için bir nesne tespit modeli kullanır. Gözlerin konumunu ve sınırlarını belirler.

Göz İşaretçileri ve Özellik Noktaları: Gözlerin içindeki çeşitli işaretçileri ve özellik noktalarını belirler. Bu noktalar, göz kapaklarının kenarları, iris merkezi ve göz bebekleri gibi gözün farklı bölgelerini temsil eder.

Göz Hareketlerinin Tahmini: Göz işaretçileri ve özellik noktaları kullanılarak göz hareketleri tahmin edilir. Örneğin, bakış yönü, göz kapağı durumu, gözün açıklığı ve benzeri bilgiler elde edilebilir.

Mediapipe göz takibi, gerçek zamanlı olarak çalışabilen ve yüksek doğruluk sağlayan bir yöntemdir. Bu, uygulamaların kullanıcının göz hareketlerini takip etmesini, dikkat odaklarını belirlemesini veya interaktif göz kontrollü uygulamalar geliştirmesini sağlar (Kaushik, 2021).

3.5.5. Gaze Algoritması

Bakışları tahmin etmekte kullanılan bir DÖ modelidir. İlgilenilen alan ile ilgili yöne bakış konusunda analiz yaparak tespitler çıkartmakta kullanılmaktadır.

Bakış Takibi: İlk adımda, görüntü üzerindeki gözlerin tespit edilmesi gerekmektedir. Bu adım genellikle gözleri tespit etmek için bir nesne tespit modeli veya göz tespiti algoritması kullanır. Gözlerin konumunu ve sınırlarını belirler.

Pupil Merkezi Tespiti: Gözlerin tespit edilmesinden sonra, her göz için iris ve göz bebeği bölgesi analiz edilir. Bu adımda, göz bebeğinin merkezi (pupil merkezi) tespit edilmeye çalışılır. Bu, gözün odaklandığı noktanın tahmin edilmesine yardımcı olur.


Gaze Vektörünün Hesaplanması: Pupil merkezinin tespit edilmesinden sonra, gözün bakış yönünü temsil eden bir vektör hesaplanır. Bu genellikle göz merkezinden pupil merkezine doğru bir vektör olarak ifade edilir. Vektörün yönü, gözün odaklandığı yönü gösterir.

Koordinat Dönüşümleri: Gözün bakış yönünü dünya koordinatlarına dönüştürmek için gerekli olan kamera kalibrasyon parametreleri ve gözün konumunu bilmek gerekebilir. Bu adımlar, gözün bakış yönünü belirli bir referans noktası veya ekran koordinatlarına dönüştürmek için kullanılır.

Odak Noktasının Tahmini: Gaze algoritması, gözün bakış yönünü temsil eden vektörleri kullanarak odak noktasını tahmin etmeye çalışır. Bu, kullanıcının odaklandığı noktanın belirlenmesine yardımcı olur. Örneğin, bir ekran üzerindeki belirli bir nokta veya nesne olabilir (Kyle, 2023).

4. GELİŞTİRİLEN UYGULAMA VE BULGULAR


Bu tez çalışması kapsamında, geliştirilen bir LMS sistemi olan OKİNAR uygulaması ile öğrencilerden kimlik doğrulaması için görüntü verilerinin elde edilmesi, doğrulanması ve sınav esnasındaki video görüntüleri kullanılarak usulsüzlüklerin analizinin gerçekleştirilmesi hedeflenmiştir. Geliştirilen bu yapının genel görünümü Şekil 4.1’de verilmiştir. Geliştirilen bu uygulama genel olarak kullanıcı girişi, video konferans ortamı, kimlik doğrulama, bakış yönü tespiti alt modüllerini içermektedir.



Şekil 4.1. Gerçekleştirilecek Adımlar

4.1. Kullanıcı Girişi


LMS sistemine kayıtlı öğrenci öncelikle sistemde oturum açmalıdır. Öğrenciye kayıtlı olduğu eğitim kurumundan mail adresi ve parolası temin edilmiştir. Öğrenci mail adresi ve parolası ile sisteme Şekil 4.2’de gösterildiği ekrandan giriş sağlar.



Şekil 4.2. Okinar LMS Oturum Aç Ekranı

4.2 Yüz Fotoğrafının Kaydedilmesi

Oturum açıldıktan sonra öğrenci sistemden profil sayfasına giriş yapmaktadır. Şekil 4.3'te gösterildiği gibi kullanıcı profili sayfasına giriş yapan öğrenci, kamera ile yüz fotoğrafı kaydetme bölümünden görüntüsünü kaydeder.




Şekil 4.3. Yüz Fotoğrafı Kaydet Ekranı

4.3 Video Konferans Ortamı

Sınava katılacak öğrenciler, kamera görüntülerini paylaşabilmek için, LMS sisteminden kendilerine tanımlanan sınav salonuna katılmaları gerekmektedir. Bu sınav salonunu eğitim kurumunda öğrencilerden sorumlu personeller tanımlamaktadır. Video konferans platformunda BBB teknolojisi kullanılmıştır.

Sınav salonuna katılım sağlandıktan sonra öğrenciler kameralarını açarak (Şekil 4.4), LMS panelinden sınav başlatma penceresine geçip veya salonda paylaşılan sınav bağlantısından sınavı başlatırlar. Sınav esnasında, kamera paylaşımı yapıldığı süre boyunca öğrencinin ekrana düz bir şekilde bakıp, sağa, sola, yukarı ve aşağı yönlerde, yani ekran dışı bölgelere bakmaması beklenir.



Şekil 4.4 BBB Video Konferans Ortamı

4.4 Sınava Giriş

Sınav salonuna katılıp kameralarını açan öğrencilerin, kamera destekli usulsüzlük tespitinin yapılabilmesi için uygun koşulları sağlaması gerekmektedir. Beklenen uygun koşullar aşağıda sıralanmaktadır:

- Bilgisayar ekranı karşısında oturmak.
- İkinci bir ekran kullanmamak.
- Yeterli aydınlatma ile yüz ve gözlerin görüldüğünden emin olmak.
- Sınav esnasında, sınav ekranı dışında hiçbir şey ile ilgilenmemek.

4.5 Render Süreci

Sınav anında kamera görüntüleri kaydedilen öğrencilerin, sınav salonu kapatıldığı zaman BBB video render süreci başlamaktadır. Tüm öğrencilerin kamera görüntüleri eşzamanlı olarak *.mp4 formatında sunucuya kaydedilir. Kayıtlara sonrasında erişilmek istendiği zaman LMS sistemi üzerinden MeetingID’si bilinen salona API isteği gerçekleştirilerek kayıtlar görüntülenebilmektedir. Video kayıtlarını sunucuya yapılan ssh bağlantısı ile render işleminin tamamlanıp tamamlanmadığını “bbb-record –list” komutu ile Şekil 4.5’te sunulduğu üzere görüntüleyebiliriz.

```

root@user:~# bbb-record --list
Internal MeetingID
-----
2e28a2a984a93d4c7c959e0042539e07c81b8a02-1705599846489 Thu 18 Jan 2024 05:44:06 PM UTC X
d4360e90772bfd7ale6c52be4d2ea775b5046b8c-1705596466367 Thu 18 Jan 2024 04:47:46 PM UTC X
e39a468fb5d9fd404793890dd7ee43b48de4e463-1705593453260 Thu 18 Jan 2024 03:57:33 PM UTC X
318c468ba1435300c3fe6c6847ffae248b5236c-1705592959550 Thu 18 Jan 2024 03:49:19 PM UTC X
5843d03420b7c8566898d24f686f04975ee57c50-1705586706895 Thu 18 Jan 2024 02:05:06 PM UTC X
5843d03420b7c8566898d24f686f04975ee57c50-1705585919051 Thu 18 Jan 2024 01:51:59 PM UTC X
5843d03420b7c8566898d24f686f04975ee57c50-1705584555078 Thu 18 Jan 2024 01:29:15 PM UTC X
5843d03420b7c8566898d24f686f04975ee57c50-1705582770862 Thu 18 Jan 2024 12:59:30 PM UTC X
7352614ede971bebebf64b799d18938bbfe4478e-1705571991910 Thu 18 Jan 2024 09:59:51 AM UTC X
5843d03420b7c8566898d24f686f04975ee57c50-1705570246926 Thu 18 Jan 2024 09:30:46 AM UTC X
7352614ede971bebebf64b799d18938bbfe4478e-1705562208245 Thu 18 Jan 2024 07:16:48 AM UTC X
5843d03420b7c8566898d24f686f04975ee57c50-1705561347416 Thu 18 Jan 2024 07:02:27 AM UTC X

```

APVDE	RAS	Slides	Processed	Published	External MeetingID
XX	X		15		31acad62f07b5b5ed81e947d038ef56aa664b8a
XXXXX	XX	15	presentation	presentation	9bb14c306dd7d4d1106547c0d4ee275bebe62c4f
XXX	X	15	presentation	presentation	acfc0d16677dad8b076f3208cfa52f7322b15ce9f3
XXX	X	15	presentation	presentation	b04ccb20b84c47f4a64fbb5bccc23824f617403a
XX	X	15			205e2285c9874b36b8e1486dfa8e968e35264b57
XX	X	15			205e2285c9874b36b8e1486dfa8e968e35264b57
XX	X	15			205e2285c9874b36b8e1486dfa8e968e35264b57
XX	X	15			205e2285c9874b36b8e1486dfa8e968e35264b57
XX	X	15			5307e64c7aa3584ac818fbb11c0410196a5beaf
XX	X	15			205e2285c9874b36b8e1486dfa8e968e35264b57
XX	X	15			5307e64c7aa3584ac818fbb11c0410196a5beaf
XX	X	15			205e2285c9874b36b8e1486dfa8e968e35264b57

Şekil 4.5. bbb-record –list Ekranı


4.6 Kimlik Doğrulama

Render aşamasından sonra video dizinine düşen öğrenci kamera görüntülerinin, FFmpeg kütüphanesi ile ön izleme resimleri aynı dizine kaydedilir. Bu işlem tamamlandıktan sonra Deepface kütüphanesini kullanarak işlem yapan Python modülü, sırası ile ilgili videolara ait olan ön izleme görüntülerini hangi öğrenciye ait ise onun profil görüntüsü ile karşılaştırarak doğrulama yapar.

Bu işlem neticesinde sınava giren kullanıcının yapabileceği en önemli usulsüzlüklerden biri olan sınavda bir başkasının yerine geçme ihlalinin de önüne geçilmiş olur.


4.7 Göz Takibi Analizi

Python ile yazılmış olan bakış yönü tahmini uygulaması, videoların taşındığı dizinde ne kadar video dosyası varsa hepsini analiz ederek, her video dosyası için .txt dosyasında bakış yönü tahmini puanını kaydetmektedir. Bu bölümde işlenecek adımlar Şekil 4.6’da gösterilmiştir.



Şekil 4.6. Göz takibi adımları

Göz bebeği Gaze algoritması ile algılandıktan sonra sol ve sağ noktalara olan uzaklıklardan Bakış Açısı Puanı (BAP) Şekil 4.7’de gösterildiği gibi hesaplanır.




Şekil 4.7. BAP Hesabı

BAP değeri ekrana düz bakıldığında 1'dir ve değeri x değerinin artışı ile küçülmeye başlar. BAP değeri önceden belirlenmiş Bakış Tolerans Değeri (BTD) altına inerse, ekran açısı dışına çıkıldığı kabul edilir. Açı dışına çıkıp çıkılmadığı kontrolü videonun tüm framerlerinde hesaplanır.

BTD ekran köşe sınırlarına göre, geliştirilen uygulama kapsamında hesaplanarak 0.7 olarak tespit edilmiştir. Bu değer, sınav sırasında ekranının köşelerine bakılarak alınmış görüntülere göre hesaplanan değerlerin ortalaması alınarak elde edilmiştir. Dolayısıyla, bu değer aşıldığı zaman ekran dışına odaklanıldığı varsayılır.


Öncelikle, Şekil 4.8'de görüldüğü gibi göz bebeği ve göz kenarları tespit edilmektedir. BAP hesaplanırken açıdaki değişim göz bebeklerinin göz kenarlarına olan mesafesinden hesaplanmaktadır.



Şekil 4.8. Gaze Algoritması Bakış Yönü Tespiti

Gaze algoritması, gözlerin bakış yönünü tahmin etmek için kullanılan bir algoritmadır. Bu algoritma, göz hareketlerinin analizi ve göz izleme tekniklerine

dayanır. Gaze algoritması ile oluşturulan model çıktısında önce mediapipe ile yüz tespiti sağlanmaktadır Şekil 4.9. Tespit edilen yüz görüntüsünden gözler ve göz bebekleri tespit edilerek işaretlenmiştir. Şekil 4.10’da gösterildiği gibi işaretlenen göz bebeklerinin hareketlerinden bakış yönü tahmin edilebilir hale gelmektedir.



Şekil 4.9. Mediapipe yüz tespiti



Şekil 4.10. Göz bebeği tespiti

Gaze algoritması ile bakış yönü tespit edildikten sonra Video Karesi Başına Göz sınır değeri ve yüz sınır bölgesi aşıp aşılmadığı kontrol edilir. BTD Göz sınır değerinden (0,7)'den küçük ise Toplam Başarı Değeri düşer. Bakış Çizgisi yüz açısının baktığı yönü belirlemekte kullanılmaktadır. Bu çizgi, Mediapipe ile kare alan içerisine alınan yüz sınır bölgesinin dışına taşarsa, yüzün farklı yöne baktığı anlaşılır ve Toplam bakış değeri düşürülür (Şekil 4.10). Bakış değeri başlangıçta 100'dür. Dümdüz hareketsiz ekrana bakıldığı zaman bu değer değişmemektedir. Sürekli ekranın dışına bakılırsa değer 0'a kadar düşebilir. Sıfırın altına düşemez. Bu kontroller ve bakış değerinin hesaplanması Şekil 4.11'da verilen örnek kod ile yapılmıştır.

```

1 foreach(Video as VideoKaresi){
2     if(BTD < GozSinirDegeri){
3         ToplamBasariDegeri-=DusulecekBasariDegeri;
4     }
5     if(BakisCizgisi > YuzSinirBolgesi){
6         ToplamBasariDegeri-=DusulecekBasariDegeri;
7     }
8 }

```

Şekil 4.11. Örnek Kod


Bakış değerlerinden usulsüzlük tahmini yani şüpheli listesi oluşturabilmek için bakış değeri için bir eşik değerinin belirlenmesi denemeler yoluyla yapılmıştır. Yapılan denemeler sonucunda farklı bakış yönleri için farklı değerlerde bakış değerleri elde edilmiş ve bu değerlere birer örnek Çizelge 4.1'de verilmiştir. Çizelge 4.1, bir öğrencinin 30 saniyelik düz şekilde ekrana bakma, aşağı bakma, yukarı bakma, sağa bakma, sola bakma ve karma yöne bakma durumundaki görüntülerine göre elde edilen bakış yönü değerini ifade etmektedir. Ekrana düz bakıldığında değer yüksek kaldığı, ekran dışı alanlara bakıldığı aktivitelerde göz bebeğinin göz kenarlarına yaklaşması ile değer düşümü ve başın farklı yönlere dönmesi ile de değer düşümü işlemlerinin gerçekleştirildiği görülebilmektedir. Elde edilen bu sonuçlar dikkate alınarak eşik değeri 30 olarak belirlenmiş ve bakış değerinin 30'dan küçük olması şüpheli durum olarak değerlendirilmiştir.

Çizelge 4.1. Farklı yönler için elde edilen Bakış Yönü değerleri


Bakış Yönü	Bakış Değeri
Düz bakış	46.503884572697004
Aşağı yöne bakış	16.151202749140893
Sağ yöne bakış	0.32679738562091504
Sol yöne bakış	1.5384615384615385
Yukarı yöne bakış	0.7865168539325843
Karma bakış	3.0555555555555554

4.8 Bulgular

Geliştirilen uygulamanın performansı OKİNAR LMS sistem üzerinden deneysel olarak 10 dakikalık kısa sınavlar düzenlenerek elde edilmiş verilerle test edilmiştir. Sınav süresine göre puanlamalarda değişim görülebilir. Daha uzun süreli sınavlar ve kısa süreli sınavlarda puanlarda değişim olurlen, şüpheli ve süphesiz durumlar arasındaki açıklık görülmeye devam etmektedir. Toplamda 250 uzaktan eğitim öğrencisinin 10 dakikalık, 5 soru çözdükleri bir sınavda geçirdikleri süre ve ekran görüntüleri incelenmiştir. Bu amaçla 250 öğrenciye ait bu görüntü ve sınav bilgileriyle bir veri seti oluşturulmuştur. Oluşturulan bu veri setine ait görüntüler aynı zamanda eğitim kurumundaki uzmanlar tarafından da incelenerek kopya çekme teşebbüsü vardır veya yoktur olarak etiketlenmiştir. Oluşturulan bu veri setinde öğrencilerin ekran görüntülerine göre elde edilen Bakış Değerlerinin dağılımı Şekil 4.10'da verilmiştir. Şekil 4.10'da görüldüğü gibi, dağılım iki farklı bölge gruplanmıştır. Uzman görüşlerine göre sınavlara katılan 250 öğrencinin sadece 9 tanesi kopya çekme teşebbüsünde bulunmuştur. Bunun yanında, görüntülere göre bakış değerleri eşik değerinin altında olduğu halde kopya çekmeye teşebbüs, dikkati dağınık 7 öğrenci tespit edilmiştir. 250 öğrencinin, şüpheli olmayan ve kopya çekmeye teşebbüsedan öğrencilere ait istatistiksel bilgiler Çizelge 4.2'de verilmiştir. Şekil 4.11'de bakış değerlerine göre şüpheli görünen öğrenciler ve bakış değerleri grafik üzerinde gösterilmiştir.



Şekil 4.10. Öğrencilerin görüntülerine göre Bakış Değerlerinin dağılımı



Şekil 4.11. Şüpheli öğrencilerin bakış değerleri

Çizelge 4.2. Öğrencilere ait istatistiksel bilgiler

İstatistiksel Değerler	Tümü		Şüpheli Olmayan		Şüpheli	
	Süre	Bakış Değeri	Süre	Bakış Değeri	Süre	Bakış Değeri
Ortalama	7,12	44,14	7,11	45,65	7,56	1,78
Standart Sapma	2,04	13,51	2,04	11,07	2,13	1,99
Minimum	4	0	4	1	4	0
Maksimum	10	60	10	60	10	5

Çizelge 4.2’de tüm sınava katılan öğrencilerin, şüpheli ve şüpheli olmayanların ortalaması, standart sapması, minimum ve maksimum değerleri gösterilmiştir. Çizelge 4.3’de sınavda kopya girişiminde bulunmamış ilk 7 öğrenciye ait bakış değerleri verilmiştir. Çizelge 4.4’te ise kopya çekmeye teşebbüs eden 9 öğrenciye ait sınavda geçirdikleri süre ve geliştirilen uygulama ile hesaplanan Bakış değerleri verilmiştir. Görüldüğü gibi bakış değerleri 5’e eşit veya daha küçüktür. Bu da ekrana odaklandıkları zaman dilimin çok küçük olduğunu göstermektedir. Şekil 4.5’te bakış değeri küçük olmasına rağmen uzman görüşüne göre kopya çekmediği tespit edilmiş ama ekrana odaklanma konusunda sorunlu olan öğrencilere ait bilgileri göstermektedir.

Çizelge 4.3. Kopya çekmeyen Öğrencinin Bakış Tahmini Değerleri

Öğrenci	Sınavda Geçirilen Süre	Bakış Değeri
Öğrenci_1	8 dk	50.359038798955633
Öğrenci_2	6 dk	56.486297700686341
Öğrenci_3	7 dk	47.736537588564412
Öğrenci_4	4 dk	45.346767689255791
Öğrenci_5	6 dk	50.823315019771212
Öğrenci_6	9 dk	47.432147617411285
Öğrenci_7	10 dk	44.589392324329366

Şüpheli öğrencilerin sütun grafiği Şekil 5.3’de gösterilmiştir.

Çizelge 4.4. Kopya Çekmeye Teşebbüs Eden Öğrencilerin Bakış Tahmini Değerleri

Öğrenci	Sınavda Geçirilen Süre	Bakış Değeri
Öğrenci_223	10	1,00
Öğrenci_176	9	0,00
Öğrenci_139	8	2,00
Öğrenci_87	5	5,00
Öğrenci_69	8	1,00
Öğrenci_44	10	5,00
Öğrenci_37	6	2,00
Öğrenci_19	4	0,00
Öğrenci_62	8	0,00

Çizelge 4.5. 7 Bakış Değerine göre şüpheli görünen öğrenciler

Öğrenciler	Sınavda Geçirilen Süre	Bakış Değeri
Öğrenci_236	7	5,00
Öğrenci_205	8	3,00
Öğrenci_143	6	1,00
Öğrenci_129	4	9,00
Öğrenci_90	8	6,00
Öğrenci_56	8	8,00
Öğrenci_22	10	2,00

Çizelge 4.5’de görüldüğü gibi şüpheli öğrencilerin bakış değerleri 10 değerinin altında kalmıştır. Bu puanın şüpheli olmayan öğrencilerin bakış puanının altında olduğu açıktır.

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında geliştirilen LMS uygulaması ile uzaktan eğitim sürecinin düzgün ve güvenli bir şekilde yürütülmesi hedeflenmiştir. Bu kapsamda, öğrencilerin uzaktan eğitim sistemine kayıt olması, derslerin ve sınavların yürütülmesi gerçekleştirilebilmektedir. Katılımcıların hile yapmaması için kimlik doğrulama ve sınavda kopya çekmeye teşebbüs edilmesinin önüne geçilebilmesi için sınavda yüz ve bakış tespiti sisteme entegre edilmiştir. Sonuç olarak, yapılan çalışma ile uzaktan eğitim sistemlerinde kullanılan LMS yazılımları ile birçok modülün bir arada kullanılarak, sınav güvenliğinin sağlanmasında önemli bir çözüm oluşturduğu görülmüştür.

Bu çalışma, yüz tanıma teknolojisi ve göz bebekleri takibi ile , çevrim içi bir sınavda, kameralarını açan öğrencilerin sınav anında ekran dışı bölgelere bakıp bakmadığının tahminini yapmaktadır. Öğrenciler ve eğitimciler Okinar LMS yazılımını kullanmaktadır. Okinar LMS yazılımı üzerinde çevrimiçi sınav sistemi ve kameralı görüntü iletişimi için BBB video konferans sistemi bulunmaktadır. LMS yazılımına daha önceden eğitimciler tarafından kaydedilmiş öğrenciler sınav zamanı geldiğinde sınavı başlatabilmektedirler. Sınava giriş yapan öğrenciler aynı zamanda BBB video konferans sistemine de katılmış olurlar. Sınav anı boyunca öğrencilerin ekranı dışında biryere bakmaması beklenir. Öğrenci kamera görüntüleri BBB sisteminde mp4 formatında sınav bitene kadar kaydedilir. Sınav bittikten sonra öğrencilerin sınavda geçirdiği süre, sorulara verilen cevap anahtarı ve kamera görüntüleri kaydedilmiş olur. BBB sunucusundaki kamera görüntüleri sınav ile ilgili toplantı kimliği altında render edilerek sınav salonunu sonradan tekrar izlemek için, uzman eğitmenin inceleme yapması için bir video daha oluşur. Oluşturulan videoda salona katılan öğrencilerin kameraları birleştirilmiş şekilde gösterilmektedir. Sınav tamamlandıktan sonra kamera görüntülerinden , öğrenci kimlik doğrulaması yapılır. Videodan kimlik doğrulama işleminde haarcascade ve deepface kütüphaneleri kullanılır. Haarcascade ile videodan insan yüzü tespit edilip resim formatında kaydedilir. Deepface kütüphanesi de sisteme kayıtlı öğrencilerin fotoğraflarını videodan elde edilen görüntü ile karşılaştırarak kimlik tespitinde bulunur. Bu işlem ile sınav anında yapılabilecek en büyük usulsüzlük (sınava bir başkasının girmesi) engellenmiş olur. Kimlik doğrulaması tamamlandıktan sonra aynı video dosyasından öğrencinin bakış yönü tahmini çıkartılır. Bu işlemde mediapipe kütüphanesi kullanılır. Mediapipe ile insan yüzü tespit edildikten sonra, yüz üzerinden gözler, sonrasında göz bebekleri işaretlenmiş olur. Bu aşamadan sonra göz bebeklerinin

hareketlerine göre öğrenciden bakış yönü tahmini puanı çıkartılır. Gaze algoritması ve geliştirilen algoritma ile göz bebeklerinin ve başın hareketlerinden öğrencinin hangi yöne baktığı puanlanmış olur. Bu puan ile sorunsuz bakışlar 100, kesin kopya olarak değerlendirilen bakışlar 0 aralığında değerlendirilmektedir. Öğrencinin bakış yönü tahmini, LMS yazılımında yönetici panelinde listelenmektedir. Bakış yönü tahmini belirlenen değer altında kalan öğrenciler şüpheli olarak ayrıştırılarak, eğitmeniye rapor sunmakta ve sınav denetmenliği işlemi kolaylaştırılmaktadır.

Bakış değerlerinden usulsüzlük tahmini yani şüpheli listesi oluşturabilmek için bir eşik değeri altında kalan kullanıcıların, ekran dışına daha çok ilgilendikleri bir liste çıkartılabilmektedir. Bu işlem için 250 öğrencinin girmiş olduğu sınav sonucunda puanı çok düşük olan kişilerin sınav görüntüsü uzman eğitmen tarafından incelemesi neticesinde belirlenen eşik değerine göre şüpheli tahmin listesi tespit edilmiştir.

Eğitim kurumlarının ÖABT öğrencileri katılımı ile 10 dakikalık, 5 sorudan oluşan bir sınava 250 öğrenci katılım göstermiştir. Bu öğrencilerden 234 tanesinin usulsüzlük yapmadığı, 16 tanesinin ekran dışındaki alanlar ile ilgilendiği, 16 öğrenciden 9'unun usulsüzlük yaptığı, 7 öğrencinin değerlendirmeye uygun pozisyon almadığı tespit edilmiştir.

Bu işlem için 250 öğrencinin girmiş olduğu sınav sonucunda puanı çok düşük olan kişilerin sınav görüntüsü uzman eğitmen tarafından incelemesi neticesinde belirlenen eşik değerine göre şüpheli tahmin listesi oluşturulmuştur. Geliştirilen uygulama ile her bir öğrencinin sınav esnasında kayıt altına alınan ekran görüntülerinden hesaplanan bakış değerlerine göre kopya çekme teşebbüsleri tahmin edilmiştir. 250 öğrenciden 241 tanesi doğru olarak tespit edilmiş ve %96.4 başarıya ulaşılmıştır.

Bu çalışma LMS sistemi ve alt modülleri ile birlikte, çevrimiçi sınavları daha güvenli hale getirmek için DÖ yöntemleri kullanarak çözüm sunmuştur.-Bu sonuçlar ile katılımın çok fazla olduğu çevrim içi sınavlarda, uzman eğitmenlerin kameradan öğrencileri takip etmesi yerine, sınav sonunda sadece bakılması gereken kameraların listesinin oluşturulmasının büyük kolaylık sağlayacağı düşünülmüştür.

5.1 Öneriler

Gelecekte uzaktan eğitimde yüz tanıma ve bakış tahmini için bir model eğitilmesinin çalışmayı derinleştireceği düşünülmektedir. Yapılan çalışmada tek bir BAP değerinin olması şüpheli listesinde yardımcı olmaktadır ama BAP değerinin

derecelendirilmesi, usulsüz işlemler listesinde kademeli bilgi sağlayabilir. Örnek olarak Kritik, Orta, Düşük şüphe derecelerinde eğitimcilerin kararına yardımcı olacağı düşünülmektedir.

Ekrana bakış değerinin daha hassas hale gelmesi, ekranda bakılan yerlerin ısı haritası gibi özellikler ile sistemin daha çok ayrıtıdan çıkarım yapması sağlanabilir.



KAYNAKLAR

- Ahdid, R., Taifi, K., ve Safi, S., 2016, Euclidean & Geodesic Distance between a Facial Feature Points in Two-Dimensional Face Recognition System, *International Arab Conference on Information Technology (ACIT'2016)*, Sultan Moulay Slimane University
- Akar, F., ve Akgül, İ., 2022, Derin Öğrenme Modeli ile Yüz İfadelerinden Duygu Tanıma, *Journal of the Institute of Science and Technology*, 12(1), 69-79.
- Alsabhan, W., 2023, Student Cheating Detection in Higher Education by Implementing Machine Learning and LSTM Techniques, *Sensors* 2023, 23, 4149, <https://doi.org/10.3390/s23084149>
- Artsin, M., Koçdar, S., ve Bozkurt, A., 2020, Öğrenenlerin Öz-Yönetimli Öğrenme Becerilerinin Kitlese Açık Çevrimiçi Dersler Bağlamında İncelenmesi, *Anadolu Journal of Educational Sciences International*, 10(1).
- Baffour, P. A., Nunoo-Mensah, H., Keelson, E., ve Kommey, B., 2022, A Survey on Deep Learning Algorithms in Facial Emotion Detection and Recognition, *Inf. J. Ilm. Bid. Teknol. Inf. dan Komun.*, 7, 1, 24-32, <https://doi.org/10.25139/inform.v7i1.4563>
- Borgalli, R. A., ve Surve, S., 2022, Deep learning for facial emotion recognition using custom CNN architecture, *J. Phys.: Conf. Ser.*, 2236, <https://doi.org/10.1088/1742-6596/2236/1/012004>
- Bulut, C., (2021, Ocak 17), *En iyi 10 lms yazılımı (öğrenme yönetim sistemi)*. Argenova, <https://www.argenova.com.tr/en-populer-10-lms-yazilimi-ogrenme-yonetim-sistemi>
- Çalışkan, D., ve Demir, Ö., 2022, Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti, *Int. Per. of Recent Tech. in App. Eng.* 2022; 3,1, 28-43, <https://doi.org/10.29228/porta.8>
- Dang, N. C., Moreno-García, M. N., & De la Prieta, F., 2020, Sentiment Analysis Based on Deep Learning: A Comparative Study, *Electronics*, 9(3).
- Dursun, F., & Gelen, G. (2021). Düşük Çözünürlüklü Resimlerden Göz Merkezi Belirleme ve İris Yarıçapı Kestirimi için İyileştirilmiş Bir Algoritma.
- El Barachi, M., AlKhatib, M., ve Mathew, S. S., 2021, A Hybrid Machine Learning

- Approach for Sentiment Analysis of Partially Occluded Faces, *2021 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*, 389-392.
- Ergin, T., <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> [Ziyaret Tarihi: 1 Ocak 2024].
- Furqon, M., Sinaga, P., Liliyasi, L., & Riza, L. S. (2023). The Impact of Learning Management System (LMS) Usage on Students. *TEM Journal*, 1082-1089.
<https://doi.org/10.18421/TEM122-54>
- Genemo, M.D., 2022, Suspicious activity recognition for monitoring cheating in exams, *Proc.Indian Natl. Sci. Acad.* 88, 1–10, <https://doi.org/10.1007/s43538-022-00069-2>
- Gökçakıl, H. (2022, Mart 1), Online görüntülü görüşme uygulaması microsoft teams nedir, nasıl indirilir ve kullanılır?, <https://www.webtekno.com/microsoft-teams-nedir-nasil-kullanilir-h121140.html>
- Gupta, S., Kumar, P., ve Tekchandani, R.K., 2023, Facial emotion recognition based real-time learner engagement detection system in online learning context using deep learning models, *Multimed Tools Appl* 82, 11365–11394, <https://doi.org/10.1007/s11042-022-13558-9>
- Hayat, C. (2020, Nisan 15), Zoom nedir? Zoom nasıl kullanılır?, Medium, <https://medium.com/@cansuhayat58/zoom-nedir-zoom-nas%C4%B1l-kullan%C4%B1r-22ef1e9d7247>
- Hussein, D. M. E.-D. M., 2018, A survey on sentiment analysis challenges, *Journal of King Saud University - Engineering Sciences*, 30(4), 330-338.
- Hussein, F., Al-Ahmad, A., El-Salhi, S., Alshdaifat, E., ve Al-Hami, M., 2022, Advances in Contextual Action Recognition: Automatic Cheating Detection Using Machine Learning Techniques, *Data* 2022, 7, 122, <https://doi.org/10.3390/data7090122>
- İnik, Ö., ve Ülker, E., 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Dergipark*, 6(3), 85-104.
- Jayalekshmi, J., ve Mathew, T., 2017, Facial expression recognition and emotion classification system for sentiment analysis, *2017 International Conference on Networks & Advances in Computational Technologies (NetACT)*, 1-8.

- Kaushik, M. (2021, Haziran 21), *Computer vision using mediapipe*, Medium, <https://medium.com/geekculture/computer-vision-using-mediapipe-c0933b743cf5>
- Keskin, K., ve Güneş, A., 2015, Online Sınav Sistemlerinde Güvenlik Sorunları Ve Güvenli Online Sınav Giriş Uygulaması, Eğitim ve Öğretim Araştırmaları Dergisi, 4, 4, 06, ISSN: 2146-9199, <http://www.jret.org/FileUpload/ks281142/File/06.keskin...pdf>
- Ko, B. C., 2018, A Brief Review of Facial Emotion Recognition Based on Visual Information, *Sensors* 2018, 18, 401, <https://doi.org/10.3390/s18020401>
- Koç, E., 2022, "Yüz tanıma teknolojisine kısa bir bakış", Miuul, <https://miuul.com/not-defteri/yuz-tanima-teknolojisine-kisa-bir-bakis> [Ziyaret Tarihi: 27 Aralık 2023]
- Koç, T., 2015, OpenCV Haar Cascade sınıflandırıcısı Nedir? [online], Talhakoc.NET, <https://talhakoc.net/OpenCV-haar-cascade-siniflandiricisi-nedir> [Ziyaret Tarihi: 2 Aralık 2022].
- Kohli, S. E., Jannaj, Y., Maanan, M., ve Rhinane, H., 2021, Deep Learning: New Approach For Detecting Scholar Exams Fraud, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLVI-4/W3-2021, 103–107, <https://doi.org/10.5194/isprs-archives-XLVI-4-W3-2021-103-2022>
- Kotsiantis, S., Pierrakeas, C., ve Pintelas, P., 2004, Predicting Students' Performance in Distance Learning Using Machine Learning Techniques, *Applied Artificial Intelligence*, 18(5), 411-426.
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E., 2012, ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, 25.
- Kyle, (2023, Ağustos 16), *Gaze estimation with multi-view tracking*, Medium, <https://blog.seeso.io/gaze-estimation-with-multi-view-tracking-85e9753b2279>
- LeCun, Y., Bengio, Y., & Hinton, G., 2015, Deep learning, *Nature*, 521(7553), Art. 7553.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278-2324.
- Longline, (2021, Kasım 29), Video konferans nedir ne işe yarar, <https://www.longlinenetwork.com/urunler/video-konferans-nedir-ne-ise-yarar/>

- Mehendale, N., 2020, Facial emotion recognition using convolutional neural networks (FERC), *SN Appl. Sci.* 2, 446, <https://doi.org/10.1007/s42452-020-2234-1>
- Mohanta, S.R., ve Veer, K., 2022, Trends and challenges of image analysis in facial emotion recognition: a review, *Netw Model Anal Health Inform Bioinforma* 11, 35, <https://doi.org/10.1007/s13721-022-00376-0>
- Okinar, <https://okinar.com> [Ziyaret Tarihi: 1 Ocak 2024].
- Özdemir, D., ve Uğur, M.E., 2021, A Model proposal on the determination of student attendance in distance education with face recognition technology, *Turkish Online Journal of Distance Education (TOJDE)*, 22(1).
- Peng, H., Cambria, E., & Hussain, A., 2017, A Review of Sentiment Analysis Research in Chinese Language, *Cognitive Computation*, 9(4), 423-435.
- Pieńczykowski D. (2020, Mayıs 28), *How to build a learning management system from scratch*, Medium, <https://medium.com/selleo/how-to-build-a-learning-management-system-from-scratch-92b4e1fcb500>
- Rodríguez-Villalobos, M., Fernandez-Garza, J., ve Heredia-Escorza, Y., 2023, Monitoring methods and student performance in distance education exams, *International Journal of Information and Learning Technology*, 40 2, 164-176, <https://doi.org/10.1108/IJILT-04-2022-0085>
- Saaisri, (2022, Temmuz 23), *Deep Face recognition*, Medium, <https://medium.com/featurepreneur/deepface-face-recognition-91ebb7e794a4>
- Safali, Y., & Avaroğlu, E., 2021, Derin Öğrenme ile Yüz Tanıma ve Duygu Analizi, *Avrupa Bilim ve Teknoloji Dergisi*, 31, 764-770.
- Salamh, A. B. S., & Akyüz, H., 2022, A New Deep Learning Model for Face Recognition and Registration in Distance Learning, *International Journal of Emerging Technologies in Learning (IJET)*, 17(12), 29-41.
- Simonyan, K., & Zisserman, A., 2015, Very Deep Convolutional Networks for Large-Scale Image Recognition, *ICLR 2015*.
- Singh, V., Gandhi, S., Kumar, R., Yadav, R., ve Joshi, S., 2021, Deep Neural Network for Facial Emotion Recognition System, *Computational and Experimental Methods in Mechanical Engineering, Smart Innovation, Systems and Technologies*, 239, Springer, Singapore. https://doi.org/10.1007/978-981-16-2857-3_39

- Singhal , A., ve Bhardwaj, V., 2022, Machine Learning Based Model To Predict Human Emotions Using Facial Features, *International Journal Of Scientific Research In Engineering And Management (Ijsrem)*, 06, 11, ISSN: 2582-3930
- Subudhiray, S., Palo, H.K., ve Das, N., 2023, Effective recognition of facial emotions using dual transfer learned feature vectors and support vector machine, *Int. j. inf. tecnol.* 15, 301–313, <https://doi.org/10.1007/s41870-022-01093-7>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A., 2015, Going deeper with convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.
- Tenekeci, M. E., Gümüşçü, A., Aslan, E., 2014, *Görüntüden OpenCV ile Duygu Analizi, Mersin Üniversitesi 14. Akademik Bilişim Konferansı Bildirileri* .
- Tejada, J., Freitag, R.M.K., Pinheiro, B.F.M., Cardoso, P. B., Souza, V.R.A., ve Silva, L.S., 2022, Building and validation of a set of facial expression images to detect emotions: a transcultural study, *Psychological Research* 86, 1996–2006, <https://doi.org/10.1007/s00426-021-01605-3>
- Ukoha, C. (2022). As simple as pressing a button? A review of the literature on BigBlueButton. *Procedia Computer Science*, 197, 503-511. <https://doi.org/10.1016/j.procs.2021.12.167>
- Ünyildiz, Z. (2023 Mart 28), *FFmpeg nedir?*, Medium, <https://zekiunyildiz.medium.com/ffmpeg-nedir-e65bdf1fc754>
- Wang, M., & Deng, W. (2021). Deep face recognition: A survey. *Neurocomputing*, 429, 215-244. <https://doi.org/10.1016/j.neucom.2020.10.081>
- Xu, G., Meng, Y., Qiu, X., Yu, Z., & Wu, X., 2019, Sentiment Analysis of Comment Texts Based on BiLSTM, *IEEE Access*, 7, 51522-51532.
- Yazır, S., 2018, Türkiye'de bulut bilişimin teknolojik gelişimi ve bulut platformu üzerinde örnek bir kişisel web uygulamasının sunulması., Yayımlanmamış Yüksek Lisans Tezi., Necmettin Erbakan Üniversitesi Fen Bilimler Enstitüsü, Konya
- Yılmaz, 2021, The design of smart dashboard system using cloud computing based face recognition technology, <https://tez.yok.gov.tr/>, 702125
- Yue, L., Chen, W., Li, X., Zuo, W., & Yin, M., 2019, A survey of sentiment analysis in social media, *Knowledge and Information Systems*, 60(2), 617-663.

- Zainuddin, Z., & Laswi, A. S., 2017, Implementation of The LDA Algorithm for Online Validation Based on Face Recognition, *Journal of Physics: Conference Series*, 801(1), 012047.
- Zeiler, M. D., & Fergus, R., 2014, Visualizing and Understanding Convolutional Networks, *Springer International Publishing*, 818-833.
- Zhang, A., Lipton, Z. C., Li, M., Smola, A. J., 2021, "Dive into Deep Learning", Cornell University, <https://doi.org/10.48550/arXiv.2106.11342>
- Zhang, L., Wang, S., & Liu, B., 2018, Deep learning for sentiment analysis: A survey, *WIREs Data Mining and Knowledge Discovery*, 8(4), e1253.
- Zhao, Q., & Ye, M., 2010, The application and implementation of face recognition in authentication system for distance education, *2010 International Conference on Networking and Digital Society*, 1, 487-489.
- Zheng, T., Pan, W., & Jia, B., 2009, Study on the Application of Pattern Recognition Technology in Distance Education System, *2009 Second International Conference on Computer and Electrical Engineering*, 1, 474-477.