



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
PSİKİYATRİ HEMŞİRELİĞİ ANABİLİM DALI

**Derin Öğrenme Yöntemi Kullanarak Psikiyatri Kliniğinde
Şiddet ve İntihar Girişimi Davranışlarının Tespiti**

Doktora Tezi

Ceyda ÖZTÜRK AKDENİZ

Şubat 2025



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

PSİKİYATRİ HEMŞİRELİĞİ ANABİLİM DALI

**Derin Öğrenme Yöntemi Kullanarak Psikiyatri Kliniğinde
Şiddet ve İntihar Girişimi Davranışlarının Tespiti**

Doktora Tezi

Ceyda ÖZTÜRK AKDENİZ

Danışman

Prof. Dr. Ayşe OKANLI

Şubat 2025

TEZ JÜRİSİ ONAYI

Ceyda ÖZTÜRK AKDENİZ tarafından hazırlanan "Derin Öğrenme Yöntemi Kullanarak Psikiyatri Kliniğinde Şiddet ve İntihar Girişimi Davranışlarının Tespiti" başlıklı bu Doktora Tezi, Psikiyatri Hemşireliği Anabilim Dalı'nda hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Prof. Dr. Ayşe Okanlı
İstanbul Medeniyet Üniversitesi

Üyeler:

Prof. Dr. Emine CAN
Medeniyet Üniversitesi

Doç. Dr. Berna DİNÇER
Medeniyet Üniversitesi

Doç. Dr. Yeliz DOĞAN MERİH
Sağlık Bilimleri Üniversitesi

Dr. Öğr. Üyesi Elçin BABAOĞLU
Üsküdar Üniversitesi

Tez Savunma Tarihi: 24 / 02 / 2025

BEYANLAR

Yazım ve Kaynak Gösterme Kılavuzu Beyanı

Danışmanlığımda yazılan bu tezin APA yazım ve kaynak gösterme kılavuzunda belirtilen kurallara uygun olarak yapılandırıldığı ve bu kılavuzun metin içi kaynak gösterme standartlarının bu tezde tutarlı olarak uygulandığı tarafımdan incelenerek teyit edilmiştir.

İmza

Prof. Dr. Ayşe OKANLI

Etik İlkelere Sadakat Beyanı

Hazırladığım bu tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi beyan ederim.

İmza

Ceyda ÖZTÜRK AKDENİZ

TEŞEKKÜR

Sevgili danışmanım sayın Prof. Dr. Ayşe Okanlı hocama tez önerimden son ana kadar bana destek olduğu için teşekkürlerimi sunarım. Alana yeni bir şey katmak istememin heyecanını benimle tüm samimiyetiyle paylaştığı için ve yaşanan olumsuzluklarda hevesimi hiç kırmadan bana güç verdiği için kendisine minnettarım. Bilgi ve donanımıyla bana hep destek olan, yönlendirmeleriyle tez sürecimi yürütmemi kolaylaştıran, her soruma titizlikle yanıt veren sayın Prof. Dr. Emine Can hocama teşekkürlerimi sunarım. Tez izleme komitemde yer alarak beni destekleyen sayın Dr. Öğr. Üyesi Elçin Babaoğlu hocama teşekkürlerimi sunarım. Oyunculara ulaşabilmem konusunda bana çok yardımcı olan ve desteğini esirgemeyen sayın Doç. Dr. Rüstem Mürseloğlu hocama ve çalışmamda yer almaya gönüllü olan tiyatro oyuncularına teşekkürlerimi sunarım.

Tezimin ilk aşamasında mühendislik alanında yaptığı başarılı işlerden dolayı kendisine ulaştığım, bilgi birikimi ve yönlendirmeleriyle destek olan sevgili dostum Felipe Partika'ya çok teşekkürler.

Doktora sürecimde bilgi birikimi, maddi ve manevi desteğiyle bana güç veren ve tezimin her aşamasında tüm yorgunluğuna rağmen yanımda olan kıymetli eşim Serhat Oytun Akdeniz'e, bu süreçte minik kalbiyle tüm yorgunluğumu alan, her anı birlikte paylaştığım canım kızım Nil Vera Akdeniz'e, son olarak anne, baba ve kardeşlerime sonsuz teşekkür ediyorum.

CEYDA ÖZTÜRK AKDENİZ

ÖZET

Derin Öğrenme Yöntemi Kullanarak Psikiyatri Kliniğinde Şiddet ve İntihar Girişimi Davranışlarının Tespiti

ÖZTÜRK AKDENİZ, Ceyda

Doktora Tezi, Psikiyatri Hemşireliği Anabilim Dalı

Danışman: Prof. Dr. Ayşe OKANLI

Şubat 2025

Bu araştırmanın amacı psikiyatri yataklı servisinde intihar ve şiddet davranışlarının derin öğrenme yöntemi kullanarak tespitini sağlamaktır. Araştırma Göztepe Prof. Dr. Süleyman Yalçın Şehir Hastanesi Erişkin Erkek Psikiyatri Kliniğinde Mayıs-Temmuz 2024 tarihleri arasında yürütülmüştür. Araştırma <https://clinicaltrials.gov/> adresine kayıt edilmiştir (ClinicalTrials.gov Identifier: NCT06421480). Araştırma kapsamında şiddet, şiddetsizlik ve intihar girişimi olmak üzere üç sınıf tanımlanmıştır. Şiddet ve şiddetsizlik sınıflarına ait eğitim verileri için Life Violence Situations Dataset kullanılırken, ası yoluyla intihar girişimi verileri özel olarak oluşturulmuştur. Üç sınıfa ait test verisi için ise özgün bir veri seti oluşturulmuştur. Görüntüler, dokuz oyuncu yardımıyla kamera kaydı yöntemiyle toplanmış; OpenPose algoritması kullanılarak açı ve pozisyon değişiklikleri hesaplanmıştır. Bu özellikler, azimutal yer değiştirme yönteminin uygulanmasıyla elde edilerek LSTM (Uzun Kısa Dönem Hafızası) ağına girdi olarak sunulmuştur. Doğruluk oranı %95 olan modelin gerçek zamanlı uyarı mekanizması, Telegram ve bilgisayar ekranı üzerinden “violence detected” veya “suicide attempt detected” mesajlarını iletecek şekilde tasarlanmıştır. Gerçek zamanlı değerlendirme aşamasında 4 tiyatro/drama oyuncusunun yardımı alınmıştır. Oyuncular gece ve gündüz sürelerince üç sınıfa ait tüm eylemleri gerçekleştirmiş ve kamera kaydı yapılmıştır. Kaydedilen görüntüler üzerinden üç sağlık çalışanının görüşü alınarak meydana gelen her şiddet ve intihar eyleminin başlangıç ve bitiş zamanlarını ortak bir değerlendirmeye yazması istenmiştir. Modelin çalışması bittiğinde oluşan log dosyası sağlık çalışanlarının belirttiği başlangıç ve bitiş süreleriyle kıyaslanarak hem gerçek zamanlı etkinliği hem de insan gözüyle kıyaslandığında ki etkinliği değerlendirilmiştir. Gece çekimlerinde model 51 uyarı vermiş; bunların üçü gerçekte şiddet içermemesine rağmen “şiddet” şeklinde etiketlenmiştir. Yüze yastık kapama ve tekme atma davranışlarında uyarı vermesi gerekirken, vermemiştir. Gündüz çekimlerinde 122 uyarı alınmış, model gerçekleşen her şiddet eylemi için uyarı vermiştir. Şiddetsiz eylemlerde 37 yanlış şiddet uyarısı gözlenmiştir. Bu değerlendirme sonucunda gece ve gündüz sürelerince hemen hemen tüm şiddet ve intihar girişimi eylemlerinin tespit edildiği sonucuna varılmıştır.

Anahtar Kelimeler: Şiddet, Şiddetsizlik, İntihar Girişimi, Derin Öğrenme, Psikiyatri Kliniği

ABSTRACT

Detection of Violence and Suicide Attempt Behaviors in Psychiatry Clinic Using Deep Learning Method

ÖZTÜRK AKDENİZ, Ceyda

Doctoral Thesis, Department of Psychiatric Nursing

Advisor: Prof. Dr. Ayşe OKANLI

February 2025

The purpose of this study is to detect suicidal and violent behaviors in an inpatient psychiatric setting using a deep learning approach. The research was conducted between May and July 2024 at the Adult Male Psychiatry Clinic of Göztepe Prof. Dr. Süleyman Yalçın City Hospital and registered at <https://clinicaltrials.gov> (ClinicalTrials.gov Identifier: NCT06421480). Within the scope of the study, three classes were defined: violence, non-violence, and attempted suicide. While the Life Violence Situations Dataset was employed for training data concerning violence and non-violence, an additional dataset for attempted suicide by hanging was specifically created. An original dataset was then constructed for testing across all three classes. Video data were collected using camera recordings of nine actors, after which angle and position changes were computed via the OpenPose algorithm. The resulting features, obtained by applying azimuthal displacement, were subsequently fed into an LSTM (Long Short-Term Memory) network. The model achieved an accuracy rate of 95% and was equipped with a real-time alert mechanism that provides “violence detected” or “suicide attempt detected” notifications via Telegram and computer screens. During the real-time evaluation phase, four theater/drama actors performed all three classes of actions (violence, non-violence, and attempted suicide) both day and night, while their behaviors were recorded. Three healthcare professionals then reviewed these recordings and jointly determined the start and end times of each violent and suicidal act. Upon completion, the model’s log file was compared against these reference times to evaluate both real-time performance and agreement with human observation. During nighttime recordings, the model issued 51 alerts, with three falsely labeled as violence, and failed to detect covering the face with a pillow and kicking behaviors. In daytime recordings, 122 alerts were generated, capturing all actual violent incidents but mistakenly labeling 37 non-violent acts as violent. Based on this assessment, it was concluded that nearly all violent and suicidal behaviors were successfully detected in both daytime and nighttime sessions.

Keywords: Violence, Non-violence, Suicide Attempt, Deep Learning, Psychiatry Clinic

İÇİNDEKİLER

ÖZET	VI
ABSTRACT	VII
İÇİNDEKİLER	VIII
TABLolar LİSTESİ	X
ŞEKİLLER LİSTESİ	X
KISALTMALAR VE SİMGELER	XI
BÖLÜM 1. GİRİŞ.....	1
1.1.Problemin Tanımı ve Önemi.....	1
1.2. Araştırmanın Amacı.....	2
1.3. Araştırmanın Hipotezleri.....	2
BÖLÜM 2. GENEL BİLGİLER.....	3
2.1. Şiddet Davranışı ve Türleri.....	3
2.1.1.Fiziksel Şiddet.....	3
2.1.2.Cinsel Şiddet.....	3
2.1.3.Duygusal Şiddet.....	3
2.1.4. Ekonomik Şiddet.....	4
2.1.5. Siber Şiddet.....	4
2.2. Psikiyatri Kliniklerinde Şiddet Davranışı.....	4
2.3.Psikiyatri Kliniklerinde İntihar Davranışı.....	5
2.4. Makine Öğrenmesi Yöntemi.....	7
2.4.1.Supervised Learning (Gözetimli Öğrenme).....	7
2.4.2. Unsupervised Learning (Gözetimsiz Öğrenme).....	8
2.4.3.Semisupervised Learning (Yarı Gözetimli Öğrenme).....	8
2.4.4.Reinforcement Learning (Takviyeli Öğrenme).....	8
2.5. Derin Öğrenme.....	8
2.6. Derin Öğrenme ve Psikiyatri Alnında Kullanımı	9
BÖLÜM 3. GEREÇ VE YÖNTEM.....	11
3.1. İş Akış Diagramı.....	12
3.2 Veri Seti Oluşturma.....	13
3.3. OpenPose Uygulamasıyla Beden Özelliklerinin Çıkarımı.....	14
3.4. Veri Ön İşlemesi.....	16
3.5. Data Augmentation (Veri Artırma).....	17

3.6. Modelin Mimarisi.....	17
3.7. Davranışın Sınıflandırılması.....	20
3.8 Karşılaşılan Zorluklar ve Çözümler.....	20
4. BULGULAR.....	22
4.1. Modelin Performans Değerlendirmesi.....	22
4.2. Gerçek Zamanlı Değerlendirme.....	26
5. TARTIŞMA.....	38
5.1. Şiddet Tespitine Yönelik Sonuçların Tartışılması.....	38
5.2. İntihar Girişimi Tespitine Yönelik Sonuçların Tartışılması.....	39
5.3. Psikiyatri Hemşireliği ve Güvenli Ortam Üzerine Etkilerinin Tartışılması.....	40
6. SONUÇ ve ÖNERİLER.....	42
6.1.Sonuç.....	42
6.2. Öneriler.....	42
KAYNAKLAR.....	44
EK_1: ETİK KURUL İZNİ.....	51
EK_2: KURUM İZNİ.....	52
EK_3: BİLGİLENDİRİLMİŞ GÖNÜLLÜ ONAM FORMU.....	53
EK_4: ANKET FORM.....	54

TABLÖLAR LİSTESİ

Tablo 1: Sınıflandırma Raporu (Sınıf 0: Şiddetsizlik, Sınıf 1: Şiddet, Sınıf 2: İntihar Girişimi).....	23
Tablo 2: Confusion Matrix.....	25
Tablo 3: Gerçek Zamanlı Değerlendirme Tablosu.....	30

FORMÜLLER LİSTESİ

Formül 1: F1 Score Hesaplama.....	22
Formül 2: Accuracy Hesaplama.....	22
Formül 3: Recall Hesaplama.....	22
Formül 4: Precision Hesaplama.....	23

ŞEKİLLER LİSTESİ

Şekil 1: İş Akış Diagramı.....	12
Şekil 2: OpenPose Uygulamasının Şiddet ve İntihara Yönelik Eylemlerde Vücut Anahtar Noktalarının Çıktı Örnekleri.....	14
Şekil 3: Bir boyutlu evrişimlerin iki katmanını, LSTM'yi ve yoğun katmanları ve ayrıca onun uzaysal boyutlarını içeren ağ mimarisi.....	18
Şekil 4: Sistemin Gerçek Zamanlı Akış Diagramı.....	28
Şekil 5: Gündüz Gelen Uyarıların Grafiği.....	34
Şekil 6: Gece Gelen Uyarıların Grafiği.....	34
Şekil 7: Gündüz Sergilenen Davranışlara Ait Isı Haritası.....	35
Şekil 8: Gece Sergilenen Davranışlara Ait Isı Haritası.....	35
Şekil 9: Gerçek Zamanlı Değerlendirmede Gece Kaydından Telegrama Gelen Uyarıların Ekran Görüntüsü.....	36
Şekil 10: Gerçek Zamanlı Değerlendirmede Gündüz Kaydından Telegrama Gelen Uyarıların Ekran Görüntüsü.....	36

KISALTMALAR ve SİMGELER

WHO: Dünya Sağlık Örgütü

YZ: Yapay Zeka

AI: Yapay Zeka

ML: Makine Öğrenmesi

DL: Derin Öğrenme

SSL: Yarı Gözetimli Öğrenme

RL: Takviyeli Öğrenme

DNN: Derin Sinir Ağları

GPU: Grafik İşleme Birimi

LSTM: Uzun Kısa Süreli Bellek

2D: İki Boyutlu

CNN: Evrişimsel Sinir Ağı

YOLO: You Only Look Once

BİLSTM: Çift Yönlü Uzun Kısa Süreli Bellek

LDA: Gizli Dirichlet Ayrımı

IoT: Nesnelerin İnterneti

BoW: Kelime Torbası

BÖLÜM 1. GİRİŞ

1.1. Problemin Tanımı ve Önemi

Psikiyatri kliniğinde yatan hastaların güvenliğini sağlamak, şiddet ve intihar gibi riskli davranışları tespit etmek sağlık çalışanlarının birinci sorumlulukları arasındadır. Özellikle psikiyatrik hastalığa sahip bireyler arasında intihar kanıta dayalı en önemli risk etmenidir ve hasta güvenliğini tehdit eden en önemli unsurların başında gelmektedir (Harmancı, 2015). İntihar girişimi kliniklerde sıklıkla karşılaşılan bir kriz durumudur. Yatan hastalarda intihar girişimi oranının 5-10 kat arttığı bilinmektedir. İntihar girişimlerinin yanı sıra şiddet davranışları da yatarak tedavi gören hastaların olduğu kliniklerde sıklıkla karşımıza çıkmaktadır (Woottuluk et al., 2020). Ülkemizde Kızılırmak (2014) yaptığı çalışmada şizofreni ve diğer psikotik bozukluğa sahip bireylerde şiddet potansiyelinin yüksek olduğu belirlenmiştir. İntihar girişimi oranlarının majör depresyon, bipolar bozukluk, şizofreni ve diğer psikotik bozuklukların varlığında anlamlı düzeyde arttığı sonucuna varılmıştır. Literatür tarandığında psikiyatri kliniklerinde şiddet ve intihar davranışının önlenmesinin ülkemizde ve Dünya’da önemli bir konu olduğu anlaşılmaktadır.

Bu araştırmada tespit edilmesi istenen davranışlar şiddet (tokat atma, arkadan boğazını sıkma, kafa atma, sert bir cisimle vurma, saç çekme, tekme atma, yumruk atma, itme, duvara yaslama, boğuşma, yüze yastık kapama) ve ası yoluyla intihar davranışlarıdır. Ası eyleminin yüksek oranda ölümle sonuçlanması ve bazı ülkelerde giderek daha yaygınlaşması nedeniyle Dünya çapında öncelikli bir sorun haline gelmiştir. Ası yoluyla intihar girişimi sonrası sağ kalan bireylerde miyokardiyal hasar, felç ve hipoksik beyin hasarı gibi durumlar tespit edilmiştir. Ası yoluyla intiharlarda bağlama noktalarının ve araçlarının tamamı yok edilememesi sebebiyle ası olarak intiharı azaltmak için önleme alanında daha az fırsat mevcuttur (Sabrinskas et al., 2022; Naghavi, 2019). Christl et al. (2022) yaptığı çalışmada psikiyatri kliniklerinde yatarak tedavi gören hastalarda ası yoluyla intihar en sık karşılaşılan intihar yöntemi olduğu ve çoğunun ölümle sonuçlandığı tespit edilmiştir.

Psikiyatri kliniklerinde görev yapan hemşireler, hasta güvenliğini sağlamak ve terapötik ilişkileri sürdürmek gibi önemli sorumlulukları yerine getirmektedir (Slemon et al., 2017). Bu bağlamda, psikiyatri hemşireleri özellikle şiddet ve intihar davranışlarının önlenmesi amacıyla risk değerlendirme, psiko-eğitim, kriz müdahalesi ve önleyici güvenlik stratejileri gibi kapsamlı girişimler uygulamaktadırlar (American Psychiatric Nurses Association, 2022; Svensson, 2022). Ayrıca, intihar riski yüksek olan hastalarla çalışırken koruyucu önlemleri alma (örneğin ası girişiminde kullanılabilecek materyallerin kontrolü) ve bu hastalara özel bakım planları düzenleme sorumluluğu da hemşirelerin görevleri arasındadır. Psikiyatri kliniklerinde şiddet ve intihar davranışlarının belirlenmesi ve hasta/çalışan güvenliğinin sağlanması amacıyla Sağlık Hizmetleri Genel Müdürlüğü (2023) sağlıkta kalite standartları kapsamında, psikiyatri kliniklerinde yatan hastaların kamerayla gözlemlenmesine ilişkin önlemler yer almaktadır. Ancak bu önlemler tamamıyla sorunu çözmede yeterli değildir. Psikiyatri kliniklerinde hastanın takibi bir hemşirenin sürekli olarak bilgisayar ekranından odalara yerleştirilen kamera görüntülerini takip etmesiyle sağlanmaktadır. Özellikle gece nöbetlerinde daha az sayıda hemşire çalışmaktadır. Bu durum hem gece nöbetlerinde kamera takibinin yapılmasını zorlaştırmakta hem de hasta güvenliği açısından problem oluşturmaktadır. Ekran takibi yapılamadığı anlarda meydana gelebilecek olumsuz davranışlar gözden kaçabilmektedir. Bu nedenle yapay zeka ve veri analizinde gün geçtikçe daha yaygın kullanılmaya başlayan derin

öğrenme yöntemi şiddet ve intihar gibi olumsuz durumları önlemek amacıyla kullanılmıştır. Derin öğrenme mevcut verilerden anlamlı sonuç/tahmin çıkarmaya çalışan yapay zeka algoritmalarının özelleşmiş bir alt dalıdır. Sağlık alanında derin öğrenme yöntemi sıkça kullanılmaktadır ve psikiyatride bu alanlardan birisidir. Literatür incelendiğinde psikiyatri alanında derin öğrenme genellikle hastalıkların doğru teşhisi, hastalığın seyri ve tedaviye yanıt konusunda kullanılmıştır. Ruhsal hastalığa sahip bireylerde beden hareketlerinden duyguları tanımak ve sınıflandırmak amacıyla yapılan çalışmada % 90'nın üzerinde başarı elde edilmiştir (Ahmed et al., 2019). Park ve arkadaşlarının (2016) yaptığı bir çalışmada genel insan hareketlerini tanımaya yönelik bir çalışma yapmış ve % 95 üzeri başarı elde etmiştir. Başka bir çalışmada intihar eyleminin tam zamanlı tespitine yönelik yüksek başarı elde edilmiştir (Bouachir et al., 2018). Bu araştırmada derin öğrenme yöntemi kullanarak psikiyatri kliniğinde tedavi gören hastaların şiddet ve intihar girişimi davranışlarının tespitini sağlamak birincil amacımızdır. Psikiyatri klinikleri bu davranışların sık meydana geldiği kliniklerdir. Araştırma kapsamında yer alan davranışların tespiti derin öğrenme yöntemi ve OpenPose uygulaması kullanılarak beden hareketlerinden sağlanmıştır. OpenPose insan vücudunun iskelet yapısını yüksek doğrulukla tespit ederek uzamsal bir temel sunmaktadır. Geleneksel ham görüntü verilerine göre gürültüye ve ortamsal değişimlere karşı daha dayanıklıdır. OpenPose görsel içeriği iskelet noktalarına indirgeyerek bu sayede daha az boyutlu ancak zengin bir veri temsili sağlamaktadır. Ancak, sadece anlık pozları yakalamak, dinamik süreçleri tam anlamıyla çözümlemek için yeterli olmamaktadır. LSTM (Long Short-Term Memory) gibi zaman serisi analizine odaklanan derin öğrenme yöntemleri, bu iskelet verilerinin zaman içindeki ardışık değişimlerini yakalayıp anlamlandırmaya olanak tanır. OpenPose, LSTM modelleriyle birleştirildiğinde, modelin farklı bireylerin hareketlerini, farklı ortam koşullarında dahi tutarlı bir biçimde yorumlayabilmesine imkân tanıyabilmektedir. Bu olumlu özellikler nedeniyle OpenPose ve LSTM modeli çalışmada tercih edilmiştir.

Psikiyatri kliniğinde şiddet ve intihar davranışlarının erken tespitinin sağlanması, hemşirelerin hasta bakımı ve güvenliği konusundaki rollerini kolaylaştırabilmektedir. Kamera izleme gibi mevcut yöntemler tek başına yeterli olmadığında, gelişmiş yapay zeka ve derin öğrenme tabanlı sistemler, hemşirelerin iş yükünü hafifleterek daha geniş kapsamlı bir hasta değerlendirmesine olanak tanımaktadır. Araştırma sonucunda sağlık çalışanlarının ekran takibi yapmadığı durumlarda yapay zeka destekli akıllı uyarı sistemi sayesinde araştırma kapsamında yer alan davranışların tespitinin sağlanması ve kliniklerde güvenli ortamın desteklenmesi amaçlanmaktadır. Araştırma alanda yapılacak yeni çalışmalar için bir kaynak ve destek niteliği taşımaktadır.

1.2. Araştırmacının Amacı

Bu çalışmanın amacı psikiyatri kliniklerinde yatarak tedavi gören hastalarda derin öğrenme yöntemi kullanarak şiddet ve intihar davranışlarının tespitini sağlamaktır.

1.3. Araştırmanın Hipotezleri

H 0-1: Geliştirilen model şiddet eyleminin tespitine yönelik % 80 ve üzeri accuracy(doğruluk) oranına sahiptir.

H 0-2: Geliştirilen model intihar girişimi eyleminin tespitine yönelik % 80 ve üzeri accuracy(doğruluk) oranına sahiptir.

BÖLÜM 2. GENEL BİLGİLER

2.1. Şiddet Davranışı ve Türleri

Şiddet kavramı DSÖ (Dünya Sağlık Örgütü) tarafından, “fiziksel güç veya iktidarın kasıtlı bir biçimde bir başkasına, kendisine veya bir topluluğa uygulanması sonucunda, maruz kalan kişide yaralanma, ölüm ve psikolojik zarara yol açan ya da açma olasılığı bulunan eylem” olarak tanımlanmaktadır (WHO, 2002). Yaşamın birçok alanında karşımıza çıkan şiddet gün geçtikçe artmakta, bireylerin yaşam kalitesini, huzurunu ve sağlığını olumsuz yönde etkilemektedir. Uluslararası bir toplum sağlığı problemi olarak adlandırabileceğimiz şiddet kavramı birçok ölüm ve sakatlığa neden olabilmektedir (İnce, 2024).

Şiddetin birçok türü vardır. Şiddetin uygulanış biçimine göre beş tür mevcuttur:

1. Fiziksel şiddet
2. Cinsel şiddet
3. Duygusal şiddet
4. Ekonomik şiddet
5. Siber şiddet

2.1.1. Fiziksel Şiddet: Fiziksel şiddet, zarar verme veya yaralama amacıyla fiziksel güç içeren bir dizi saldırgan davranışı kapsamaktadır. Vurmak, tokatlamak, tekmelemek, itmek, boğmak, ısırarak ve cinsel saldırı gibi eylemler fiziksel şiddetin kapsamı içerisinde yer almaktadır. Araştırmalar, fiziksel şiddetin sıklıkla psikolojik ve cinsel şiddet gibi diğer şiddet biçimleriyle iç içe geçerek karmaşık bir zarar ağı oluşturduğunu göstermiştir. Fiziksel şiddetin etkileri uzun süreli olabilmekte, depresif belirtiler, travma sonrası stres bozukluğu, anksiyete ve intihar düşünceleri gibi sağlık sorunlarına yol açabilmektedir (Sun et al., 2017; Pico-Alfonso et al., 2006).

2.1.2. Cinsel Şiddet: Cinsel şiddet genellikle erkek fail kadın mağdur şeklinde alışılagelmiş olsa da her iki cinsiyette cinsel şiddet mağduru olabilmektedir. Tecavüz girişimi veya tamamlanmış tecavüz, cinsel baskı, istenmeyen temas, taciz gibi durumların hepsi cinsel şiddet kapsamında yer almaktadır. Cinsel şiddete maruz kalmış bireylerde saldırının ardından şok, korku, ajitasyon, kafa karışıklığı ve sosyal geri çekilme yaşanabilmektedir. Uzun vadede depresyon, TSSB, yaygın anksiyete, alkol/madde bağımlılığı, uyku sorunları gibi ciddi ruhsal problemler yaşanabilmektedir (Jordan et al., 2010).

2.1.3. Duygusal Şiddet: Duygusal şiddet yaşam boyunca en sık karşılaşılan ve farkedilmesi en zor şiddet türüdür. Fiziksel ve cinsel şiddet gibi bedensel kanıtlarla gözlemlenemez. Ancak fiziksel ve cinsel şiddete maruz kalan bir kişi duygusal şiddete de uğramaktadır. Duygusal şiddet uygulayan kişinin amacı bireyi duygusal olarak manipüle etmek özsaygısını düşürmek, yıldırarak ve yapılan davranışları uygun olarak göstermektir (Polat, 2016; Aytaç vd., 2016).

2.1.4. Ekonomik Şiddet: Ekonomik şiddet, mağdurun "kaynakları edinme, kullanma ve sürdürme yeteneğini kontrol eden, böylece ekonomik güvenliğini ve kendi kendine yeterlilik potansiyelini tehdit eden" davranışları içerir. Ekonomik şiddet sonucunda kişi finansal açıdan bağımlı hale gelmekte veya maddi açıdan zor durumda kalmaktadır. Bireyin kazandığı maddi kaynaklara el konulmasını kapsadığı gibi çalıştırılmaması ve maddi kazanç elde etmesinin önlenmesi olarak da karşımıza çıkabilmektedir (Adams et al., 2008; Stylianou, 2018).

2.1.5. Siber Şiddet: Dijital araçların yaygınlaşmasıyla gün geçtikçe daha sık karşılaştığımız siber şiddet internet aracılığıyla gerçekleştirilen bir saldırganlık ve istismar türüdür. Kişi veya grupların, belirli kişi veya gruplara zarar vermek amacıyla, internet yoluyla saldırıya uğrayan bireylerin sosyal değerini düşürecek, kişilik, mülkiyet ve bilgi edinme hakkını ihlal edecek şekilde davranışlarda bulunmasını ifade etmektedir. Siber şiddetin failleri genellikle anonimlerdir ve bu nedenle saldırılarını çekinmeden yapabilmektedirler. Kurbanlara gece gündüz, kendi evlerinde veya başka herhangi bir yerde zarar verilebilir ve onlar internetten ayrıldıklarında bile bu zararı devam ettirebilirler. Siber şiddet mağdurları sıklıkla depresyon, anksiyete ve kendine zarar verme belirtilerinden intihara kadar uzanan ruhsal problemler yaşayabilmektedirler (Sharma et al., 2021; Kresic Coric et al., 2020).

2.2. Psikiyatri Kliniklerinde Şiddet Davranışı

Yataklı psikiyatri kliniklerinde şiddet sorunu neredeyse psikiyatri alanı kadar eskidir. Psikiyatrik bozukluklar ile şiddet içeren davranışlar arasındaki ilişkiler her zaman bir tartışma konusu olmuştur. Epidemiyoloji Yakalama Alanı (ECA) çalışması, psikiyatrik bozuklukları (şizofreni, mani, majör depresyon ve bipolar bozukluk) olan hastaların dahil olduğu şiddet olaylarının görülme sıklığının, genel popülasyona göre beş kat daha yüksek olduğunu belirlemiştir. Günümüzde psikiyatri klinik ortamlardaki şiddetin kesin oranlarını belirlemek zordur (Cornaggia et al., 2011).

Psikiyatri kliniğinde yatan bireyler hastane personeline, diğer hastalara, aile üyelerine veya klinikteki nesnelere zarar vererek şiddet davranışı sergileyebilmektedirler. Şiddet önlenmesi ve kontrol edilmesi zor bir durum olmakla birlikte kliniklerde yaşanan bu gibi olaylar şiddet mağduru hastaların tedavisinin etkinliğini engellemektedir. Psikiyatri kliniğinde çalışan hemşireler de şiddet konusunda risk grubunda yer almaktadır ve kariyerleri süresince hastaların en az bir kere fiziksel saldırısına uğramaktadır. Bu da hem çalışma ortamında güvensizlik yaratmakta hem de mesleki ve kişisel yaşantılarını olumsuz yönde etkileyebilmektedir. Binil ve arkadaşlarının (2017) yaptığı çalışmada psikiyatri kliniklerinde hastalar arasında şiddet yaygınlığının % 16 olduğu, erkek cinsiyete sahip olmak ve alkol/madde kullanım öyküsünün varlığının da bu sıklığı etkilediği bulunmuştur. Ayrıca kalabalık klinikler, hemşire başına düşen hasta sayısının fazlalığı, personelin bilgi eksikliği de şiddet davranışlarının sıklığını etkilemektedir (Anderson & West., 2011; Binil et al., 2017).

Akut psikiyatri servislerinde fiziksel şiddet hastalar ve personel için yaralanmaya yol açabilmekte, terapötik ortamı bozarak tedaviyi kötü etkileyebilmektedir. Fiziksel şiddete maruz kalmanın diğer yatan hastalar üzerindeki duygusal etkileri öfke, şok, korku, depresyon, kaygı ve uyku problemlerini içermektedir (Iozzino et al., 2015). Dack ve arkadaşları (2013) akut psikiyatri servisleri de dahil olmak üzere çok çeşitli yatan hasta ortamlarında saldırganlık veya şiddet ile ilişkili faktörlere ilişkin çalışmaların bir meta-analizini gerçekleştirmiş ve saldırganlığın genç yaş, erkek cinsiyet, istemsiz başvuru, evli olmama, şizofreni tanısı, daha önce başvuru sayısının fazla olması, şiddet öyküsü, kendine zarar verme öyküsü, madde kullanım öyküsü ve uyku bozuklukları ile ilişkili olduğunu belirtmişlerdir.

Psikiyatri hastalarının yattığı kliniklerde öfke, düşmanlık, saldırganlık ve şiddet hepsi birbiriyle bağlantılıdır ve bu durumlarla sıkça karşılaşılmaktadır. Psikotik bozukluğun akut dönemi, paranoid şizofreni, alkol ve uyuşturucu bağımlılığı, antisosyal kişilik bozukluğu, yatış sürecinin uzaması, sigara içememe gibi durumların varlığı nedeniyle psikiyatri kliniğinde yatan hastalarda şiddet davranışı artış göstermektedir. Psikiyatri kliniklerine hasta yatışının önemli

nedenlerinden biri de tedaviye yardımcı olacak güvenli bir ortam yaratmaktır ancak şiddet eylemlerinin varlığı bu ortamın oluşmasını engelleyebilmektedir (Sy et al., 2019).

Kliniklerde şiddetin azaltılmasına yönelik geleneksel yöntemler, hastalara yönelik fiziksel kısıtlama, sedasyon ve tecridi içermektedir. Bu tür önlemlerin modern versiyonları arasında el bileği, ayak bileği ve bel kısıtlamaları, haloperidol gibi ilaçlarla sedasyon ve tecrit odaları olarak adlandırılan odalarda izolasyon yer almaktadır. Bununla birlikte, kısıtlama, tecrit ve benzeri önlemlerin hem hastalar hem de personel için psikolojik olarak travmatik olabileceği ve hatta fiziksel olarak tehlikeli olabileceği belirlenmiştir (Bach, 2018).

Psikiyatri kliniklerinde yatan hastalarda en fazla sözel şiddet uyguladıkları bilinmektedir. Bireyin kendine, diğer bireylere veya nesnelere yönelik zarar verici davranışların tümü şiddet kapsamında değerlendirilebilir. Şiddetin yönetiminde hastanın içgörü kazanması, tedaviye uyumunun iyi olması, klinik belirtilerde düzelmelerin olması, saldırganlığa neden olan faktörlerin bilinmesi, uygun müdahalelerin yapılması önemlidir (Umut vd., 2012).

2.3. Psikiyatri Kliniklerinde İntihar Davranışı

İntihar, kişinin kendi hayatını kasıtlı olarak sona erdirmeye yönelik davranışlarda bulunması olarak tanımlanmaktadır ve 15-29 yaş arası gençlerde üçüncü ölüm nedeni olarak bilinmektedir. Yapılan çalışmalar intihara teşebbüs olaylarının tamamlanmış intihara göre 20 kat daha fazla olduğunu göstermektedir. Özellikle dürtüsellik ve sınırda kişilik belirtilerinin varlığı intihar için önemli risk etmenidir. Bu nedenle intiharın önlenmesi ve buna yönelik çalışmaların yapılması oldukça önemlidir (Bhatt et al., 2018; WHO, 2024). Psikiyatrik ve tıbbi komorbidite, hastaneye yatış, tekrarlanan intihar girişimleri, yoksulluk, kronik stres, damgalanma gibi olumsuz ve uzun vadeli sonuçlar intiharla ilişkili olabilmektedir. Geçmişteki intihar öyküsü, mevcut ruh hali, kaygı, madde kullanımı ve travma sonrası stres bozuklukları, gelecekteki intihar eylemine yönelik riski artırmaktadır. İntihar dünya çapında sağlık bakımı için ciddi bir sorun teşkil etmektedir. Her yıl Dünya’da 720.000’den fazla kişi intihar nedeniyle yaşamını yitirmektedir. İntihar her yaş grubunda ve her ülkede görülmektedir ancak düşük ve orta gelirli ülkelerde Dünya çapındaki intiharların %73’ü gerçekleşmektedir. DSÖ tarafından yayımlanan 2013-2030 Ruh Sağlığı Eylem Planında intihar oranlarının azaltılması acil kabul edilmiş ve önceliklendirilmiştir. DSÖ’nün intihara yönelik hedefleri arasında, intiharın önde gelen ölüm nedenleri arasında yer almasını önlemek ve intihar girişimi olan veya intiharı düşünen bireylerin gerekli yardımı rahatça almasını sağlamaktır. DSÖ bu amaçla LİVE LİFE adında ulusal intiharı önleme stratejisi olsun ya da olmasın tüm ülkeler için bir kılavuz yayımlamıştır. Bu kapsamda Türkiye’de de faaliyetler başlamıştır. İntiharı önleme il komiteleri kurulmuş ve tüm iller kendi intiharı önleme programını geliştirmiştir (WHO, 2024; WHO, 2021; Goldman-Mellor et al., 2014). Psikiyatrik hastalığa sahip bireylerde intihar genel popülasyona oranla sık görülse de psikiyatrik hastalığı olanların küçük bir kısmı intihar girişiminde bulunmaktadır. İntihar riski ve intihar yönünden en riskli ruhsal hastalıklar duygudurum bozuklukları ve psikotik bozukluklardır. Psikososyal stres etkenleri, çocuklukta istismar öyküsü ve akut stres psikiyatri hastalarında intihar riskini artırmaktadır (Chung et al., 2017; Olfson et al., 2016). Roaldset (2016), psikiyatri kliniklerinde intiharın önleme stratejilerini geliştirmek için personelin acil intihar riskini tespit etmek amacıyla klinik değişkenlere odaklanması gerektiğini, özellikle de hastanın intihar düşüncelerini, değersizlik duygusunu ve diğer klinik belirtileri dinlemeye odaklanması gerektiğini önermektedir. Oquendo ve arkadaşlarının (2024) yaptığı çalışmada kanıtlar, intihar davranışının, eşlik eden psikiyatrik bozuklukları olmayan bireylerde de ortaya

çıkabileceğini öne sürerek, intihar düşünce ve davranışlarını doğrudan ele alan hedefe yönelik müdahalelerin gerekliliğini vurgulamaktadır. Neuner ve arkadaşlarının (2008) tarafından yapılan çalışmada bir psikiyatri hastanesinde yatan hasta intiharlarının yaygınlığı ve risk faktörleri 10 yıllık süre boyunca araştırılmıştır ve bu süre içerisinde meydana gelen 41 intihar analiz edilmiştir. Önemli risk faktörleri arasında psikofarmakolojik tedaviye direnç, daha önce intihar girişiminde bulunulması, şiddetli yan etkiler olduğu belirlenmiştir.

İntihar girişiminin genç yetişkinlerde ve kadınlarda görülme oranı daha yüksektir. Ası yoluyla intihar ve intihar girişimi yaygın olarak kullanılan bir yöntemdir. Asılma, boyun çevresinde bir bağ kullanarak kendini öldürme eylemidir. Ası tam olabileceği gibi (her iki ayak yerden kesilmiş bir şekilde serbestçe asılarak) kısmi de olabilmektedir (diz çökerek, oturarak, uzanarak veya bir veya iki ayak yerde veya başka bir yüzeyde kalarak). Ası eyleminin yüksek oranda ölümle sonuçlanması ve bazı ülkelerde giderek daha yaygınlaşması nedeniyle Dünya çapında öncelikli hale gelmiştir. Ası yoluyla intihar girişimi sonrası sağ kalan bireylerde miyokardiyal hasar, felç ve hipoksik beyin hasarı gibi durumlar tespit edilmiştir. Özellikle yaşlı bireylerde kadın ve erkek fark etmeksizin en sık karşılaşılan intihar türüdür. Bunu kadınlarda intoksikasyon ve yüksekten atlama, erkeklerde ise ateşli silah kullanımıyla intihar takip etmektedir (Naghavi, 2019).

Ası, zehirlenmeye kıyasla bireyin kendi bedenine yönelik şiddet içeren bir intihar yöntemi olup genellikle ölümle sonuçlanmaktadır. Ası yoluyla intihar girişimi için tahmini ölüm oranının %85 olduğu tahmin edilmektedir. Hayatta kalan %15'inde ise ciddi komplikasyonlar gelişebilmekte, hastanede acil değerlendirme ve tedaviye ihtiyacı olabilmektedir (Cai et al., 2022). Bir bireyin güçlü bir intihar niyeti varsa ve ateşli silahlara erişim hükümet mevzuatı tarafından kısıtlanmışsa ası yoluyla intihara yönelebilmektedir. Çoğu asılma vakası ölümcül olduğu ve özel mülkte gerçekleştiği için ası vakalarının önlenmesi sınırlıdır. Ası yoluyla intiharda ölüm boyun damar sisteminin tıkanması, trakeanın sıkışması, karotis sinüsünün baroreseptörlerine baskı yoluyla kalbin vagal inhibisyonu ve boyun omurlarının kırılmasına bağlı gelişebilmektedir (Sauvageau et al., 2010; Gunnell et al., 2005).

İntihar önlemeye yönelik eylemler düşünüldüğünde genellikle ölümcül araçların veya belirli bir yöntemle erişimin kaldırılması ve kısıtlanması önemli bir intihar önleme stratejisidir (WHO, 2014). Bunlar arasında ev gazı, böcek ilaçları, reçetesiz satılan ilaçlar ve ateşli silahlar gibi potansiyel intihar yöntemlerine erişimin kısıtlanması yer almaktadır. Araçlara erişim kısıtlandığında, yalnızca bu araçlarla ilişkili intiharların azaltmakla kalmadığı, aynı zamanda bazı ülkelerde genel intihar oranlarını da azaldığı bulunmuştur. İntihar davranışında bulunan çoğu kişi, yaşamak veya ölmek konusunda kararsızlık yaşamakta ve birçok intihar, akut stres faktörlerine bir yanıt olarak yani dürtüsel gerçekleşmektedir (genellikle 30 dakikadan kısa süren düşünceden sonra). Ölümcül intihar araçlarının zor ulaşılabilir hale getirilmesi, sıkıntı içindeki kişilere, ölümcül eylemde bulunulmadan önce akut krizlerin geçmesi için zaman sağlayabilmektedir (Lee, 2021; WHO, 2021)

Ası yoluyla intiharlarda bağlama noktalarının ve araçlarının tamamı yok edilemeyeceği için asılarak intiharı azaltmak için önleme alanında daha az fırsat mevcuttur. Erken müdahale, büyük ölçüde ası eyleminin en etkili önleme çabasıdır ve bireyin intihar yöntemi olarak asıyı seçme kararını neye göre verdiğini anlama çabasını kapsamaktadır (Sabrinskas et al., 2022).

Ruhsal bozukluğu olan bireylerde intihar genellikle hastane dışında meydana gelirken kliniklerde tedavi gören hastalarda da hayatını kaybeden bireyler olabilmektedir. Flynn ve

arkadaşları (2017) gözlem altında yatan hastaların intiharlarını rapor etmişler ve sürekli gözlem altında bile hastalara yönelik intihar önleme tedbirlerinin tamamen koruyucu olmadığını sonucuna varmışlardır.

2.4. Makine Öğrenmesi Yöntemi

Son on yılda, yapay zeka (YZ) hem bilimsel topluluk içinde hem de dışında popüler bir konu haline gelmiş, bu alanda teknoloji ve teknoloji dışı dergilerde çok sayıda makale yayınlanmıştır. Makine öğrenmesi yönteminin oluşmasına giden süreç yapay zekanın keşfi ile başlamıştır. Bir grup bilgisayar bilimcisi tarafından 1956 yılında, bilgisayarların düşünmek ve akıl yürütmek üzere programlanabileceğini, "öğrenmenin her yönünün veya zekanın herhangi bir başka özelliğinin, prensipte, bir makinenin bunu simüle edebileceği kadar kesin bir şekilde tanımlanabileceğini" öne sürmüşlerdir. Bu prensibi "yapay zeka" olarak tanımlamışlardır. Yapay zeka herhangi bir "öğrenme" biçimini içermeyen yaklaşımlardan oluşur. Yapay zekanın bir alt dalı olan sembolik YZ, açıkça tanımlanmış mantıksal problemleri çözmede yetenekli olsada, konuşma tanıma veya görüntü sınıflandırması gibi daha yüksek seviyeli desen tanıma gerektiren görevlerde sıklıkla başarısız olmaktadır. Bu karmaşık alanlarda makine öğrenmesi (ML) ve derin öğrenme (DL) daha etkili sonuçlar ortaya koymaktadır (Brown et al., 2018; Moor, 2006).

Makine öğrenmesi, bir veri kümesini en iyi şekilde temsil eden algoritmalar geliştirerek YZ'nın öğrenme yönüne odaklanan bir alandır. ML, ilk prensiplerden türetilenlerden farklı veya yeni özellik ve ağırlık kombinasyonları kullanabilen bir algoritma oluşturmak için veri alt kümelerini kullanmaktadır (Choi et al., 2020).

Makine öğrenmesinde farklı işlevleri gerçekleştirmek için kullanılan dört yaygın yöntem vardır. Bunlar;

Supervised Learning

Unsupervised Learning

Semisupervised Learning

Reinforcement Learning

2.4.1. Supervised Learning (Gözetimli Öğrenme): Gözetimli öğrenme, bilinen bir çıktıyı veya hedefi tahmin etme amacı taşımaktadır. Bu öğrenme yöntemi yeni bir veri örneğini en iyi şekilde tanımlamak için alt gruplar arasında seçim yapmayı içeren sınıflandırmaya ve bilinmeyen bir parametreyi tahmin etmeye odaklanır. Bunlar arasında el yazısı tanıma (el yazısı rakamları tanıma gibi), nesnelerin görüntülerini sınıflandırma (örneğin bu bir kedi mi yoksa bir köpek mi?) ve belge sınıflandırması (örneğin bu kalp yetmezliğiyle ilgili bir klinik deney mi yoksa bir finansal rapor mu?) bulunmaktadır. Özellikle, bunların hepsi eğitilmiş bir kişinin iyi yapabileceği görevlerdir ve bu nedenle bilgisayar genellikle insan performansını yaklaşık olarak tahmin etmeye çalışır (NVIDIA, 2018).

2.4.2. Unsupervised Learning (Gözetimsiz Öğrenme): Gözetimsiz öğrenme, etiketli çıktılar kullanılmadan verilerdeki kalıpları ve yapıları belirlemeye odaklanan bir makine öğrenimi dalıdır. Modellerin bilinen etiketlere sahip veri kümeleri üzerinde eğitildiği gözetimli öğrenmenin aksine, gözetimsiz öğrenme algoritmaları verilerin kendisindeki doğal yapıları, ilişkileri veya kümeleri keşfetmek için giriş verilerini analiz eder. Bu yaklaşım, etiketli verilerin

yetersiz veya mevcut olmadığı senaryolarda özellikle değerlidir ve ham verilerden içgörüler çıkarılmasına olanak tanır. Gözetimsiz öğrenmede kullanılan birincil tekniklerden biri, veri noktalarını benzerliklerine göre gruplamayı içeren kümelemedir. Gözetimsiz makine öğrenimi yaklaşımlarının, önceden tanımlanmış etiketler olmadan veri kümelerinin soyut temsillerini yorumlayabileceğini, öğrenebileceğini ve anlamlı kalıplara kümelenmesini sağlayabileceği bilinmektedir. Bu yöntem, karmaşık veri kümelerinin altında yatan yapının anlaşılmasının oldukça önemli olduğu ilaç keşfi ve biyoenformatik gibi alanlarda kullanılabilir (Scheeder et al., 2018).

2.4.3. Semisupervised Learning (Yarı Gözetimli Öğrenme): Yarı-gözetimli öğrenme (SSL), gözetimli ve gözetimsiz öğrenme paradigmaları arasındaki boşluğu kapatan makine öğreniminde temel bir yaklaşımdır. Öğrenme sürecini geliştirmek için hem etiketli hem de etiketsiz verileri kullanmaktadır. Bu yöntem özellikle etiketli veri edinmenin pahalı veya zaman alıcı olduğu senaryolarda daha değerli hale gelmektedir. SSL'nin temel öncülü, öğrenmeyi daha büyük bir etiketsiz veri havuzundan yönlendirmek için sınırlı etiketli örnekleri kullanmak ve böylece kapsamlı etiketleme çabalarına gerek kalmadan model performansını iyileştirmektir (Kingma et al., 2014; Sun & Xie, 2016).

2.4.4. Reinforcement Learning (Takviyeli Öğrenme): Takviyeli öğrenme (RL), makine öğrenimi içerisinde, ajanların kümülatif ödülleri en üst düzeye çıkarmak için bir ortamda nasıl eylemde bulunmaları gerektiğine odaklanan önemli bir alandır. Bu paradigma temelde, bir ajanın çevresiyle etkileşime girerek, ödüller veya cezalar şeklinde geri bildirim alarak karar vermeyi öğrendiği deneme-yanılma öğrenmesi kavramına dayanmaktadır (Sweetser & Aitchison, 2020). Öğrenme süreci genellikle, her durum-eylem çifti için beklenen getiriyi tahmin eden ve böylece etkenin kararlarını yönlendiren bir değer fonksiyonunun tahmin edilmesini içermektedir (Charlier et al., 2020). RL'deki son gelişmeler, derin öğrenme tekniklerinin entegrasyonundan önemli ölçüde etkilenmiş ve derin takviyeli öğrenmenin (DRL) ortaya çıkmasına yol açmıştır. DRL, derin sinir ağlarının temsili gücünü takviyeli öğrenmenin karar alma yetenekleriyle birleştirerek etkenlerin yüksek boyutlu girdi alanlarını etkili bir şekilde ele almasını sağlamaktadır (Mnih et al., 2015).

2.5. Derin Öğrenme

Makine öğrenimi teknolojisi modern toplumu güçlendiren birçok teknolojik ürünün içinde mevcuttur. Resimlerdeki nesneleri tanımlamak, konuşmayı metne dönüştürmek, haber öğelerini, gönderileri veya ürünleri kullanıcıların ilgi alanlarıyla eşleştirmek ve aramanın ilgili sonuçlarını seçmek gibi uygulamalar makine öğreniminden faydalanmaktadır. Ancak geleneksel makine öğrenimi teknikleri, doğal verileri ham halleriyle işleme yetenekleri bakımından sınırlıdır. Bu nedenle ham verilerden daha nitelikli özellik çıkarılmasını geliştirmek amacıyla onlarca yıl süren mühendislik çalışmaları sonucunda derin öğrenme geliştirilmiştir. Derin öğrenmenin gelişmesiyle oluşan sistem sayesinde girdilerdeki desenler algılanabilir ve sınıflandırılabilir hale gelmiştir. Derin öğrenme bir temsil öğrenimi yöntemi olup, her bir temsili daha soyut ve daha yüksek seviyedeki bir temsile dönüştürme yeteneğine sahiptir. Bu tür dönüşümlerin yeterince birleştirilmesiyle çok karmaşık işlevleri öğrenilebilmektedir. Bu gelişmeler sayesinde YZ'nın uzun zamandır çözümleyemediği problemlerde önemli yol katetmiştir. En başarılı olduğu alanlar arasında görüntü tanıma ve konuşma tanıma yer almaktadır (LeCun et al., 2015; Krizhevsky et al., 2012). Derin öğrenme (DL), makine öğrenimi alanında ilk olarak 2006 yılında ortaya çıkan yeni bir çalışma alanıdır.

Anlamlı özellik çıkarma ve temsil, makine öğreniminin amaçlanan görevlerini yerine getirme kapasitesinin temelleridir. Teknik adı "derin sinir ağı öğrenimi" olarak da bilinen "derin öğrenme", hızla gelişen ve oldukça etkili sonuçlar veren son teknoloji bir çalışma alanıdır. Derin öğrenme yapay sinir ağlarının birden fazla gizli katmanını içermektedir. Çalışma metodolojisi, büyük veri tabanlarında yüksek düzeyde doğrusal olmayan dönüşümler ve model soyutlamaları üzerine kurulmuştur. Derin öğrenme, derin sinir ağları (DNN) olarak bilinen çok katmanlı yapay sinir ağlarını kullanarak verilerdeki karmaşık örüntüleri modellemek için gelişmiş bir makine öğrenmesi yöntemidir. Bu yaklaşım, ham verilerden özellik gösterimlerini otomatik olarak öğrenme yeteneği ile ayırt edebilmektedir. Bu yönüyle görüntü tanıma, doğal dil işleme, sağlık hizmetleri ve robotikteki çeşitli uygulamalar gibi görevlerde önemli iyileştirmeler sağlamaktadır (Hu et al., 2021; Boldrini et al., 2019). Derin öğrenme modellerinin mimarisi, büyük veri kümeleri içindeki karmaşık ilişkileri yakalamalarını sağlayarak gerçekleşmektedir. Bu yönüyle geleneksel makine öğrenme yönteminde verilerin karmaşıklığı ve hacmi nedeniyle zorlanabileceği alanlarda onları özellikle etkili hale getirmektedir (Hu et al., 2021). Derin öğrenmenin evrimi, özellikle kapsamlı veri kümeleri üzerinde büyük modellerin eğitilmesini kolaylaştıran grafik işleme birimlerinin (GPU) kullanımı yoluyla gelişim göstermiştir (Langer et al., 2020). Ayrıca, donanım maliyetlerindeki azalma, derin öğrenmeyi daha erişilebilir hale getirerek araştırmacıların ve uygulayıcıların çeşitli mimariler ve eğitim metodolojileriyle denemeler yapmasına olanak tanımıştır (Hu et al., 2021). Sonuç olarak, derin öğrenme, tıbbi görüntülerin otomatik olarak segmentasyonu ve hasta sonuçlarının tahmini modellemesi gibi görevlerde kullanıldığı tıp da dahil olmak üzere çok sayıda alanda dönüştürücü bir güç haline gelmiştir. Derin öğrenmenin daha az mühendislik çabası gerektiren mevcut hesaplama yöntemi ve veri artışlarından kolayca faydalanabilmesi sayesinde yakın gelecekte çok daha fazla başarıya ulaşacağı düşünülmektedir (LeCun et al., 2015).

2.6. Derin Öğrenme ve Psikiyatri Alanında Kullanımı

Ruhsal bozukluklar, her yaştan milyonlarca insanı etkilemeye devam etmektedir. Bu nedenle derin öğrenme teknolojisi de bu hastalıkların teşhis ve tedavisi üzerine yoğunlaşmıştır. DL esas olarak psikiyatride hasta ve normal gruplar arasında ayırım yapmak, yüksek riskli bir grupta bozukluk geliştirme riskini tahmin etmek ve tedaviye yanıtı tahmin etmek için bir model olarak kullanılmaktadır. Psikiyatrik hastalıklarda erken teşhis ve müdahale sağlamak, hastalığın bireylerin yaşam kalitesi üzerindeki olumsuz etkisini azaltmak ve daha ciddi uzun vadeli etkileri önlemek için önemlidir. Derin öğrenme, büyük veri setlerini analiz etme yeteneği sayesinde, psikiyatrik bozuklukların tanınması ve tedavisinde iyi işlev görebilmektedir. Psikiyatri alanı nesnel tanı konulmasını destekleyen herhangi bir biyobelirteç sahip değildir. Biyobelirteç geliştirmek amacıyla son yıllarda nörogörüntüleme verilerini kullanarak psikiyatrik bozuklukların sınıflandırılması üzerine yapılan çalışmalar, bu alandaki en umut verici gelişmelerden biridir (Quaak et al., 2021; Vieira & Pinaya, 2017). Mehlretter ve arkadaşlarının (2019) yaptığı çalışmada depresyon tanısına sahip bireylerde kişiye uygun antidepresan seçiminin yapılmasında derin öğrenme tekniklerinden faydalanılmaya çalışılmıştır. Çalışma sonucunda derin öğrenmenin çeşitli tedavi seçenekleri arasından seçim yaparken antidepresan yanıtının bireye özgü seçiminde etkili olduğu kanıtlanmıştır.

Lew ve arkadaşlarının (2023) yaptığı çalışmada alzheimer hastalığında amiloid-tau-nörodejenerasyon sınıflandırması için PET yerine zararsız bir yöntem olan MRI yöntemini daha kullanılabilir hale getirmeyi hedeflemişlerdir. Derin öğrenme algoritması, MRI ve diğer mevcut

tanı verilerini kullanarak (hastanın demografik bilgileri, bilişsel puanları, APOE gen durumu, hipokampal hacim) değerlendirildiğinde, alzheimer teşhisinde PET'e yakın sonuçlar vermiştir.

Derin öğrenme tabanlı bir dil modeli olan GPT'nin de psikiyatri de kullanımı önemlidir. Özellikle doğru bir psikoterapi süreci yürütebilmek gelecekteki hedefler arasında yer almaktadır. Ancak mevcut durumda empati, duygu tanıma, kişilik değerlendirmesi ve ruh sağlığı uyarı işaretlerinin tespitini içeren gelişmelere ihtiyaç duymaktadır (Cheng et al., 2023).

Derin öğrenme algoritmaları büyük miktarda veriyi hızla işleyebilmekte ve bunu yaparken de yorgunluk, dikkatsizlik gibi insani durumlar yaşamamaktadır. Karar verme mekanizmaları veriye dayalı olduğu için tamamen objektif olabilmektedir. Bu yönüyle bağımsız bir şekilde karar verme unsuru olmasından ziyade, iş yükünü azaltan, tanı/tedaviye karar vermede hızlı ve doğru karar verme sürecini destekleyen bir uygulama olması hedeflenmektedir (Akalın & Veranyurt, 2021).




BÖLÜM 3. GEREÇ VE YÖNTEM

Çalışmada derin öğrenme yöntemi kullanarak psikiyatri kliniklerinde gerçek zamanlı şiddet ve ası yoluyla intihar tespiti için sağlanması hedeflenmektedir. Çalışmada şiddet, şiddetsizlik ve intihar girişimi olmak üzere üç sınıf yer almaktadır. Çalışmanın sonunda şiddet ve intihar girişimi sınıfı için uyarı veren bir model oluşturulması hedeflenmektedir. Uyarılar için gerçek zamanlı mesajlaşma uygulaması olan Telegramdan faydalanılmıştır. Ayrıca oluşan her uyarı bilgisayar ekranına yansımaktadır. Şiddet ve şiddetsizlik sınıfına ait eğitim veri seti için Soliman ve arkadaşları (2019) tarafından geliştirilen Real Life Violence Situations Dataset kullanılmıştır. Bu veri seti şiddet tespiti modellerinin geliştirilmesi ve değerlendirilmesi amacıyla oluşturulmuş kapsamlı bir video koleksiyonudur. İçeriğinde 1.000 gerçek sokak kavgası ve 1.000 şiddet içermeyen durumu içeren toplam 2.000 video klipten oluşmaktadır. Videolar, YouTube gibi platformlardan toplanarak, makine öğrenimi modellerinin dayanıklılığını artırmak için çeşitli ortam ve koşulları kapsayacak şekilde seçilmiştir. İntihar eylemine yönelik açık kaynak bir veri seti bulunmadığı için ası yoluyla intihara yönelik bir eğitim veri seti oluşturulmuştur. Kaydedilen görüntülerden özellik çıkarmak amacıyla OpenPose uygulaması kullanılmıştır. Özellikleri çıkarılan görüntülerin azimutal yer değiştirme kullanılarak açı ve pozisyon değişiklikleri hesaplanmıştır. Sonrasında t karesindeki anahtar noktalar t+1 karesiyle karşılaştırılarak bir gradyan vektörü elde edilmiştir. Gradyan vektörünün büyüklüğü ve açısı, yer değiştirme hızını ve hareketin yönünü sırasıyla göstermektedir. Modelin mimarisi için bir derin öğrenme yöntemi olan uzun kısa süreli bellekten (LSTM) faydalanılmıştır. Geliştirilen modeli test etmek için özgün bir test veri seti oluşturulmuştur. Geliştirilen model bu veri seti üzerinden çalıştırılmış ve accuracy, F1 score gibi metriklerle değerlendirilmiştir. Modelin gerçek zamanlı değerlendirmesi için gece ve gündüz sürelerince şiddet, şiddetsizlik ve intihar girişimi sınıfına ait davranışlar rastgele bir şekilde (her davranış için 30 sn-1 dk süresince) ve kesintisiz olarak uzun süreli video halinde kaydedilmiştir. Geliştirilen modelin anlık uyarıları için sistem Telegrama entegre edilmiştir. Ayrıca gelişen her şiddet ve intihar girişimi eylemi için bilgisayar ekranında uyarı oluşturulmuştur. Daha sonra görüntüler üzerinde sağlık çalışanlarının yaptığı değerlendirmelerle modelin log ve telegram çıktıları karşılaştırılarak uyarıların doğruluğu ve niteliği uzman görüşüyle model çıktısını kıyaslama yöntemiyle belirlenmiştir.

3.1. İş Akış Diagramı:

Şekil 1: İş Akış Diagramı



3.2. Veri Seti Oluşturma

Veriler Göztepe Prof. Dr. Süleyman Yalçın Şehir Hastanesi Erişkin Erkek Psikiyatri Kliniğinde sorumlu araştırmacı tarafından video kaydı yöntemiyle toplanmıştır. Çalışmanın etik kurul onayı (EK_1) ve kurum izinleri (EK_2) alınmıştır. Araştırmanın verileri Mayıs-Temmuz 2024 tarihleri arasında toplanmıştır. Araştırmada şiddet, şiddetsizlik ve intihar girişimi olmak üzere üç sınıf yer almaktadır. Bu sınıflarda yer alan davranışlara yönelik test ve eğitim video veri seti oluşturulmuş ve veri setinin oluşturulması aşamasında 9, gerçek zamanlı değerlendirme için videoların oluşturulmasında 4 oyuncu olmak üzere toplam 13 oyuncunun yardımı alınmıştır. Oyuncular genç erişkin (18-30 yaş) arası kadın ve erkeklerden oluşmaktadır. Araştırmaya katılmaya gönüllü olan, tiyatro/drama oyuncusu olan ve istenilen hareketleri yapmasını engelleyecek bir sağlık problemi olmayan herkes araştırmaya dahil edilmiştir. Araştırma süresince Ezviz C3X marka 4 adet kamera kullanılmıştır. Kameranın 4 adet olmasının nedeni dört farklı yönden davranışın görünmesini sağlamak, daha çok video verisi ve sistemi doğru eğitebilecek özellikte videolar elde etmektir. Kameralar odanın her bir köşesine yerleştirilerek dört farklı açıdan görüntü kaydı sağlanmıştır. Bu şekilde davranışların birçok perspektiften görüntü özellikleri çıkarılabilmektedir. Kullanılan kamera akıllı çift lens, renkli gece görüş, gömülü AI derin öğrenme algoritması, insan/araç şekil algılama, sesli uyarı sistemi özelliklerine sahiptir (Ezviz, 2024).

Veri toplama sürecinin ilk aşamasında intihar eylemine yönelik kullanılabilecek kamuya açık bir video veri seti olmadığından intihara yönelik bir veri seti oluşturulmuştur. İntihar eylemine yönelik bu veri seti için kameralar odanın her bir köşesine 35° eğim açısına sahip bir şekilde yerleştirilmiştir. Etkili bir vücut pozisyonu tahmini sağlamak için, oyuncu ile her bir kamera arasındaki mesafenin yaklaşık olarak 2 m ile 5 m arasında tutulmuştur. Veri setini oluşturmak için oyuncular da şu senaryo gerçekleştirmeleri istenmiştir.

Oyuncular, düğüm yapılmış ve sabit bir noktaya yerleştirilmiş olan ipin altında sandalyeye çıkmaları, ipi başlarından geçirmek için tutup açmaları ve başlarından geçirmeleri istenmiştir. Bu eylem için yaklaşık iki erkek bir kadın olmak üzere üç oyuncunun desteği alınmıştır. Bu şekilde yaklaşık 250 tekrar ile dört farklı kamera açısından 1000 adet ası yoluyla intihar videosu elde edilmiştir. Şiddet eylemleri ve şiddetsizlik eylemleri için Soliman ve arkadaşları (2019) tarafından geliştirilen Real Life Violence Situations Dataset adlı veri seti kullanılmıştır. Bu veri seti araştırmamız için gerekli olan 1000 adet şiddet ve 1000 adet şiddetsizlik eylemlerine yönelik YouTube üzerinden toplanan videoları içermektedir.

Çalışmanın ikinci aşaması olan test aşamasında oyuncuların çalışma kapsamında yer alan (şiddet, şiddetsizlik, intihar girişimi) tüm davranışları sergilemeleri istenmiştir. Çekimler esnasında odada üç yatak, iki koltuk, bir sandalye ve çekilecek eylemi gerçekleştirecek sayıda oyuncu mevcuttur. Hastanedeki herhangi bir psikiyatri klinik yapısına benzer bir ortam oluşturulmuş ve her bir eylem sergilenmeden önce oyuncuların istenilen davranışın şekli hakkında bilgi verilmiştir. Oyunculara eylemler sırasında hareketin hızının, beden/eklem konfigürasyonunun önemi anlatılmış ve istenilen performansın ne olduğu açıklanmıştır. Oyuncular eylemleri sergilerken bilgisayar ekranından performansları takip edilmiştir. Çalışma kapsamına geliştirilen modelin çalışma prensibi eklem hareketlerinden davranış tespitine odaklandığı için yüz ifadeleri önem arz etmemektedir. Çekimler gece ve gündüz sürelerinde yapılmış, gündüz saatlerinde yer alan her eylem gece de aynı şekilde sergilenmiş ve video kaydına alınmıştır. Test veri seti tamamlandığında tüm eylemler istenilen şekilde sergilenmiştir.

Oyuncuların sergileyeceği davranışlar hakkında sorumlu araştırmacı gerekli yönlendirmeyi yapmıştır. (Davranışın kaç kere yapılması gerektiği, hangi davranışın yapılması gerektiği, süresi, şekli gibi konularda). Test aşaması için veri toplamada (80/20) yani 80 eğitim, 20 test verisi oranına ulaşılması amaçlanmıştır. Bunun için her davranışın beş dakika boyunca odanın farklı yerlerinde farklı şekillerde sergilenmesi istenmiştir (odanın köşelerinde, ortasında, yataarken, otururken, yürürken vb.). Veri setinin toplanması ve test aşamasında tiyatro oyuncularının davranışlarının uygunluğu ve tekrar sayıları izlenmiştir. Bu sayede eksik ve yetersiz bir çekim yapılmasının önüne geçilmiştir. Tüm aşamalar henüz hasta yatışı olmayan erkek psikiyatri kliniğinde tamamlanmıştır. Video kaydı OBS studio üzerinden dört farklı kamera açısıyla senkronize şekilde gerçekleştirilmiştir.

Test veri setinin oluşturulması için üç erkek, üç kadın olmak üzere altı oyuncudan yardım alınmıştır. Eylemler gece ve gündüz şeklinde kaydedilmiştir. OBS studio ile veri seti oluşturulurken 30 FPS hızında video görüntüleri elde edilmiştir.

Veri setindeki sınıflar arasında şiddetsizlik sınıfına ait örneklerin sayısı, şiddet veya intihar girişimi sınıfına kıyasla daha az örnek içermektedir. Ancak çalışmanın ana hedefi intihar girişimi ve şiddeti tespit etmek olduğu için, şiddet içermeyen örneklerin sayısının daha düşük olması kabul edilebilir olarak değerlendirilmektedir.


3.3. OpenPose Uygulamasıyla Beden Özelliklerinin Çıkarımı

Openpose insan-bilgisayar etkileşimi dahil olmak üzere çeşitli alanlarda sıkça kullanılan, gerçek zamanlı ve iki boyutlu (2D) poz tahmini üretmeye yarayan bir uygulamadır. OpenPose, vücut, ayak, el ve yüz anahtar noktaları dahil olmak üzere insan vücudundaki anahtar noktaları tespit etmek için parça yakınlık alanlarını kullanır ve bu sayede çeşitli ortamlarda ve uygulamalarda etkili bir şekilde çalışmasını sağlar (Cao et al., 2021).


Çalışmada OpenPose algoritması kullanılarak ası yoluyla intihar, şiddet ve şiddetsizlik eylemlerinin özellikleri çıkarılmıştır. Ası yoluyla intihar, intihar girişimi olarak etiketlenmiştir. Şiddet eylemleri (tokat atma, arkadan boğazını sıkma, kafa atma, sert bir cisimle vurma, saç çekme, tekme atma, yumruk atma, itme, duvara yaslama, boğuşma, yüze yastık kapama) şiddet eylemleri olarak etiketlenmiştir. Şiddetsizlik sınıfında yer alan davranışlar (su içme, yemek yeme, saç tarama, kitap okuma, yatma, konuşma, giyinme, soyunma, yürüme, dışarıyı izleme) şiddetsizlik olarak etiketlenmiştir. Tüm bu eylemlerin 2D görüntüsü OpenPose uygulamasıyla çıkarılmıştır. Aşağıda şiddet ve intihar girişimi veri grubuna ait OpenPose uygulamasının birkaç örnek çıktısı sunulmuştur.

Şekil 2: OpenPose Uygulamasının Şiddet ve İntihara Yönelik Eylemlerde Vücut Anahtar Noktalarının Çıktı Örnekleri


Kafa Atma




Bir Cisimle Vurma




Tekme Atma




Duvara Dayamak




Saç Çekme




Tokat Atmak




Yumruk Atma




Yüze Yastık Kapama




İtmek




Arkadan Boğazını Sıkma



Boğuşma



İntihar



3.4. Veri Ön İşlemesi

Bu aşamada azimutal yer değiştirme yöntemi kullanılmıştır. Azimutal yer değiştirme yöntemi hareket eden bir nesnenin veya vücut parçasının 2D düzlemdeki açısal pozisyonundaki değişimleri (azimutal açılar) zaman içinde izleyebilmektedir. Bu yöntem, özellikle hareketin yönünü ve hızını analiz etmek için kullanılmaktadır. Video verilerinden çıkarılan anahtar nokta koordinatları azimutal yer değiştirme hesaplamalarında temel girdilerdir. Bu işlem, bir hareketin başlangıç noktasından belirli zaman aralıklarındaki açı ve pozisyon değişikliklerinin hesaplanmasıyla gerçekleşmektedir. Bir yer değiştirme gradyanı vektörü elde etmek için t karesindeki anahtar noktalar $t+1$ karesiyle karşılaştırılmaktadır. Bu vektör daha sonra azimutal koordinatlara dönüştürülmüştür. Bu dönüşüm, anahtar noktanın konumu yerine yer değiştirmeyi dikkate almaktadır. Bu sayede her bir eylem konum ve ölçek değişimine dönüştürülmektedir. Gradyan vektörünün büyüklüğü ve açısı, yer değiştirme hızını ve hareketin yönünü sırasıyla göstermektedir. Bu da bu çalışmada eylem tanıma, yani şiddet ve intihar tespiti için anahtar noktaların ham koordinatlarından daha anlamlı olduğunu kanıtlamaktadır. OpenPose ile elde edilen anahtar noktalar üzerinden bu tür bir koordinat dönüşümü yapmak, ham koordinatlardan daha anlamlı bir veri sunarak LSTM'nin eylem tanıma ve şiddet tespiti gibi görevlerde daha başarılı olmasını sağlayabilmektedir. Azimutal yer değiştirme yöntemi hareketin detaylı ve hassas analizini sağlamaktadır ve modelin hesaplama yükünü azaltmaktadır. Çünkü her bir anahtar noktanın koordinatlarının direkt kullanımı yerine açısal yer değiştirme verileri işlenmektedir. Geleneksel görüntü tabanlı analizlerin aksine bu yöntemde ışık değişimlerine daha az duyarlı olan anahtar nokta koordinatları kullanılmaktadır. Bu durum özellikle gece çekimleri gibi düşük ışık koşullarında yöntemin performansını artırmaktadır. Azimutal yer değiştirme ile vücut bölümlerinin zaman içindeki açısal ve pozisyonel değişikliklerini doğru bir şekilde ölçmek mümkün olmaktadır. Bu durum karmaşık ve sürekli hareketlerin analizi için oldukça avantajlıdır. Azimutal koordinatlar, konum ve yön bilgilerini daha net bir şekilde sunarak, özellikle uzamsal hareketlerin ve açısal değişimlerin anlamlandırılmasını kolaylaştırmaktadır (Partika., 2022; Kim et al., 2020).

3.5. Data Augmentation (Veri Artırma)

Modelin performansını ve farklı video koşullarına uyarlanabilirliğini iyileştirmek için veri artırma teknikleri uygulanmıştır. Bunlara çözünürlük ayarlamaları ve trapezoidal bozulmaları, kamera açısı ve perspektifindeki değişiklikleri simüle etmek de dahildir. Bu artırma, kamera kurulumlarındaki ve psikiyatri hastanelerinde tipik olarak bulunan çevre koşullarındaki

değişiklikleri hesaba katarak sistemin gerçek dünya senaryolarına daha iyi genelleme yapmasını sağlamaktadır.

Derin öğrenme çerçevesi olarak TensorFlow kullanılmıştır. TensorFlow, açık kaynaklı ve farklı seviyelerde yapay zeka sistemleri geliştirmeye olanak tanıyan bir yazılım kütüphanesidir. Özellikle TensorFlow, derin öğrenme modellerinin geliştirilmesinde ve sağlık gibi kritik alanlarda görüntü işleme, hastalık teşhisi gibi uygulamalarda sıklıkla tercih edilmektedir (Selçuk vd., 2021).

Overfitting ile mücadele etmek için burada veri artırma (data augmentation) yöntemi kullanılmıştır. Bu, modelin eğitim sırasında aşırı öğrenmesini ve eğitim verisine aşırı uyum sağlamasını (overfitting) önlemek için yaygın olarak kullanılan bir tekniktir. Veri artırma, mevcut eğitim verilerini çeşitli dönüşümlerden (örn. döndürme, ölçekleme, ayna yansıması, parlaklık değişiklikleri vb.) geçirerek veri kümesindeki çeşitliliği artırmaktadır. Bu şekilde model, aynı veri üzerinde farklı perspektiflerden eğitilerek daha genel bir öğrenme elde etmektedir ve bu da overfitting riskini azaltmaktadır. Ayrıca, bu tür veri artırma teknikleri sayesinde modelin genel performansı iyileştirilebilmektedir, çünkü model, daha fazla çeşitlilik içeren verilere maruz kalarak daha genel bir hale gelmektedir. Çalışmada karşılaşılan overfitting sorunu veri artırma yöntemiyle çözülmüştür.

3.6. Modelin Mimarisi

Sistemin mimarisi daha önce Partika (2020) tarafından geliştirilen gerçek zamanlı şiddet tespit yöntemine dayanmaktadır. Ancak ek olarak intihar girişimi sınıfını ele alacak şekilde uyarlanmıştır ve gerçek zamanlı değerlendirmesi sağlanmıştır. OpenPose tarafından özellik çıkarımından sonra, veriler birkaç analiz aşaması içeren bir işlem hattından işlenmiştir.

LSTM'ler, intihar girişimi veya şiddet içeren bir davranışı gösterebilecek hareketin kademeli olarak artması gibi zaman içindeki ince davranış kalıplarını OpenPose'dan çıkarılan girdi özelliklerini işleyen bir dizi 1D evrişimsel katmandan önce tespit etmek için uygundur. Bu evrişimsel katmanlar özellik azaltma gerçekleştirmektedir ve çıkarılan poz verilerinin en önemli yönlerini vurgulayarak LSTM'ye daha alakalı ve özlü girdiler sağlamaktadır. LSTM sinir ağı, bilgiyi uzun süreler boyunca depolamak için özel modülasyon mekanizmalarını kullanmaktadır. Bu nedenle, mevcut video karesinin geçmiş kareler bağlamında değerlendirilmesi gereken karmaşık görsel işleme için potansiyel olarak uygundur. Son araştırmalar LSTM'nin video verilerindeki insan eylemlerini (örneğin koşma, el sallama) etkili bir şekilde tanıyabildiğini ve sınıflandırabildiğini göstermiştir (Grushin et al., 2013). LSTM'lerin mimarisi, üç kapıyla birlikte bilgileri uzun süreler boyunca koruyabilen bellek hücrelerini içerir: giriş kapısı, unutma kapısı ve çıkış kapısı. Bu kapılar, bellek hücresine giren ve çıkan bilgi akışını düzenleyerek, ağın hangi bilginin saklanması gerektiğini ve hangisinin atılabileceğini öğrenmesini sağlamaktadır (Deng et al., 2017).


Evrişimsel ön işleme ve LSTM tabanlı zamansal modellemenin bu birleşimi, sistemin kritik eylemleri gerçek zamanlı olarak yüksek hassasiyetle algılanmasını sağlamaktadır. LSTM'den sonra, tamamen bağlı yoğun katmanlar üç olası eylem için bir olasılık puanı üretmektedirler. Bunlar şiddetsizlik, şiddet ve intihar girişimi eylemlerini içermektedir.

Çıkarım için AWS Lambda'yı kullanmak sistemin ölçeklenebilirliğine daha fazla katkıda bulunmaktadır. AWS Lambda, sunucu sağlama ve yönetme ihtiyacı olmadan yazılan kodu çalıştırmaya yarayan sunucusuz bilgi işlem hizmetidir. Yazılan kodu yüksek kullanılabilirliğe

sahip bir altyapıda çalıştırır, sistem bakımı, kapasite ve otomatik ölçeklendirme, monitoring, loglama gibi işlemlerin tümünü kendi gerçekleştirir. AWS, Cloud'da ki hesaplama gereksinimlerini yönetmektedir ve bu da yerinde pahalı donanım ihtiyacını en aza indirmektedir. Cloud altyapısının esnekliği, ek işlem gücü, şirket içi cihazları yükseltmeden sağlanabildiğinden, sistemi daha büyük ortamlara ölçeklenebilir hale getirmektedir (Amazon, 2024).

Çalışmanın mimarisi, OpenPose'dan çıkarılan özellikleri azimutal yer değiştirme ve merkez mesafelerine çevirmek için tek boyutlu evrişim, bath normalizasyonu, maksimum pooling ve dropoutun iki dizisini kullanmaktadır (Cao et al., 2021). Ayrıca çalışmanın mimarisi tek boyutlu evrişimlerin iki katmanını, LSTM'yi ve yoğun katmanları ve ayrıca IJCVIP.304462.f07 uzaysal boyutlarını içeren ağ mimarisini içermektedir.

Şekil 3: Bir boyutlu evrişimlerin iki katmanını, LSTM'yi ve yoğun katmanları ve ayrıca onun uzaysal boyutlarını içeren ağ mimarisi



Tek boyutlu evrişim, evrişim yalnızca zaman boyutu üzerinde gerçekleştiğinden düşük bir hesaplama maliyetiyle çok etkili bir özellik çıkarma yöntemi sağlamaktadır (Kiranyaz et al., 2020).

Evrişimin karmaşıklık derecesinin O fonksiyonu olduğunu ve $K \times K$ çekirdeği olan bir $N \times N$ görüntüsüne sahip olduğunu varsayarsak, bir ve iki boyut arasındaki karmaşıklık karşılaştırması şu şekildedir:

- Tek Boyut IJCVIP.304462.m02
- İki Boyut IJCVIP.304462.m03

Bu iki boyut, normalizasyon ve maksimum pooling dizisi, ikinci katmanın daha yüksek bir soyutlama düzeyinde çalışmasına olanak tanır ve en alakalı bilginin daha kompakt bir temsilinin üretilmesine olanak sağlamaktadır (Krizhevsky et al., 2012).

Daha sonra bu kompakt temsil, LSTM ağını besler ve kaybolan gradyanlar gibi diğer tekrarlayan sinir ağlarındaki yaygın sorunlardan etkilenmeden uzun vadeli zamansal bağımlılıkları yakalama yeteneğini araştırır (Mahasseni & Todorovic, 2016; Yu et al., 2019).

Bu mimarideki son katman, LSTM çıktısını şiddet, şiddetsizlik ve intihar girişimi olmak üzere son üç sınıfa yerleştirerek son sınıflandırmayı gerçekleştiren tam bağlantılı bir katmandır (Caetano, 2020; Peixoto et al., 2019).

Bu çalışmada, şiddet ve intihar girişimi tespiti için genişletilmiş LSTM tabanlı modelin verimli bir şekilde eğitilmesini ve optimum performansını sağlamak için önemli hiperparametreler şunlardır:

- Öğrenme Oranı: Öğrenme oranı, hem yakınsama hızını hem de model doğruluğunu optimize eden deneysel bir aramanın ardından 0,001 olarak belirlenmiştir. Çünkü daha yüksek bir öğrenme oranı (örneğin 0.01) modelin optimizasyon sürecinde kararsızlığa neden olmuş, daha düşük oranlar (örneğin 0.0001) ise yakınsama sürecini yavaşlatmıştır. 0.001 öğrenme oranı, modelin kayıp fonksiyonunu hızlı ve istikrarlı bir şekilde minimize etmesine olanak sağlamıştır. Bu oran, doğruluk ve eğitim süresi arasında bir denge oluşturmuştur.

- Batch Boyut: Hesaplama verimliliği ve bellek sınırlamaları dengelenerek 64'lük bir batch boyutu seçilmiştir. Bunun nedeni 64'lük bir batch boyutu, model eğitimi sırasında belleği etkili bir şekilde kullanmak ve hesaplama yükünü dengelemek için tercih edilmiştir. Daha küçük batch boyutları eğitim süresini uzatmış, daha büyük boyutlar ise bellek sınırlamalarına neden olmuştur. 64'lük boyut, hem eğitim sürecinin hızını artırmış hem de modelin genel doğruluğunu optimize etmiştir.

-LSTM Birimlerinin Sayısı: LSTM katmanı 128 birim içermektedir. Bu sayı, aşırı uyumu en aza indirirken sıralı verilerdeki zamansal bağımlılıkları yeterince yakalamak için seçilmiştir. Zamansal bağımlılıkları yakalamak için yeterli bir kapasite sağlamış, aynı zamanda aşırı öğrenme riskini en aza indirmiştir. Daha az birim (örneğin 64), modelin uzun vadeli bağımlılıkları anlamada yetersiz kalmasına neden olmuş, daha fazla birim (örneğin 256) ise gereksiz karmaşıklık yaratmıştır. 128 birim dengeli bir performans sunmuştur.

-Dropout Oranı: Aşırı uyumu azaltmak ve modelin görülmemiş verilere iyi bir şekilde genelleştirilmesini sağlamak için 0,5'lik bir dropout oranı uygulanmıştır. 0.5'lik bir dropout oranı, aşırı öğrenmeyi önlemek ve modelin genelleme yeteneğini artırmak için uygulanmıştır. Bu oran, modelin doğruluk ve kayıp değerlerini sabit tutmuş, daha düşük oranlar aşırı öğrenmeye yol açarken, daha yüksek oranlar modelin öğrenme kapasitesini düşürmüştür.

- Epoch Sayısı: Model 65 epoch için eğitilmiştir çünkü dönem sayısındaki daha fazla artış performansta önemli bir artış sağlamamış ve aşırı uyum riski doğurmuştur. Model 65 epoch boyunca eğitilmiş, çünkü bu noktadan sonra ek epochlar performansta önemli bir iyileşme sağlamamış ve aşırı öğrenme riskini artırmıştır. Epoch sayısı, erken durdurma yöntemiyle birlikte kullanılmış ve modelin gereksiz yere eğitim görmesinin önüne geçilmiştir.

Çalışmanın eğitim süreci, veri setini 80/20 oranında eğitim/doğrulama setlerine bölmeyi içermektedir. Bu oran, modelin genelleme yeteneğini ölçmek için yeterli veri bırakmıştır.

Model, her parametre için öğrenme oranını uyarlayan ve verimli yakınsamaya yol açan sağlam bir optimize edici olan ‘Adam Optimizer’ kullanılarak eğitilmiştir. Adam optimizasyon algoritması, parametre güncellemeleri için öğrenme oranını adapte ederek kayıp fonksiyonunu etkili bir şekilde minimize etmiştir. Sorunun çok sınıflı doğası nedeniyle kategorik çapraz entropi kaybı işlevi kullanılmıştır. Kategorik çapraz entropi kayıp fonksiyonu, çok sınıflı bir problem olan bu çalışmada, her sınıf için doğru bir sınıflandırma olasılığı hesaplamıştır. Doğrulama kaybı 10 epoch boyunca iyileşmediğinde eğitim sonlandırılmış, bu da aşırı öğrenmenin önüne geçmiştir. Beş katlı çapraz doğrulama yöntemi, modelin farklı veri alt kümelerinde nasıl performans gösterdiğini değerlendirmek için kullanılmıştır. Bu, sonuçların genel olarak sağlam olduğunu göstermiştir.

Doğrulama için, doğrulama kaybını izlemek ve aşırı uyumu önlemek için erken durdurma kullanılmıştır. Doğrulama kaybı 10 ardışık epoch boyunca iyileşmediyse, eğitim sonlandırılmıştır. Ek olarak, modelin sağlamlığını sağlamak için beş katlı bir çapraz doğrulama gerçekleştirilmiş ve performans değerlendirmesi için hassasiyet, geri çağırma ve F1 puanı gibi ölçütler kullanılmıştır.

3.7. Davranışın Sınıflandırılması

Davranış sınıflandırılması şiddet, şiddetsizlik ve intihar girişimi olmak üzere üç kategoriye içermektedir. Şiddet sınıfında tokat atma, arkadan boğazını sıkma, kafa atma, sert bir cisimle vurma, saç çekme, tekme atma, yumruk atma, itme, duvara yaslama, boğuşma, yüze yastık kapama eylemlerini içermektedir. Şiddetsizlik sınıfı su içme, yemek yeme, saç tarama, kitap okuma, yatma, konuşma, giyinme, soyunma, yürüme, dışarıyı izleme gibi davranışları içermektedir. İntihar girişimi sınıfında ise ası yoluyla intihar yer almaktadır.

Model saniyede 15 FPS hızında çalışmaktadır ve özellik çıkarmak için 3 sn’lik video klipler kullanılmaktadır. Model (15 FPS X 3 sn= 45 kare) formülüyle 45 kare üzerinden tek bir sınıf etiketi çıkarıyorsa bu, 45 karelik zaman dilimi boyunca gözlemlenen davranışın bir bütün olarak bir sınıf altında etiketlendiği anlamına gelmektedir.

3.8. Karşılaşılan Zorluklar ve Çözümler

Bu çalışmada, veri toplama, model geliştirme ve gerçek zamanlı test süreçlerinde çeşitli zorluklarla karşılaşmıştır. Aşağıda bu zorluklar ve geliştirilen çözüm yöntemleri açıklanmaktadır.

Veri Seti Toplama Süreci: İntihar girişimi verilerinin açık kaynaklı olarak erişimin olmaması yeni bir eğitim veri seti oluşturulmasını gerektirmiştir. Bu sorunun üstesinden gelebilmek için, gönüllü tiyatro/drama oyuncularının katılımıyla intihar girişimi davranışlarının simüle edilmesi sağlanmış ve gerekli video verileri elde edilmiştir. Bu sayede, çalışmaya özgün ve güvenilir bir veri seti oluşturulmuştur.

Veri Artırma (Data Augmentation): Modelin performansını artırmak ve aşırı öğrenme (overfitting) problemini önlemek amacıyla veri artırma teknikleri uygulanmıştır. Simüle edilen davranışların varyasyonları, modelin eğitim setine dahil edilerek, modelin daha genel bir performans göstermesi sağlanmıştır.

Güven Parametrelerinin Optimize Edilmesi: Model performansını daha da iyileştirmek amacıyla güven parametreleri optimize edilmiştir. Bu ayarlamalar, modelin daha yüksek

doğruluk oranı elde etmesine ve hatalı sınıflandırmaların azaltılmasına yönelik olarak yapılmıştır.

İnternet Altyapısından Kaynaklı Problemler: Hastanenin internet ağına kurumun güvenlik önlemleri nedeniyle erişim sağlanamamıştır. Bu nedenle, veri aktarımı ve bağlantı ihtiyaçlarını karşılamak için taşınabilir internet sağlayıcısı tarafımızca temin edilmiştir. Bu çözüm, bağlantı sürekliliğini sağlarken araştırmanın kesintisiz olarak sürdürülmesine olanak tanımıştır.



4. BULGULAR

4.1. Modelin Performans Değerlendirmesi

Oluşturulan sistem, psikiyatri hastanesinde oyuncularla çekilen test videoları kullanılarak değerlendirilmiştir. Üç davranış (şiddetsizlik/şiddet/intihar giriřimi) kategorisini test edilmiş ve sistem tüm kategorilerde yüksek doğruluk ve güvenilirlik göstermiştir. Modelin performansı, çeşitli kamera perspektiflerine ve çevre koşullarına genellemeyi iyileştiren veri artırma tekniklerinin kullanımıyla geliştirilmiştir.

İntihar giriřimi ve şiddet tespiti için hassasiyet, geri çağırma ve F1 puanları gibi metrikler üzerinden skorlar elde edilmiştir. Bu scorelar neticesinde sistemin gerçek dünya senaryolarında etkili olduğunu doğrulamıştır. AWS Lambda'nın entegrasyonu, sistemin yanıt verme yeteneğini önemli ölçüde iyileştirdiğı belirlenmiştir. Bu, sistemin gecikmeden aynı anda birden fazla video akışını işleyebilmesini sağlayarak gerçek zamanlı izleme için ideal hale getirmiştir.

F1 Score: Sınıflandırmada, F1 puanı, Recall ve Precision modelin performansını değerlendirmek için popüler bir ölçüttür. Recall, modelin tüm pozitif örnekleri yakalama kapasitesini değerlendirirken, precision modelin pozitif tahminlerinin doğruluğunu incelemektedir. Bir modelin performansının kapsamlı bir değerlendirmesi, recall ve precision harmonik ortalaması olan F1 puanı tarafından sağlanmaktadır. Bu metrik 0 ile 1 arasında değişmektedir, burada 1 mükemmel precision ve recall, 0 ise zayıf performansı göstermektedir. F1 Score hesaplaması şu şekildedir:

Formül 1: F1 Score Hesaplama

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Accuracy: Sınıflandırma için en sık kullanılan ölçütlerden biridir. Accuracy, bir ölçümün gerçek değere yakınlığını tanımlamak için kullanılır. Aşağıdaki denklemle hesaplanabilir:

Formül 2: Accuracy Hesaplama

$$\text{Accuracy} = \frac{\text{True Positives} + \text{True Negatives}}{\text{True Positive} + \text{True Negatives} + \text{False Positives} + \text{False Negatives}}$$

Recall: Sınıflandırıcının tüm pozitif örnekleri bulma yeteneğidir. Formülü şu şekilde gösterilebilir:

Formül 3: Recall Hesaplama

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

Precision: Sınıflandırıcının negatif bir örneği pozitif olarak etiketlememe yeteneğidir. Şu formülle gösterilmektedir:

Formül 4: Precision Hesaplama

$$Precision = \frac{True\ Positives}{True\ Positives + False\ Positives}$$

Tablo 1: Sınıflandırma Raporu (Sınıf 0: Şiddetsizlik, Sınıf 1: Şiddet, Sınıf 2: İntihar Girişimi)



Classification Report				
	Precision	Recall	F1-Score	Support
0	0.88	0.92	0.90	639
1	0.96	0.93	0.94	1294
2	0.98	0.99	0.99	1346
Accuracy			0.95	3279
Macro Avg	0.94	0.95	0.94	3279
Weighted Avg	0.95	0.95	0.95	3279

Macro Average (macro avg) :

Her sınıfın precision, recall ve F1-score değerlerinin eşit ağırlıklı ortalamasıdır. Modelde macro avg genel olarak iyi bir performans göstermiştir ve her sınıfta benzer doğruluk seviyeleri yakalanmıştır.

Weighted Average (weighted avg):

Her sınıf için ölçülen metriklerin (precision, recall, F1 score) ağırlıklı ortalamasıdır, sınıfın veri setindeki örnek sayısına göre ağırlıklandırılır. Weighted avg hesaplamasında, büyük sınıflar (1 ve 2) daha fazla ağırlık taşımaktadır. Sınıf 0'ın precision değeri biraz daha düşük olmasına rağmen, sınıflar arasındaki örnek dağılımı dengeli bir sonuç vermiştir. Bu nedenle model, büyük veri kümelerinde de iyi bir performans sergilemektedir.

Support:

Her sınıf için veri setindeki gerçek örnek sayısıdır. Yani, modelin tahmin etmeye çalıştığı sınıfın veri setinde ne kadar bulunduğunu gösterir. Sınıflandırma raporlarında, her sınıfın gerçek örnek sayısını gösterir ve weighted avg hesaplamalarında kullanılır. Şiddetsizlik eylemi için 639 sayıyla en az örnek, intihar girişimi 1346 sayıyla en çok örneğe sahiptir.

Classification Report Yorumlanması

Sınıf 0 (Şiddetsizlik):

Precision (Kesinlik): Şiddetsizlik sınıfında yer alan davranışların %88'inin gerçekten şiddet içermediği anlamına gelmektedir.

Recall (Duyarlılık): Gerçekten şiddet içermeyen verilerin %92'si doğru şekilde şiddetsizlik olarak sınıflandırılmıştır. Geri kalan %8 ise şiddet ya da intihar girişimi sınıflarına yanlış atanmıştır.

F1-score: Precision ve Recall'un dengeli bir birleşimi olan bu skor, şiddetsizlik sınıfı için %90 olarak belirlenmiştir. Bu da şiddetsizlik sınıfında modelin performansın dengeli ve iyi olduğunu ifade etmektedir.

Sınıf 1 (Şiddet):

Precision: Modelin şiddet olarak sınıflandırdığı verilerin %96'sının gerçekten şiddet içerdiği anlamına gelmektedir.

Recall: Gerçekten şiddet içeren verilerin %93'ü doğru şekilde sınıflandırılmıştır.

F1-score: Precision ve Recall'un dengeli bir birleşimi olan bu skor, şiddet sınıfı için %94 oranındadır. Bu, modelin şiddet sınıfında güçlü bir performans sergilediğini göstermektedir.


Sınıf 2 (İntihar Girişimi):

Precision: Modelin intihar girişimi olarak sınıflandırdığı verilerin %98'i gerçekten intihar girişimi davranışı olarak belirlenmiştir.

Recall: Gerçekten intihar girişimi olan verilerin %99'u doğru sınıflandırılmıştır. Model, intihar girişimi sınıfına ait örnekleri neredeyse tamamına yakın yakalamıştır ve sadece %1'lik bir kaçırma oranı vardır.

F1-score: Precision ve Recall'un birleşimi olarak intihar girişimi sınıfı için %99 oranındadır. Model bu sınıf için oldukça başarılı sonuç göstermiştir

Tablo 2: Confusion Matrix



	0	1	2
0	589	43	7
1	77	1201	16
2	2	12	1332
False Positives (FP): [79 55 23]			
False Negatives (FN): [50 93 14]			
True Positives (TP): [589 1201 1332]			
True Negatives (TN): [2561 1930 1910]			

Confusion Matrix Yorumlanması:

Şiddetsizlik sınıfı için doğru sınıflandırılan 589 veri vardır, 43 veri yanlışlıkla şiddet (1) ve 7 veri intihar girişimi (2) olarak sınıflandırılmıştır. Şiddet sınıfında 1201 veri doğru sınıflandırılmıştır, ancak 77 veri yanlışlıkla şiddetsizlik (0) ve 16 veri intihar girişimi (2) olarak etiketlenmiştir. İntihar girişimi sınıfında 1332 veri doğru sınıflandırılmıştır, 12 veri şiddet (1) olarak sınıflandırılmış ve 2 veri şiddetsizlik (0) olarak etiketlenmiştir.

Yanlış Pozitifler (False Positives)

Model 79 kez şiddetsizlik sınıfında olmayan bir veriyi yanlışlıkla şiddetsizlik olarak sınıflandırmıştır. Şiddet içermeyen verilerden 55 tanesi yanlışlıkla şiddet olarak

sınıflandırılmıştır. İntihar girişimi olmayan veriler 23 kez intihar girişimi olarak sınıflandırılmış.

Yanlış Negatifler (False Negatives):

Şiddetsizlik sınıfına ait olan bir veri 50 kez şiddet veya intihar girişimi olarak sınıflandırılmıştır. Şiddet sınıfında olan 93 veri yanlışlıkla şiddetsizlik veya intihar girişimi olarak sınıflandırılmıştır. İntihar girişimi olan 14 veri şiddet veya şiddetsizlik olarak sınıflandırılmıştır.

Bu çalışma, orijinal şiddet tespit yöntemini intihar girişimlerinin tespitini de içerecek şekilde genişleterek psikiyatri kurumları için daha kapsamlı bir çözüm haline getirmeyi amaçlamaktadır. AWS Lambda gibi Cloud tabanlı hizmetlerden yararlanarak sistem hem uygun fiyatlılık hem de ölçeklenebilirlik elde edilerek ve pahalı yerinde donanım ihtiyacı duymadan gerçek zamanlı işleme olanak sağlamaktadır. Sistemin yüksek doğruluğu, Telegram üzerinden gerçek zamanlı bir uyarı sistemi entegrasyonu ile birleştiğinde, sağlık çalışanlarına kritik olayları gerçek zamanlı olarak izlemek ve bunlara yanıt vermek için bir araç sunmaktadır. Bu genişletilmiş yaklaşım, hassas ortamlarda şiddet ve intihar girişimlerinin gerçek zamanlı video tabanlı tespitinin potansiyelini göstermektedir. Ruh sağlığı bakım ortamlarında hasta güvenliği için ölçeklenebilir, uygun fiyatlı ve etkili bir çözüm sağlamaktadır. Model genel anlamda tüm sınıflarda iyi performans sergilemektedir. İntihar girişimi sınıfında en iyi başarı sağlanırken, şiddetsizlik sınıfında model daha fazla yanlış pozitif ve yanlış negatif yapma eğilimindedir. Şiddet sınıfında da model iyi performans sergilemektedir, ancak yanlış negatif oranı şiddetsizlik sınıfına göre biraz daha yüksektir. Modelin genel accuracy (doğruluk) oranı %95'dir. Bu da modelin büyük ölçüde doğru sınıflandırmalar yaptığı anlamına gelmektedir.


4.2. Gerçek Zamanlı Değerlendirme

Çalışma kapsamında yer alan davranışlar gece ve gündüz ayrı olacak şekilde her biri yaklaşık 30-60 sn süresince kesintisiz bir şekilde ardışık olarak kaydedilmiştir. Kameralar saniyede 15 FPS hızında çalışmaktadır ve özellik çıkarmak için 3 sn'lik video klipler kullanılmıştır. Model $(15 \text{ FPS} \times 3 \text{ sn} = 45 \text{ kare})$ formülüyle 45 kare üzerinden tek bir sınıf etiketi çıkarmaktadır. Uyarılar bu 45 karenin değerlendirilmesiyle bilgisayar ekranına ve telegrama yansıtılmaktadır. Oyuncular bu süreçte her davranışı belirtilen saniye aralığında odanın farklı yerlerinde sergilemişlerdir ve bu aşamada dört oyuncunun yardımı alınmıştır. Çekimler esnasında oda içerisinde üç yatak, iki koltuk, bir sandalye ve üç oyuncu mevcuttur. Bu şekliyle hasta yatışı olan klinik odasıyla benzer bir yapı oluşturulmuştur. Çekimler esnasında iki kişi veya tek kişi çalışma kapsamında yer alan herhangi bir davranışı sergilerken odada ki diğer kişi veya kişilerin farklı bir eylem sergilemesi istenmiştir. Bu sayede birden çok farklı hareketin yer aldığı bir ortamda modelin nasıl çalışacağı test edilmiştir. Eylemler birden çok kez karma bir şekilde art arda tekrar edilmiştir. Davranışları sergilerken oyunculardan odanın her noktasını kullanmaları istenmiştir. Bu sayede gerçek bir klinik ortamında meydana gelebilecek olası durumlar senaryolaştırılmıştır. Çalışma kapsamında önemli olan oyuncuların beden hareketlerinin davranışa uygun bir şekilde sergilenmesidir. Bunun için oyunculara test verisinde yer alan örnek birkaç video izletilmiş ve benzer şekilde eylemleri sergilemeleri istenmiştir. Her bir eylemin süresi ve uygunluğu bilgisayar ekranından takip edilmiş oyunculara gerekli yönlendirmeler sağlanmıştır. OpenPose modeli beden hareketlerinden anahtar noktaların çıkarılarak çalışması prensibine dayandığı için kişilerin jest ve mimikleri önem arz etmemektedir. Çekimler gece ve gündüz sürelerinde yapılmış, gece için hemen hemen tüm eylemlerin sergilendiği 21.11 dk'lık video kaydedilmiştir. Gündüz için tüm eylemlerin sergilendiği 17.35 dk'lık video

kaydedilmiştir. Geliştirilen modelin değerlendirilmesi kaydedilen bu video görüntülerinden sağlanmıştır. Modelden beklenen performans her şiddet eyleminde ve intihar girişiminde bilgisayar ekranına ve anlık mesajlaşma uygulaması olan telegrama uyarı vermesidir. Bunun için geliştirilen model telegrama da entegre edilmiştir. Gerçek zamanlı değerlendirme amacıyla en az hemşirelik lisans son sınıf düzeyinde eğitim gören ve en az lisans mezunu olan üç hemşirenin yardımı alınmıştır. Kaydedilen görüntüler üzerinden üç sağlık çalışanının meydana gelen her şiddet ve intihar eyleminin başlangıç ve bitiş zamanlarını ortak bir süre belirleyerek yazmaları istenmiştir. Sonrasında model kaydedilen görüntüler üzerinde bir bilgisayar mühendisinin yardımıyla çalıştırılarak sorumlu araştırmacı tarafından eylemlerin ve uyarıların değerlendirilmesi sağlanmıştır. Modelin çalışması bittiğinde oluşan log dosyası sağlık çalışanlarının belirttiği başlangıç ve bitiş süreleriyle kıyaslanarak hem gerçek zamanlı etkinliği hem de insan gözüyle kıyaslandığında ki etkinliği değerlendirilmiştir ve şu sonuçlara varılmıştır.

Gece çekimlerinde model tarafından 51 uyarı gelmiştir. Bu uyarılardan 4'ü ası yoluyla intihar eylemine yöneliktir. Şiddet eylemi bulunmamasına rağmen üç tane yanlış şiddet uyarısı gelmiştir. Yüze yastık kapama ve tekme atma davranışlarında şiddet uyarısı gelmesi gerekirken uyarı gelmemiştir. Gündüz çekimlerinde model tarafından 122 uyarı gelmiştir. Bunlardan 4'ü ası yoluyla intihara yöneliktir. Model gerçekleşen her şiddet eylemi için uyarı vermiştir. Konuşma, kitap okuma ve yemek yeme gibi şiddetsizlik sınıfında yer alan davranışlarda model 37 yanlış şiddet uyarısı oluşturmuştur. Bu değerlendirme modelin verdiği uyarılar ve süreleriyle, sağlık çalışanlarının her bir davranış için belirttiği başlangıç ve bitiş süreleri karşılaştırılarak sağlanmıştır. Her davranış için sağlık çalışanlarının belirttiği başlangıç ve bitiş süresi içerisinde model tarafından uyarı verme durumu ve kaç uyarı verdiği dikkate alınmıştır. Sağlık çalışanının belirttiği süre içerisinde model bir veya daha fazla uyarı verdiyse bu durum uyarının doğru kabul edilmesini desteklemiştir. Modelin uyarılarında sağlık çalışanı tarafından verilen sürenin +10 sn ve -10 sn sapmalar olması kabul edilebilir olarak değerlendirilmiştir. Bunun nedeni gerçek zamanlı değerlendirmede uzun süreli ve birbirinden farklı eylemlerin kesintisiz bir video akışı içerisinde gerçekleşmesidir. Model 15 FPS hızında ve her 3 sn'de bir sınıflandırma yapmaktadır. Eğitim ve test sırasında ise eylemlerin olduğu kesin zaman dilimleri mevcuttur. Gerçek zamanlı çalıştırıldığında eylemler eğitim ve test sürecindeki zaman dilimleriyle her zaman örtüşmemektedir.

Şekil 4: Sistemin Gerçek Zamanlı Akış Diagramı



Sistem test aşamasında önceden kaydedilmiş videolarla çalıştırılmıştır, ancak gerçek zamanlı video akışı ile çalışacak şekilde tasarlanmıştır.

Video Giriş (Kaydedilmiş Veri): Sistemin değerlendirilmesi için gerçek zamanlı bir kamera akışı yerine, önceden kaydedilmiş bir video dosyası kullanılmıştır.

Frame by Frame İşleme: Video akışı gerçek zamanlıymış gibi kare kare okunmuştur ve her kare tekil bir zaman adımı olarak işlenmiştir.

Beden Özelliklerinin Çıkarılması: OpenPose uygulamasıyla insan iskelet noktaları (keypoints) tespit edilmiştir.

Veri Ön İşleme ve Özellik Hazırlama: Bulunan iskelet noktaları model girişine uygun formata getirilmiştir (ölçeklendirme, normalizasyon vb.).

Model İnfereansı (LSTM + AWS Lambda): Hazırlanan veriler LSTM tabanlı modele gönderilmiş ve sınıflandırma sonucu anında geri alınmıştır.

Davranış Sınıflandırma: Modelin çıktısına göre her kare için davranış etiketi belirlenmiştir. (örnek: violence detected, suicide attempt detected).

Bildirim Gönderimi: Son olarak sınıflandırma sonucunda kritik bir durum tespit edildiğinde, sistem Telegram üzerinden uyarı mesajı göndermiştir.

Tablo 3: Gerçek Zamanlı Değerlendirme Tablosu


GECE (Meydana Gelen Eylem)	Başlangıç	Bitiş	Bilgisayar Log Çıktıları/51 uyarı
Yatma	0.0	0.50	Uyarı Yok
Yüze Yastık Kapama	0.58	1.28	Uyarı Yok
Oturma	1.50	2.12	Uyarı Yok
Tokat Atma	2.37	3.15	Violence detected at 2m 50s
Giyinme	3.40	4.19	Uyarı Yok
Arkadan Boğazını Sıkma	4.26	4.48	Violence detected at 4m 35s Violence detected at 4m 38s
Soyunma	5.05	5.35	Uyarı Yok
Saç Çekme	5.54	6.25	Violence detected at 5m 59s Violence detected at 6m 2s
Su İçme	6.51	7.27	Uyarı Yok
Yürüme	7.39	8.15	Violence detected at 7m 50s
Yumruk Atma	8.17	8.49	Violence detected at 8m 26s Violence detected at 8m 29s Violence detected at 8m 32s Violence detected at 8m 35s Violence detected at 8m 38s Violence detected at 8m 41s Violence detected at 8m 44s
Duvara Dayama	8.53	9.38	Violence detected at 8m 56s Violence detected at 8m 59s Violence detected at 9m 2s Violence detected at 9m 5s Violence detected at 9m 8s Violence detected at 9m 11s Violence detected at 9m 14s Violence detected at 9m 17s Violence detected at 9m 20s Violence detected at 9m 23s Violence detected at 9m 26s Violence detected at 9m 29s
İtme	10.18	11.00	Violence detected at 10m 29s Violence detected at 10m 32s Violence detected at 10m 35s Violence detected at 10m 38s Violence detected at 10m 47s
Bir Cisimle Vurma	11.21	11.50	Violence detected at 11m 44s Violence detected at 11m 47s Violence detected at 11m 50s
			Violence detected at 12m 2s
İntihar	13.10	14.37	Suicide attempt detected at 14m 5s Suicide attempt detected at 14m 8s Suicide attempt detected at 14m 11s Suicide attempt detected at 14m 14s
Saç Tarama	15.05	15.58	Uyarı Yok

Kafa Atma	16.10	16.50	Violence detected at 16m 8s Violence detected at 16m 11s Violence detected at 16m 20s Violence detected at 16m 23s Violence detected at 16m 26s Violence detected at 16m 29s Violence detected at 16m 32s Violence detected at 16m 35s Violence detected at 16m 38s
			Violence detected at 16m 56s
Pencereden Bakma	17.03	18.00	Uyarı Yok
Tekme Atma	18.00	19.15	Uyarı Yok
Boğuşma	19.54	20.40	Violence detected at 20m 5s Violence detected at 20m 8s Violence detected at 20m 11s
GÜNDÜZ (Meydana Gelen Eylem)	Başlangıç	Bitiş	Bilgisayar Log Çıktıları/ 122 uyarı
Yatma	0.0	0.40	Uyarı Yok
			Violence detected at 0m 41s Violence detected at 0m 44s
Bir Cisimle Vurma	0.49	1.19	Violence detected at 0m 47s Violence detected at 1m 17s Violence detected at 1m 20s Violence detected at 1m 23s
Yürüme	1.36	2.07	Uyarı Yok
Saç Çekme	2.07	2.38	Violence detected at 2m 14s Violence detected at 2m 29s Violence detected at 2m 32s
Saç Tarama	2.47	3.17	Uyarı Yok
Konuşma	3.30	4.03	Violence detected at 3m 29s Violence detected at 3m 38s Violence detected at 3m 41s Violence detected at 3m 44s Violence detected at 3m 47s Violence detected at 3m 50s Violence detected at 3m 53s Violence detected at 3m 56s Violence detected at 3m 59s
Tokat Atma	4.04	4.34	Violence detected at 4m 8s Violence detected at 4m 17s Violence detected at 4m 20s Violence detected at 4m 23s Violence detected at 4m 26s Violence detected at 4m 29s
Arkadan Boğazını Sıkma	4.38	5.15	Violence detected at 4m 41s Violence detected at 4m 44s Violence detected at 4m 53s Violence detected at 5m 8s Violence detected at 5m 11s Violence detected at 5m 14s


			Violence detected at 5m 17s
Su İçme	5.30	6.10	Uyarı Yok
Giyinme	6.20	6.50	Uyarı Yok
Dışarıya Bakma	7.00	7.35	Uyarı Yok
			Violence detected at 7m 47s Violence detected at 7m 50s Violence detected at 7m 53s Violence detected at 7m 56s
Yumruk Atma	8.00	8.37	Violence detected at 7m 59s Violence detected at 8m 2s Violence detected at 8m 5s Violence detected at 8m 8s Violence detected at 8m 11s Violence detected at 8m 14s Violence detected at 8m 17s Violence detected at 8m 26s Violence detected at 8m 29s Violence detected at 8m 32s Violence detected at 8m 35s Violence detected at 8m 38s
			Violence detected at 8m 41s Violence detected at 8m 44s Violence detected at 8m 47s
Yüze Yastık Kapama	09.07	09.48	Violence detected at 9m 8s Violence detected at 9m 11s Violence detected at 9m 14s Violence detected at 9m 17s Violence detected at 9m 20s Violence detected at 9m 29s Violence detected at 9m 41s Violence detected at 9m 44s Violence detected at 9m 47s
İtme	09.48	10.40	Violence detected at 9m 59s Violence detected at 10m 2s Violence detected at 10m 38s
Soyunma	10.54	11.17	Uyarı Yok
Yemek yeme	11.38	12.20	Violence detected at 11m 44s Violence detected at 11m 56s Violence detected at 11m 59s Violence detected at 12m 2s Violence detected at 12m 5s Violence detected at 12m 8s Violence detected at 12m 17s
Duvara Dayama	12.25	13.03	Violence detected at 12m 29s Violence detected at 12m 32s Violence detected at 12m 35s Violence detected at 12m 38s Violence detected at 12m 41s Violence detected at 12m 44s Violence detected at 12m 47s

			Violence detected at 12m 50s
Tekme Atma	13.03	13.40	Violence detected at 13m 8s Violence detected at 13m 11s Violence detected at 13m 14s Violence detected at 13m 17s Violence detected at 13m 20s Violence detected at 13m 23s Violence detected at 13m 26s
			Violence detected at 14m 23s
İntihar	14.30	15.10	Violence detected at 14m 38s Suicide attempt detected at 14m 47s Suicide attempt detected at 14m 50s Suicide attempt detected at 14m 53s Suicide attempt detected at 14m 56s
Kitap Okuma	15.28	16.02	Violence detected at 15m 38s Violence detected at 15m 41s Violence detected at 15m 50s Violence detected at 15m 53s Violence detected at 15m 56s Violence detected at 15m 59s Violence detected at 16m 2s
			Violence detected at 16m 5s Violence detected at 16m 8s Violence detected at 16m 11s
Kafa Atma	16.16	16.55	Violence detected at 16m 14s Violence detected at 16m 17s Violence detected at 16m 20s Violence detected at 16m 23s Violence detected at 16m 26s Violence detected at 16m 29s Violence detected at 16m 32s Violence detected at 16m 35s Violence detected at 16m 44s Violence detected at 16m 47s Violence detected at 16m 50s Violence detected at 16m 53s
Boğuşma	16.57	17.35	Violence detected at 16m 56s Violence detected at 16m 59s Violence detected at 17m 2s Violence detected at 17m 5s Violence detected at 17m 8s Violence detected at 17m 11s Violence detected at 17m 20s Violence detected at 17m 23s Violence detected at 17m 26s Violence detected at 17m 29s


Şekil :5 Gündüz Gelen Uyarıların Grafiği




Şekil 6: Gece Gelen Uyarıların Grafiği



Şekil 7: Gündüz Sergilenen Davranışlara Ait Isı Haritası

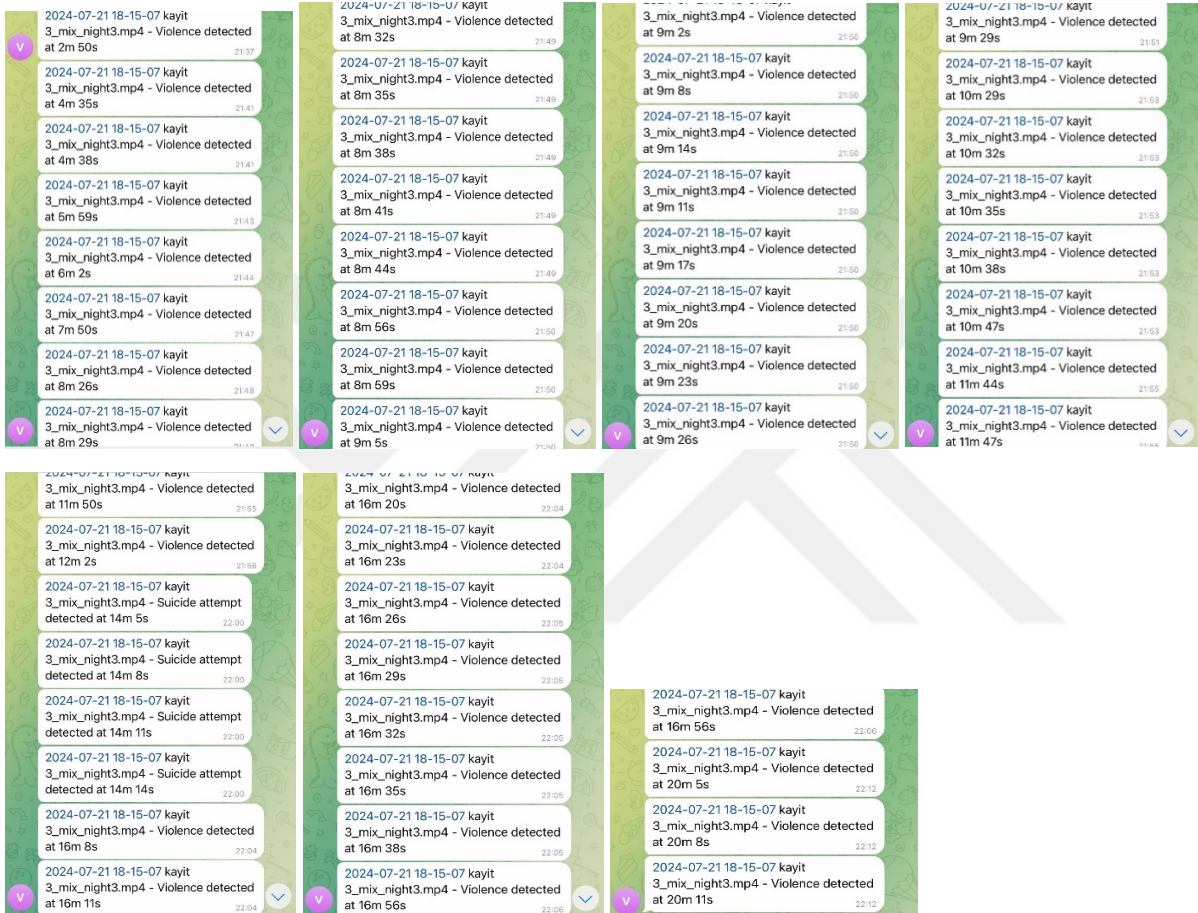


Şekil 8: Gece Sergilenen Davranışlara Ait Isı Haritası



Yukarıda yer alan ısı haritası, eylem türlerini (dikey eksen) ve zaman dilimlerini (yatay eksen) bir arada göstererek, sistemin hangi eylemlerin hangi zaman aralıklarında daha yoğun uyarı verdiğini göstermektedir. Renk yoğunluğu artan alanlar, tam olarak hangi zaman dilimlerinde hangi eylemler için daha fazla uyarı verildiğini belirtmektedir.

Şekil 9: Gerçek Zamanlı Değerlendirmede Gece Kaydından Telegrama Gelen Uyarıların Ekran Görüntüsü



Şekil 10: Gerçek Zamanlı Değerlendirmede Gündüz Kaydından Telegrama Gelen Uyarıların Ekran Görüntüsü





5. TARTIŞMA

Araştırmada derin öğrenme yöntemi kullanılarak psikiyatri kliniklerinde şiddet ve ası yoluyla intihar davranışlarının tespitini sağlayabilecek nitelikte bir yapay zeka modeli geliştirilmeye çalışılmıştır. Bu bölümde araştırma sonuçları literatürde var olan uygulamalar doğrultusunda tartışılmıştır.

5.1. Şiddet Tespitine Yönelik Sonuçların Tartışılması

Araştırma sonucunda şiddet sınıfına yönelik F1 score (0.94) ve accuracy (0.95) olarak bulunmuştur. Bu da modelin, gerçekleşen eylemin ne olduğunu yüksek oranda doğru tahmin ettiğini göstermektedir. Araştırmanın sonuçları değerlendirildiğinde **H 0-1** hipotezi doğru olarak kabul edilmektedir. Literatürde yer alan derin öğrenme kullanılarak gerçekleştirilen şiddet tespitine yönelik güncel çalışmalar taranmıştır. Zhou ve arkadaşlarının (2018) yaptığı çalışmada BoW modeli kullanılarak şiddet davranışlarının tüm ortamlarda tespitine yönelik bir çalışma yapmışlardır. Bunun için hokey oyuncularının oyun sırasındaki görüntülerinden oluşan Hokey Dövüşleri veri seti, herhangi bir sokaktaki görüntüden BEHAVE veri seti ve kalabalıkları içeren görüntülerden oluşan Crowd Violence veri setlerinden faydalanmışlardır. Bu çalışmanın sonucunda kapalı ortamlar için tanımlanan Hockey veri setiyle şiddet davranışlarının tespitine yönelik yapılan çalışmada accuracy %91.90 olarak belirtilmiştir. BEHAVE için başarı %87.17 ve Crowd için %89.78 accuracy belirlenmiştir. Peixoto ve arkadaşlarının (2020) yaptığı çalışmada şiddet tespiti için görsel ve işitsel ipuçlarından yararlanılmıştır. Çalışma sonucunda şiddet tespiti görsel öğelere dayalı C3D algoritmasıyla yapıldığında accuracy %68.3, LSTM ile yapıldığında %63.6 olarak bulunmuştur. İşitsel olarak şiddet tespiti sonucunda accuracy %72.8 olarak saptanmıştır. Gao (2023) yaptığı çalışmada IoT'da (nesne interneti) tabanlı Yolo (derin öğrenme algoritması) ile yapılan şiddet tespitine yönelik bir çalışmada şiddet ve şiddet içermeyen görüntüler kullanarak şiddet tespiti için bir model oluşturulmuştur. Çalışma sonucunda accuracy değeri % 91 olarak belirlenmiştir. Mohod ve arkadaşlarının (2024) gerçek zamanlı şiddet tespitine yönelik yaptığı çalışmada MobileNetV2 modeli kullanılmış ve %88 accuracy elde edilmiştir. Literatür tarandığında yapılan çalışmalar genel olarak şiddet ve şiddetsizlik sınıfı olmak üzere iki sınıf içermektedir. Yaptığımız çalışma üç sınıf içermesine rağmen sonuçlar literatürdeki çalışmalardan daha yüksek başarı göstermiştir.

Halder ve Chatterjee (2020) tarafından akıllı gözetimde şiddetin tespitine yönelik yapılan çalışmada CNN (Evrişimsel Sinri Ağı) tabanlı BİLSTM algoritması kullanılmıştır. Bu model, yaygın olarak kullanılan standart Hokey Dövüşleri, Filmler ve Şiddet Akışları video veri kümeleri için sırasıyla %99,27, %100 ve %98,64 accuracy sağlamıştır. Çalışmamızda ise LSTM modeli kullanılmıştır. CNN-BİLSTM modeli hem zamansal hem de mekânsal özellikleri dikkate alarak veriyi işlemektedir. Videolardaki ardışık karelerin hem önceki karelerle hem de sonraki karelerle karşılaştırılması, olayların sırasını daha doğru tahmin etmeye olanak sağlamaktadır. Sadece LSTM kullanımı bu tür çift yönlü bilgi akışını sağlamadığı için modelin doğruluğunu sınırlamış olabileceği düşünülmektedir. LSTM olayların sırasını belirlemek için yalnızca önceki karelere dayanırken CNN-BİLSTM modeli iki yönlü analiz yapmaktadır. LSTM modelleri veriyi sadece ileri yönlü işlemekte ve geçmiş durumları dikkate almaktadır. Örneğin bir olayın zaman içinde ilerlemesi gibi durumlarda LSTM, geçmiş durumlardaki bağımlılıkları öğrenir. Ancak gelecekteki durumlara dair bilgiyi kullanmaz. Ayrıca BİLSTM iki yönlü bilgi akışı sağladığından LSTM'ye göre daha fazla hesaplama gerektirir. Bu da modelin

işlem süresi açısından bir yük oluşturmaktadır. Çalışmamızda intihar ve şiddet tespiti için geçmiş durumları dikkate alan ve veriyi ileri yönlü işleyen LSTM kullanılmıştır. Çünkü bu davranışların sonrasında meydana gelecek davranışlar anlamlı olmayacağı düşünülmüştür ve hesaplama yönünden daha az maliyetlidir. Bu da gerçek zamanlı davranış tespiti için daha uygun bulunmuştur.

Elkhashab ve Behaidy (2023) tarafından daha önce eğitilmiş bir modelin şiddet tespit düzeyi yükseltilmeye çalışılmıştır. Bunun için Hockey veri setinin DenseNet121 kullanılarak videoların uzay zaman özellikleri çıkarılmıştır. Daha sonra LSTM ağıyla beslenmiş ve accuracy oranı %94 ten %96 ya çıkarılmıştır. Vijeikis ve arkadaşlarının (2022) şiddet tespiti için yaptığı çalışmada veri seti için RWF-2000 kodlayıcı olarak MobileNetV2, özellik çıkarma ve sınıflandırma için LSTM'yi kullanmışlardır. Çalışma sonucunda accuracy değeri % 82 olarak belirlenmiştir. More ve arkadaşlarının (2024) yaptığı çalışmada gerçek zamanlı silah ve şiddet tespitine odaklanılmış, mekânsal özelliklerin çıkarılmasında CNN, zamansal bağılıkları ve dinamik dizileri çıkarmak için BİLSTM kullanılmıştır, silah tespiti için bir nesne tespit algoritması olan YOLO'dan faydalanılmıştır. Çalışmanın sonucunda accuracy oranı % 89.12 olarak belirlenmiştir. Literatür tarandığında test ve eğitim için hazır veri setleri kullanılmıştır. Bu veri setleri genellikle spor müsabakalarındaki ve filmlerdeki dövüş sahnelerini içermektedir. Ancak bir psikiyatri kliniğinde şiddet daha anlık olabilmekte bu da önceden tahmin edilebilmesini zorlaştırabilmektedir. Çalışmalarda genellikle tercih edilen Hockey veri seti ve film dövüşleri veri seti ortak davranışı içermektedir. Bu davranışlar genel olarak iki kişi birbirine yavaşça yaklaştığında başlar ve kameranın tam merkezinde yer alır. Genellikle iyi aydınlatılmış bir ortam kullanılarak hazırlanmışlardır. Bu da görüntünün daha net algılanmasına olanak tanımaktadır. Ancak kliniklerde gece ışıklar kapalı halde olmaktadır. Modelin test edilmesinde ışığın az olduğu gece saatlerinden de faydalanılmıştır ve yüksek başarı elde edilmiştir. Çalışmamızda üç sınıf yer almaktadır. Üç sınıflı bir sınıflandırma sınıflar arasındaki ayrımı daha zor hale getirmektedir. Özellikle intihar sınıfının diğerlerinden ayrılması daha zor olmaktadır. Çünkü intihar girişimi yapısı gereği şiddet eyleminden çok farklıdır. Birey bu eylemi tek başına gerçekleştirmekte ve herhangi bir şiddet görüntüsü oluşturmamaktadır. Bu nedenle tahmin edilmesi ve modelin eğitimi daha farklıdır. Bu da birbirinden farklı birçok eylemin model tarafından tanınması ve sınıflandırılması gerektiği anlamına gelmektedir. Literatür tarandığında çalışmamızın accuracy(doğruluk) oranı birçok çalışmada elde edilmiş başarı oranından daha yüksek olduğu görülmüştür.

5.2. İntihar Girişimi Tespitine Yönelik Sonuçların Tartışılması

Çalışma kapsamında ası yoluyla intihar girişimi tespiti yapılmaya çalışılmış ve sonucunda F1 score (0.99), accuracy (0.95) olarak belirlenmiştir. Araştırmanın sonuçları değerlendirildiğinde **H 0-2** hipotezi doğru olarak kabul edilmektedir. Son yıllarda, özellikle asılarak intihar girişimlerinin tespiti derin öğrenme metodolojilerinin ortaya çıkmasıyla daha dikkat çekici hale gelmiştir. Çeşitli çalışmalar, zamanında müdahale ve önleme için kritik öneme sahip olan intihar davranışlarını belirlemede makine öğrenimi ve bilgisayarlı görme tekniklerinin etkinliğini vurgulamaktadır. Literatür tarandığında intihar tespiti büyük çoğunlukla intihar riski taşıyan bireylerin tespitine odaklanmaktadır. Derin öğrenmeyi kullanarak yapılan bu çalışmalar sosyal medya gönderileri, klinik kayıtlar ve beyin görüntüleme gibi çeşitli veri kaynaklarının analizine dayanmaktadır. Du ve arkadaşlarının (2018) yaptığı çalışmada Twitter gibi gerçek zamanlı bilgi paylaşım akışı olan bir uygulama kullanılmış ve intihara yönelik Tweetlerden oluşan bir veri seti oluşturulmuştur. Bu veri seti CNN tabanlı bir algoritma kullanılarak işlenmiş

ve sonucunda %83 F1 score ulaşılmıştır. Bouchair ve arkadaşlarının (2018) tarafından hapishanelerde ası yoluyla intihar eyleminin tespitine yönelik bir model oluşturulmaya çalışılmıştır. Bunun için ası yoluyla intihara yönelik RGB-D kamera kullanarak bir veri seti oluşturmuşlardır ve bu veri setindeki karelerin özelliklerini Shotton ve arkadaşları (2013) tarafından geliştirilen 3D nesne tanıma stratejilerinden faydalanarak geliştirmişlerdir. Bu çalışmada ikili sınıflandırıcı (RBF-SVM) modeli kullanılmıştır ve veri setindeki dengesizlikler giderildiğinde %100 doğruluk oranı elde edilmiştir. Li ve arkadaşlarının (2017) yaptığı çalışmada RGB-D kamerayla hapishane hücresinde ası yoluyla intihara yönelik veri seti oluşturulmuş ve LDA sınıflandırıcı kullanılarak poz ve hareket verilerini sınıflandırmıştır. Çalışma sonucunda intihar girişimlerini %100 doğruluk oranıyla tespiti sağlanmış ancak, günlük hareketler sırasında (örneğin, giysi giyip çıkarma) yanlış alarmlar (false positive) meydana gelmiştir. Çalışmamızda LSTM modeli kullanılarak gerçek zamanlı intihar tespitinde yüksek başarı elde edilmiştir. Bouachir ve arkadaşları (2018) ve Li ve arkadaşlarının (2017) yaptığı çalışmada hapishane gibi güneş ışığının olmadığı bir ortamda RGB-D kamera kullanılarak başarısı test edilmiştir. Bu kamera güneş ışığından etkilenebilmekte ve derinlik algısı bozulabilmektedir. Yapılan çalışmada hapishane hücrelerinin yapay ışık kullanılarak aydınlatılması ve penceresiz oluşu bu faktörü ortadan kaldırmıştır. Ayrıca sınıflandırma sadece günlük davranışlar ve ası yoluyla intihara odaklanmaktadır. Çalışmamızdaki model gün ışığının yoğun olduğu gündüz ve gece saatlerinde test edilmiş ve eylemlerin daha zor tespit edilebildiği gece saatlerinde de iyi bir başarı sağlamıştır. Model şiddet, şiddetsizlik ve intihar girişimi olmak üzere üç kategoriye ayrılmaktadır. Bu da model tarafından daha çok eylemin tanınması ve sınıflandırılması gerektiği anlamına gelmektedir. Bu faktörler göz önüne alındığında model intihar tespiti konusunda oldukça iyi bir başarı yakalamıştır.

Literatür tarandığında gerçek zamanlı intihar tespitine yönelik çalışmalar oldukça sınırlı sayıdadır ve bu çalışmaların birçoğu beden hareketlerinden gerçek zamanlı intihar tespitine dayanmamaktadır. Çalışmamızda beden hareketlerinden gerçek zamanlı intihar tespitine yönelik yüksek bir başarı elde edilmiş ve sınıflandırma şiddet, şiddetsizlik ve intihar girişimi olarak üç sınıf üzerinden gerçekleşmiştir.

5.3. Psikiyatri Hemşireliği ve Güvenli Ortam Üzerine Etkilerinin Tartışılması

Psikiyatri kliniklerinde güvenli ortam oluşturmak oldukça önemlidir ve bir zorunluluktur. Şiddet davranışları iyi yönetilmediğinde hastalar, çalışanlar ve terapötik ortam olumsuz etkilenebilmektedir. Psikiyatri kliniklerinde şiddet ve intihar davranışlarının belirlenmesi ve hasta/çalışan güvenliğinin sağlanması amacıyla Sağlık Hizmetleri Genel Müdürlüğü (2023) sağlıkta kalite standartları kapsamında, psikiyatri kliniklerinde yatan hastaların kamerayla gözlemlenmesine ilişkin önlemler yer almaktadır. Ancak bu önlemler tamamıyla sorunu çözmede yeterli değildir. Psikiyatri kliniklerinde hastanın takibi hemşirelerin kliniklere yerleştirilen kamera görüntülerini bilgisayar ekranından takip etmesiyle sağlanmaktadır. Özellikle gece nöbetlerinde daha az sayıda hemşire çalışmaktadır. Bu durum hem gece nöbetlerinde kamera takibinin yapılmasını zorlaştırmakta hem de hasta güvenliği açısından problem oluşturmaktadır. Ekran takibi yapılamadığı anlarda meydana gelebilecek olumsuz davranışlar gözden kaçabilmektedir. Kameralar bazı hastanelerde hasta odalarına yerleştirilirken bazı hastanelerde hasta mahremiyeti nedeniyle sadece ortak alanlar ve gözlem odalarında kullanılmaktadır (TİHEK, 2024; TİHEK, 2018). Ancak kameraların ortak alan ve gözlem odalarıyla sınırlı kalmasının hasta odalarında gelişebilecek olumsuzlukların tespitini güçleştireceği düşünülmektedir. Geliştirilen sistem ası yoluyla intihar ve şiddet eylemini tespit

ettiğinde telegram üzerinden uyarı vermektedir. Hasta odasına ait kamera görüntüleri bilgisayar ekranından anlık olarak izlenemediği durumlarda, sistemin meydana gelebilecek şiddet ve intihar eylemlerine yönelik uyarı vermesi hem hasta mahremiyetini hem de güvenli ortamı destekleyecektir. Ancak derin öğrenme sistemleri mükemmel değildir. Bu nedenle meydana gelebilecek olan yanlış pozitif (gerçekte sorun olmadığı hâlde uyarı verme) ve yanlış negatiflerde (gerçek riski atlama) yanlış uyarı verme olasılığı mevcuttur. Yanlış pozitif uyarılar, sağlık çalışanlarının zaman ve çabasını gereksiz yere harcamasına, yanlış negatifler ise gerçek risklerin gözden kaçmasına yol açabileceği göz önünde bulundurulmalıdır.

Çalışma kapsamında şiddet ve intihar davranışını içeren video kaydı gerçek zamanlı olarak çalıştırılmış ve sağlık çalışanlarının değerlendirmeleriyle kıyaslanmıştır. Bu sonuçlara göre yavaş internet hızı ve sunucuların uzak bir konumda olmasına rağmen şiddet eyleminin ve intihar eyleminin erken aşamada tespiti sağlanmıştır. Ayrıca derin öğrenme algoritmaları büyük miktarda veriyi hızla işleyebilmekte ve bunu yaparken de yorgunluk, dikkatsizlik gibi insani durumlar yaşamamaktadır. Karar verme mekanizmaları veriye dayalı olduğu için kanıta dayalı bir yaklaşım sunmaktadır (Akalin & Veranyurt., 2021). Bu yönüyle de psikiyatri hemşirelerinin iş yükünü azaltan ve kanıta dayalı bakım vermesini destekleyen bir yapıya sahiptir.

Çalışma kapsamında kullanılan kamera sistemi yapay zeka destekli, gece görüş ve uyarı verme özelliklerine sahip gelişmiş bir yapıdadır. Ancak hastanelerde kullanılan her kamera sistemi bu özellikleri karşılayamamaktadır. Bu nedenle hastanelerin mevcut kamera sistemlerinin, gerekli özelliklere sahip şekilde yapılandırılması önemlidir. Güvenli ortamı ve sistemin başarısını etkileyebilecek bir diğer önemli faktörde kliniklerde kamera görüş alanının dışında yer alan bölgelerin azaltılmasıdır. Kliniğin tüm alanlarında hem sağlık çalışanlarının hem kamera sisteminin hastaları rahatlıkla gözlemleyebilecek yapıda bir mimariye sahip olması oldukça önemlidir. Yapılacak yeni hastane tasarımlarının ve psikiyatri kliniklerinin bu doğrultuda tasarlanması güvenli ortama olumlu yönde katkı sağlayacaktır.

Psikiyatri kliniklerinde intihar eylemi de güvenli ortamı bozan durumlar arasında yer almaktadır. Ası yoluyla intihar yaygın olarak kullanılan bir yöntemdir. Ası yoluyla intiharlarda bağlama noktalarının ve araçlarının tamamı yok edilemeyeceği için asılarak intiharı azaltmak için önleme alanında daha az fırsat mevcuttur. Erken müdahale, büyük ölçüde ası eyleminin etkili önleme yöntemidir (Sabrinskas et al., 2022). Derin öğrenme yöntemi psikiyatri de genel olarak hastalıkların tedavisi ve erken teşhisine odaklanmaktadır. Ancak anlık olarak intihar girişiminin tespitinde beden hareketleri oldukça önemlidir. Bu çalışma beden hareketlerinden intihar ve şiddet eylemlerinin tespitine odaklanarak anlık olarak gelişebilen olumsuz durumların engellenmesine yönelik çözüm sunmaktadır. Geliştirilen sistem şiddet ve intihar davranışlarını önlerken, intihar girişimi veya saldırgan davranış görülme olasılığı yüksek olan hastalara daha yakın takip uygulanmasını da desteklemektedir. Bu sayede sağlık çalışanları gelen uyarıları değerlendirerek hastaların tedavi seyri ve psikososyal müdahalelerine de katkı sağlayabilecektir.

Bu çalışma kapsamında oluşturulan derin öğrenme sistemi hasta gözlem ve takibinde sağlık çalışanlarını desteklemek ve hastaların daha güvenli bir ortamda tedavi almasını hedeflemektedir. Literatür tarandığında derin öğrenmenin psikiyatri kliniklerinde ve psikiyatri hemşireliği alanında kullanımına ilişkin çalışma oldukça kısıtlıdır. Yapılan çalışmanın mevcut literatürü desteklemesi, yapılacak yeni çalışmalar için kaynak ve destek niteliği taşıması amaçlanmaktadır.

6. SONUÇ ve ÖNERİLER

6.1. Sonuç

Çalışmada şiddet, şiddetsizlik ve intihar girişimi sınıfları arasında ayrım yapabilen bir derin öğrenme modeli geliştirilmeye çalışılmıştır. Çalışma kapsamında tespit edilmesi ve uyarı verilmesi hedeflenen davranışlar ası yoluyla intihar, tokat atma, arkadan boğazını sıkma, kafa atma, sert bir cisimle vurma, saç çekme, tekme atma, yumruk atma, itme, duvara yaslama, boğuşma, yüze yastık kapama eylemlerini içeren şiddet davranışlarıdır. Şiddetsizlik sınıfı günlük yaşam aktivitelerinden oluşmaktadır ve su içme, yemek yeme, saç tarama, kitap okuma, yatma, konuşma, giyinme, soyunma, yürüme, dışarıyı izleme gibi davranışları içermektedir. Bu sınıflara yönelik beden hareketlerinin özelliklerinin çıkarılmasında OpenPose uygulaması kullanılmıştır. Modelin mimarisinde bir derin öğrenme algoritması olan LSTM'den faydalanılmıştır.

Çalışmanın sonucunda modelin accuracy (doğruluk) %95 oranında bulunmuştur. Bu da modelin, gerçekleşen eylemin ne olduğunu yüksek oranda doğru tahmin ettiğini göstermektedir. Modelin gerçek zamanlı değerlendirmesi gece ve gündüz zaman dilimlerinde yapılmıştır. Gece çekimlerinde model tarafından 51 uyarı gelmiştir. Bu uyarılardan 4'ü ası yoluyla intihar eylemine yöneliktir. Şiddet eylemi bulunmamasına rağmen üç tane yanlış şiddet uyarısı gelmiştir. Yüze yastık kapama ve tekme atma davranışlarında şiddet uyarısı gelmesi gerekirken uyarı gelmemiştir. Gündüz çekimlerinde model tarafından 122 uyarı gelmiştir. Bunlardan 4 ü ası yoluyla intihara yöneliktir. Model gerçekleşen her şiddet eylemi için uyarı vermiştir. Konuşma, kitap okuma ve yemek yeme gibi şiddetsizlik sınıfında yer alan davranışlarda model 37 yanlış şiddet uyarısı oluşturmuştur. Modelin çalışması bittiğinde oluşan log dosyası sağlık çalışanlarının belirttiği başlangıç ve bitiş süreleriyle kıyaslanarak hem gerçek zamanlı etkinliği hem de insan gözüyle kıyaslandığında ki etkinliği değerlendirilmiştir. Bu değerlendirme sonucunda gece ve gündüz sürelerince hemen hemen tüm şiddet ve intihar girişimi eyleminin tespit edildiği sonucuna varılmıştır.

6.2. Öneriler

Psikiyatri klinikleri şiddet ve intihar gibi olumsuz olayların meydana gelebildiği yerlerdir. Bu gibi durumların önlenmesinde sağlık çalışanlarının önemli rolleri vardır. Her hasta yatışında, yatan hastalarda ise belirli aralıklarla şiddet ve intihara yönelik değerlendirmelerin yapılması bu rollerden biridir. İletişim becerisi yüksek, hastalık ve kriz durumlarının yönetimini iyi yapabilen, hastaların şiddet ve intihar eğilimlerinin farkında olan, nitelikli ve donanımlı hemşirelerin psikiyatri kliniklerinde çalışması da oldukça önemlidir. Kliniklerde hasta başına düşen hemşire sayısının yeterli olması özellikle olumsuz olayların sık yaşandığı gece nöbetlerinde daha fazla sayıda hemşirenin çalışması hasta takibini kolaylaştıracaktır. Ancak ruhsal hastalıkların yaygınlığı giderek artmakta bu da mevcut kliniklerin daha da kalabalıklaşmasına neden olmakta ve yeni kliniklere duyulan ihtiyacı artırmaktadır. Mevcut kliniklerin ve bu alanda yeni açılacak kliniklerin yapı tasarımlarının şiddet ve intihar gibi olumsuz durumları önleyebilecek nitelikte yapılması, kör noktaların azaltılması, lavaboların, yemek alanlarının ve sosyal alanların hemşirenin rahatça gözlemine imkan tanıyacak şekilde tasarlanması önerilmektedir. Hasta gözetiminde hastanelerde yaygın olarak kullanılan kamera ve bilgisayar sisteminin iyi bir görüş sağlaması da olumsuz durumları önlemede önemli olan bir diğer faktördür. Tüm bu girişimlere rağmen yaşanabilecek olumsuz olayların sayısı azalsa

da tamamen engellemek mümkün olmamaktadır. Bunun için yapay zeka teknolojilerin son ürünlerinden olan derin öğrenme yöntemi görüntü algılama ve işlemede iyi bir işlev görmektedir. Çalışma sonucunda birçok şiddet ve intihar durumunu tespit edebilen bir model geliştirilmiştir. Bu modelin kliniklerde kullanıma hazır hale gelmesi için geliştirilmesi gereken bazı yönleri vardır. Model şiddet ve ası yoluyla intihar konusunda iyi bir başarı gösterse de klinikte yaşanabilecek diğer olumsuz durumlar konusunda da geliştirilmesi kliniklere uygunluğu konusunda katkı sağlayacaktır. Modelin hasta odaları dışarında yer alan alanlarda da etkinliğinin değerlendirilmesi gerekmektedir. Kliniklerde internet hızının artırılması ve kullanılan kamera sistemlerinin gerçek zamanlı video işlemeye uygun hale getirilmesi de kritik önemdedir. Ayrıca video analiz performansını artırmak amacıyla AWS Lambda sunucularının US East bölgesinden Avrupa bölgesine taşınması önerilmektedir. Bu değişiklik, video işleme sürecinde gecikmeleri minimize ederek analizlerin daha hızlı yapılmasını sağlayacaktır. Kamera ve altyapı iyileştirmeleri sayesinde verilerin anlık olarak analiz edilmesi daha verimli hale gelecektir. Bunun yanı sıra, video işleme ve derin öğrenme algoritmalarının sorunsuz çalışabilmesi için kliniklerdeki bilgisayarların performanslarının artırılması gerekmektedir. Bu teknik düzenlemeler bir arada uygulandığında, kliniklerde daha etkin bir izleme ve analiz sistemi kurulabilecektir. Araştırma sonucunda elde edilen model hasta gözetiminde sağlık çalışanlarına yardım sağlaması ve ekran takibi yapılamadığı anlarda yaşanabilecek olumsuz durumların tespit edilmesinin kolaylaştırılmasını hedeflemektedir. Araştırmamız yeni yapılacak çalışmalar için kaynak ve destek niteliği oluşturmakla birlikte özellikle gerçek zamanlı intihar tespitine odaklı yeni çalışmalara ve veri setlerine ihtiyaç vardır.

KAYNAKLAR

- Adams, A. E., Sullivan, C. M., Bybee, D., & Greeson, M. R. (2008). Development of the scale of economic abuse. *Violence Against Women*, 14(5), 563-588.
- Ahmed, F., Bari, A. H., & Gavrilova, M. L. (2019). Emotion recognition from body movement. *IEEE Access*, 8, 11761-11781.
- Akalin, B., & Veranyurt, U. (2021). Sağlık hizmetleri ve yönetiminde yapay zeka. *Acta Infologica*, 5(1), 231-240.
- American Psychiatric Nurses Association. (2022). APNA position statement: Violence prevention [Position statement]. American Psychiatric Nurses Association. Available form: <https://www.apna.org/news/violence-prevention/> [Erişim Tarihi 25.02.2025].
- Anderson, A., & West, S.G. (2011). Violence against mental health professionals: When the treater becomes the victim. *Innov Clin Neurosci*, 8(3), 34-39.
- AWS Lambda Özellikleri. Available form: <https://aws.amazon.com/tr/lambda/features/> [Erişim Tarihi 10.08.2024].
- Aytaç, S., Eteman, F.S., Aydın, G.Ç., Reçber, B., & Sezen, H.K. (2016). Kadına yönelik şiddetin dün, bugün, yarın: Kestirim tabanlı bir araştırma. *Sosyoloji Konferansları*, (54), 275-297.
- Bach, M. (2018). Violence, research, and non-identity in the psychiatric clinic. *Theor Med Bioeth*, 39(4), 283-299.
- Bhatt, M., Perera, S., Zielinski, L., Eisen, R. B., Yeung, S., El-Sheikh, W., & Samaan, Z. (2018). Profile of suicide attempts and risk factors among psychiatric patients: a case-control study. *Plos One*, 13(2), e0192998.
- Binil, V., Christopher, S., Supriya, H., & Ravishankar, N. (2017). A review on violent on behavior among patients admitted in psychiatric setting. *Medico-Legal Update*, 17, 237-242.
- Boldrini, L., Bibault, J., Masciocchi, C., Shen, Y., & Bittner, M. (2019). Deep learning: a review for the radiation oncologist. *Frontiers in Oncology*, 1(9), 977.
- Bouachir, W., Gouiaa, R., Li, B., & Noumeir, R. (2018). Intelligent video surveillance for real-time detection of suicide attempts. *Pattern Recognition Letters*, 110, 1-7.
- Brown, J.M., Campbell, J.P., Beers, A., Chang, K., Ostmo, S., Chan, R.V.P.,... Chiang, M.F. (2018). Imaging and informatics in retinopathy of prematurity (i-ROP) research consortium. Automated diagnosis of plus disease in retinopathy of prematurity using deep convolutional neural networks. *JAMA Ophthalmol*, 136(7):803-810.
- Caetano, C., dos Santos, J., & Schwartz, W. (2020). Motion-based representations for activity recognition. In *Extended Proceedings of the XXXIII Conference on Graphics, Patterns and Images*, 84-90.
- Cai, Z., Junus, A., Chang, Q., & Yip, P.S.F. (2022). The lethality of suicide methods: A systematic review and meta-analysis. *J Affect Disord*, 300, 121-129.

- Cao, Z., Hidalgo, G., Simon, T., Wei, S.E., & Sheikh, Y. (2021). OpenPose: realtime multi-person 2d pose estimation using part affinity fields. *IEEE Trans Pattern Anal Mach Intell*, 43(1), 172-186.
- Charlier, J., Ormazabal, G., State, R., & Hilger, J. (2020). MQLV: Optimal Policy of Money Management in Retail Banking with Q-Learning. *Springer: Mining Data for Financial Applications (MIDAS)*, 1-15.
- Cheng, S.W., Chang, C.W., Chang, W.J., Wang, H.W., Liang, C.S., Kishimoto, T., ...Su, K.P. (2023). The now and future of ChatGPT and GPT in psychiatry. *Psychiatry Clin Neurosci*, 77(11):592-596..
- Choi, R.Y., Coyner, A.S., Kalpathy-Cramer, J., Chiang, M.F., & Campbell, J.P. (2020). Introduction to machine learning, neural networks, and deep learning. *Transl Vis Sci Technol*, 9(2), 14.
- Christl, J., Schröder, N., Mennicken, R., Jänner, M., & Supprian, T. (2022). Inpatient suicides in late life: A retrospective analysis of a hospital group with nine psychiatric clinics. *Arch Suicide Res*, 26(3), 1436-1446.
- Chung, D.T., Ryan, C.J., Hadzi-Pavlovic, D., Singh, S.P., Stanton, C., & Large, M.M. (2017). Suicide rates after discharge from psychiatric facilities: a systematic review and meta-analysis, *JAMA Psychiatry*, 74(7), 694-702.
- Cornaggia, C.M., Beghi, M., Pavone, F., & Barale, F. (2011). Aggression in psychiatry wards: a systematic review. *Psychiatry Res*, 189(1), 10-20.
- Dack, C., Ross, J., Papadopoulos, C., Stewart, D., & Bowers, L.A. (2013). Review and meta-analysis of the patient factors associated with psychiatric in-patient aggression. *Acta Psychiatr Scand*, 127, 255–268.
- Deng, J., Eyben, F., Schuller, B., & Burkhardt, F. (2017). Deep neural networks for anger detection from real life speech data. *Seventh International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, 1-6.
- Du, J., Zhang, Y., Luo, J., Jia, Y., Wei, Q., Tao, C., & Xu, H. (2018). Extracting psychiatric stressors for suicide from social media using deep learning. *BMC Medical Informatics and Decision Making*, 18.
- Elkhashab, Y. R., & El-Behaidy, W. H. (2023). Violence detection enhancement in video sequences based on pre-trained deep models. *FCI-H Inform. Bull*, 5(1), 23-28.
- EZVİZ. Available form: <https://www.ezviz.com/product/c3x/12359?srsId=AfmBOoq93Giccm8gSXLHPNlp7UqZ9rCk1As-GhE6qhxac7EPfiQlctAG> [Erişim Tarihi 13.09.2024].
- Flynn, S., Nyathi, T., Tham, S. G., Williams, A., Windfuhr, K., Kapur, N., Appleby, L., & Shaw, J. (2017). Suicide by mental health in-patients under observation. *Psychological Medicine*, 47(13), 2238–2245.
- Gao, H. (2023). A yolo-based violence detection method in iot surveillance systems. *International Journal of Advanced Computer Science and Applications*, 14(8).

- Goldman-Mellor, S.J., Caspi, A., Harrington, H., Hogan, S., Nada-Raja, S., Poulton, R., & Moffitt, T.E. (2014). Suicide attempt in young people: a signal for long-term health care and social needs. *JAMA Psychiatry*, 71(2):119-27.
- Grushin, A., Monner, D., Reggia, J., & Mishra, A. (2013). Robust human action recognition via long short-term memory. *International Joint Conference on Neural Networks Dallas*, 1–8.
- Gunnell, D., Bennewith, O., Hawton, K., Simkin, S., & Kapur, N. (2005). The epidemiology and prevention of suicide by hanging: a systematic review. *Int J Epidemiol*, 34, 433-42.
- Halder, R., & Chatterjee, R. (2020). Cnn-bilstm model for violence detection in smart surveillance. *SN Computer Science*, 1(4).
- Harmancı, P. (2015). Dünya'daki ve Türkiye'deki intihar vakalarının sosyodemografik özellikler açısından incelenmesi, *Hacettepe University Faculty of Health Sciences Journal*, 1, 1.
- Hu, X., Chu, L., Pei, J., Liu, W., & Bian, J. (2021). Model complexity of deep learning: a survey. *Knowl Inf Syst*, 63, 2585–2619.
- İlgaz, A. (2024). Psikoloji ve Şiddet. İnce, M. (Ed.), *Medya, Şiddet ve Toplum*(pp.1-8). E-Kitap: Eğitim Yayınevi.
- Iozzino, L., Ferrari, C., Large, M., Nielssen, O., & de Girolamo, G. (2015). Prevalence and risk factors of violence by psychiatric inpatients: A systematic review and meta-analysis. *PLoS One*, 10(6), e0128536.
- Jordan, C.E., Campbell, R., & Follingstad, D. (2010). Violence and women's mental health: the impact of physical, sexual, and psychological aggression. *Annu Rev Clin Psychol*, 6, 607-28.
- Kızılırmak, B. (2014). Ruhsal bozukluğu olan bireylerin ailelerinde bakım yükü ve ruhsal sağlık durumu. *Yayınlanmamış Yüksek Lisans Tezi*. İstanbul Üniversitesi Sağlık Bilimleri Enstitüsü, İSTANBUL.
- Kim, J., Jung, W., Kim, H., & Lee, J. (2020). CyCNN: A rotation invariant CNN using polar mapping and cylindrical convolution layers. Available form: <https://arxiv.org/abs/2007.10588v1>[Erişim Tarihi 15.10.2024].
- Kingma, D., Rezende, D., Mohamed, S., & Welling, M. (2014). Semi-supervised learning with deep generative models. *Advances in neural information processing systems*, 27.
- Kiranyaz, S., Avcı, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2020). 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, 151(2021), 107398.
- Krešić Corić, M., & Kaštelan, A. (2020). Bullying through the internet - cyberbullying. *Psychiatr Danub*, 32(Suppl.2), 269–72.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1(2012), 1097–1105.

- Langer, M., He, Z., Rahayu, W., & Xue, Y. (2020). Distributed training of deep learning models: a taxonomic perspective. *Ieee Transactions on Parallel and Distributed Systems*, 31(12), 2802-2818.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436444.
- Lee, Y.Y., Chisholm, D., Eddleston, M., Gunnell, D., Fleischmann, A., Konradsen, F.,... van Ommeren, M. (2021). The cost-effectiveness of banning highly hazardous pesticides to prevent suicides due to pesticide self-ingestion across 14 countries: An economic modelling study. *Lancet Glob Health*, 9(3), e291-e300.
- Lew, C.O., Zhou, L., Mazurowski, M.A., Doraiswamy, P.M., & Petrella, J.R. (2023). Alzheimer's disease neuroimaging initiative. MRI-based deep learning assessment of amyloid, tau, and neurodegeneration biomarker status across the alzheimer disease spectrum. *Radiology*, 309(1), e222441.
- Li, B., Bouachir, W., Gouiaa, R., & Noumeir, R. (2017). Real-time recognition of suicidal behavior using an rgb-d camera. *2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA)*, 1-6.
- Live life: an implementation guide for suicide prevention in countries. Geneva: World Health Organization; 2021. Available form: <https://www.who.int/publications/i/item/9789240026629> [Eriřim Tarihi 30.10.2024].
- Mahasseni, B., & Todorovic, S. (2016). Regularizing long short term memory with 3D human-skeleton sequences for action recognition. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3054-3062.
- Mehltretter, J., Fratila, R., Benrimoh, D., Kapelner, A., Perlman, K., Snook, E., ... Turecki, G. (2019). Differential treatment benefit prediction for treatment selection in depression: A deep learning analysis of star*d and co-med data. *BioRxiv*.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A., Veness, J., Bellemare, M., ... Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533.
- Mohod, P. (2024). Real-time violence detection in surveillance videos using deep learning approach. *International Journal for Research in Applied Science and Engineering Technology*, 12(4), 1267-1274.
- Moor, J. (2006). The dartmouth college artificial intelligence conference: The next fifty years. *AI Mag*, 27, 87-87.
- More,P., Patil, S., & Pattanshetti T. (2024). Real time violence and weapon detection and alert system. *Preprint*, <https://doi.org/10.21203/rs.3.rs-4389485/v1>.
- Naghavi, M. (2019). Global, regional, and national burden of suicide mortality 1990 to 2016: Systematic analysis for the global burden of disease study 2016. *BMJ*, 364, 194.
- Neuner, T., Schmid, R., Wolfersdorf, M., & Spiessl, H. (2008). Predicting inpatient suicides and suicide attempts by using clinical routine data. *General Hospital Psychiatry*, 30(4), 324-330.

NVIDIA. Available form: <https://blogs.nvidia.com/blog/2018/08/02/supervisedunsupervised-learning/> [Eriřim Tarihi 18.10. 2024].

Olfson, M., Wall, M., Wang, S., Crystal, S., Liu, S.M., Gerhard, T., & Blanco, C. (2016). Short-term suicide risk after psychiatric hospital discharge. *JAMA Psychiatry*, 73(11), 1119-1126.

Oquendo, M. A., Wall, M., Wang, S., Olfson, M., & Blanco, C. (2024). Lifetime suicide attempts in otherwise psychiatrically healthy individuals. *JAMA Psychiatry*, 81(6), 572-578.

Park, S. U., Park, J. H., Al Masni, M. A., Al Antari, M. A., Uddin, M. Z., & Kim, T. S. (2016). A depth camera-based human activity recognition via deep learning recurrent neural network for health and social care services. *Procedia Computer Science*, 100, 78-84.

Partika, F. (2020). Welcome to the first open source project for real time violence detection. <http://www.violencedetector.org>

Partika, F. B. D. M. (2022). Simple Approach for Violence Detection in Real-Time Videos Using Pose Estimation With Azimuthal Displacement and Centroid Distance as Features. *IJCVIP*, vol.12, no.1, 1-9.

Peixoto, B., Lavi, B., Bestagini, P., Dias, Z., & Rocha, A. (2020). Multimodal Violence Detection in Videos. *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2957-2961.

Peixoto, B., Lavi, B., Martin, J. P. P., Avila, S., Dias, Z., & Rocha, A. (2019). Toward subjective violence detection in videos. *Proceedings of the International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, 8276-8280.

Pico-Alfonso, M. A., Garcia-Linares, M. I., Celda-Navarro, N., Blasco-Ros, C., Echeburúa, E., & Martínez, M. (2006). The impact of physical, psychological, and sexual intimate male partner violence on women's mental health: depressive symptoms, posttraumatic stress disorder, state anxiety, and suicide. *Journal of Women's Health*, 15(5), 599-611.

Polat, O. (2016). řiddet. *Marmara Üniversitesi Hukuk Fakóltesi Hukuk Arařtırmaları Dergisi*, 22(1), 15-34.

Quaak, M., Mortel, L., Thomas, R. and Wingen, G. (2021). Deep learning applications for the classification of psychiatric disorders using neuroimaging data: Systematic review and meta-analysis. *Neuroimage Clinical*, 30, 102584.

Roaldset, J. O. (2016). Listen to the patient – what about patients' perceptions of suicidal risk. *Acta Psychiatrica Scandinavica*, 134(2), 183-183.

Sabrinskas, R., Hamilton, B., Daniel, C. and Oliffe, J. (2022). Suicide by hanging: A scoping review. *Int J Ment Health Nurs*, 31(2), 278-294.

Saęlık Hizmetleri Genel M¼d¼rl¼ę¼. "Saęlıkta Kalite Standartları". Available form: <https://dosyamerkez.saglik.gov.tr/Eklenti/41258/0/skshastane-seti-s-61--09082021pdf>. [Eriřim Tarihi 17.12.2023].

Sauvageau, A., LaHarpe, R., & Geberth, V.J. (2010). Working group on human A-asphyxia. Agonal sequences in eight filmed hangings: analysis of respiratory and movement responses to asphyxia by hanging. *J Forensic Sci*, 55(5), 1278-81.

Scheeder, C., Heigwer, F., & Boutros, M. (2018). Machine learning and image-based profiling in drug discovery. *Curr Opin Syst Biol*, 10, 43-52.

Selçuk, H., Akinci, T., & Seker, S. (2021). Derin evrişimli sinir ağı modellerinin açık kaynak kodlu yazılım platformlarında tasarımının değerlendirilmesi. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1), 94-98.

Sharma, M.K., Anand, N., Thakur, P.C., N, S., Biswas, A., R, A.,... Murthy, K.D. (2021) Cyber violence: Case report evidence of an emerging public health concern. *Asian J Psychiatr*, 57, 102017.

Shotton, J., Sharp, T., Kipman, A., Fitzgibbon, A., & Finocchio, M., Blake, A., Cook, M., & Moore, R. (2013). Real-time human pose recognition in parts from single depth images. *Communications of the ACM*, 56 (1), 116–124.

Slemon, A., Jenkins, E., & Bungay, V. (2017). Safety in psychiatric inpatient care: The impact of risk management culture on mental health nursing practice. *Nursing Inquiry*, 24(4), e12199.

Soliman, M., Kamal, M., Nashed, M., Mostafa, Y., Chawky, B., & Khattab, D. (2019). Violence recognition from videos using deep learning techniques. *Proceedings of the 9th International Conference on Intelligent Computing and Information Systems (ICICIS'19)*, 80-85.

Stylianou, A.M. (2018). Economic abuse within intimate partner violence: A review of the literature. *Violence Vict*, 33(1), 3-22.

Sun, P., Zhang, X., Sun, Y., Ma, H., Jiao, M., Xing, K., ... Yin, M. (2017). Workplace violence against health care workers in north chinese hospitals: A cross-sectional survey. *International Journal of Environmental Research and Public Health*, 14(1), 96.

Sun, S., & Xie, X. (2016). Semisupervised support vector machines with tangent space intrinsic manifold regularization. *Ieee Transactions on Neural Networks and Learning Systems*, 27(9), 1827-1839.

Svensson, J. (2022). Patient safety strategies in psychiatry and how they construct the notion of preventable harm: A scoping review. *Journal of Patient Safety*, 18(3), 245-252.

Sweetser, P., & Aitchison, M. (2020). Do game bots dream of electric rewards? : The universality of intrinsic motivation. *FDG '20: Proceedings of the 15th International Conference on the Foundations of Digital Games*, 30, 1 – 7.

Sy, A., Simon, W., Jude, E., & Jude, C. (2019). Review and proposed management of violence in the secure psychiatric ward. *Examines in Physical Medicine & Rehabilitation*, 2(4).

TİHEK. (2018). Available form: <https://www.tihet.gov.tr/public/images/kararlar/538571.pdf> [Erişim Tarihi 21.12.2024].

TİHEK. (2024). Available form: <https://www.tihek.gov.tr/public/images/kararlar/hidj87.pdf> [Erişim Tarihi 21.12.2024].

Umut, G., Altun, Z.Ö., Danışmant, B.S., Küçükparlak, İ., & Karamustafalıoğlu, N. (2012). Bir eğitim hastanesinde yatarak tedavi gören şizofreni hastalarında tedavi uyumu, içgörü ve agresyon ilişkisi. *Düşünen Adam Psikiyatri ve Nörolojik Bilimler Dergisi*, 25, 212-220.

Vieira, S., Pinaya, W.H., & Mechelli, A. (2017). Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: Methods and applications. *Neurosci Biobehav Rev*, 74(Pt A), 58-75.

Vijeikis, R., Raudonis, V. A., & Dervinis, G. (2022). Efficient violence detection in surveillance. *Sensors*, 22(6), 2216.

Woottluk, P., Maneeton, B., Jaiyen, N., Khemawichanurat, W., Kawilapat, S., & Maneeton, N. (2020). Prevalence and associated factors of suicide among hospitalized schizophrenic patients. *World J Clin Cases*, 26;8(4), 757-770.

World Health Organization. (2002) World Report on Violence and Health. Geneva: WHO. Available form: <https://www.who.int/publications/i/item/9241545615> [Erişim Tarihi 29.08.2024].

World Health Organization. (2014). Preventing suicide: a global imperative. Geneva: World Health Organization. Available form: <https://www.who.int/publications/i/item/9789241564779> [Erişim Tarihi 01.10.2024].

World Health Organization. Suicide. (2024). Available form: <https://www.who.int/news-room/fact-sheets/detail/suicide> [Erişim Tarihi 30.10.2024].

Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *MIT Neural Computation*, 31(7), 1235–1270.

Zhou, P., Ding, Q., Luo, H., & Hou, X. (2018). Violence detection in surveillance video using low-level features. *PLoS ONE*, 13(10), e0203668.

EK_1:

ETİK KURUL İZİNİ



EK_2

KURUM İZNİ



T.C.
İSTANBUL VALİLİĞİ
İl Sağlık Müdürlüğü



Sayı : E-15916306-604.01-236089955
Konu : Ceyda ÖZTÜRK AKDENİZ'in Araştırma
İzni Hk.

İSTANBUL MEDENİYET ÜNİVERSİTESİ REKTÖRLÜĞÜ
(Lisansüstü Eğitim Enstitüsü Müdürlüğü)

İlgi : a) 20.11.2023 tarihli ve E-47464055-100-2300069856 sayılı yazınız.
b) 04.01.2024 tarihli ve E-15916306-604.01-233288105 sayılı yazınız.
c) 16.01.2024 tarihli dilekçe.

Üniversiteniz Rektörlüğü'nün ilgi (a) sayılı yazısında konu olan Lisansüstü Eğitim Enstitüsü Hemşirelik Anabilim Dalı Psikiyatri Hemşireliği Doktora Programı öğrencilerinden Ceyda ÖZTÜRK AKDENİZ'in "**Psikiyatri Kliniğinde Yatarak Tedavi Gören Hastalarda Makine Öğrenmesi Modeli Kullanarak Riskli Davranışlarının Tespiti ve Güvenli Ortamın Sağlanması**" başlıklı tezini yapma talebi Müdürlüğümüze iletilmiş ve ilgi (b) sayılı yazımız ile değerlendirilmeye alınmıştır.

Söz konusu çalışma, Müdürlüğümüz komisyonu tarafından tekrar değerlendirilmiş olup, araştırmacı ilgi (c) sayılı dilekçesi ile başvuru formunda belirtilen **C.8 ve C.14.1 bendinde revize** yapmıştır. Söz konusu revize; **İkinci aşama olarak belirtilen kısımlar çalışmadan çıkartılmıştır. Bu kapsamda kadın psikiyatri kliniği hasta odalarına kamera ve bilgisayar kurulumu yapılmayacaktır. Çalışmanın C.8 ve C.14.1 bendinde ilk aşama olarak belirtilen şekilde tamamlanacaktır. Çalışmanın tüm süreçleri henüz hasta yatışı olmayan erkek psikiyatri kliniğinde yürütülecek olup kadın psikiyatri kliniğiyle temas olmayacaktır.**" şeklinde ifade edilmektedir.

İlgili dilekçe ve başvuru formu komisyonumuz tarafından tekrar değerlendirilmesi neticesinde, Müdürlüğümüz Sağlık Hizmetleri Başkanlığı Araştırma, Basılı Yayın, Duyuru İçeriği Değerlendirme Komisyonunun **16.01.2024** tarih ve **2024 / 01** sayılı kararınca **uygun görülmüştür**. Çalışma bitiminde bir nüshasını elektronik ortamda (CD halinde) Müdürlüğümüze teslim edilmesi gerektiğinin çalışmada adı geçen kişiye tebliği hususunda;

Gereğini bilgilerinize arz ederim.

Prof. Dr. Kemal MEMİŞOĞLU
İl Sağlık Müdürü

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge doğrulama kodu: 8E711735-706F-47DE-AACB-112BC5351F85

Belge doğrulama adresi: <https://www.turkiye.gov.tr/saglik-bakanligi-ebys>

EK_3:

BİLGİLENDİRİLMİŞ GÖNÜLLÜ ONAM FORMU

Psikiyatri Kliniğinde Yatarak Tedavi Gören Hastalarda Makine Öğrenmesi Modeli Kullanarak Riskli Davranışlarının Tespiti ve Güvenli Ortamın Sağlanması” adlı çalışma, makine öğrenmesi modeli kullanarak psikiyatri kliniğinde yatan hastaların şiddet ve intihar davranışlarını tespit etmek amacıyla planlanmıştır. Çalışmanın 01.12.2023-01.12.2024 tarihleri arasında yapılması planlanmaktadır. Çalışmada veriler anket ve video kaydı kullanılarak yapılarak yürütülecektir. Video verileri çalışmaya katılmaya gönüllü tiyatro ve drama oyuncularından toplanacaktır. Anket verileri sağlık çalışanlarından toplanacaktır. Videolardan elde edilen görüntüler sadece araştırma amacıyla kullanılacak olup kişisel görüntüleriniz ve bilgileriniz herhangi bir yerde paylaşılmayacaktır. Çalışmaya katılım tamamen gönüllülük esasına dayanmaktadır. Bu çalışmadan elde edilecek veriler tamamen araştırma amacı ile kullanılacak olup kişisel bilgileriniz gizli tutulacaktır. Eğer araştırmanın amacı ile ilgili verilen bu bilgiler dışında şimdi veya sonra daha fazla bilgiye ihtiyaç duyarsanız araştırmacıya şimdi sorabilir veya mail adresinden ulaşabilirsiniz. Çalışmaya katılmama veya katıldıktan sonra herhangi bir anda çalışmadan çıkma hakkına sahipsiniz. İstemediğiniz eylemleri yapmama hakkına veya istediğiniz an çalışmadan ayrılma hakkına sahipsiniz. Bu durumda hiçbir yaptırıma ve hak kaybına maruz kalmayacağınızı bildirmek isteriz. Ayrıca yapılacak olan çalışmada / araştırmada “Kişisel Verilerin Korunması Kanununun” ilgili maddeleri dikkate alınacağını belirtmek isteriz.

Araştırma Sorumlusu

Ceyda Öztürk Akdeniz

EK_4:

ANKET FORM

Bu çalışma psikiyatri kliniklerinde derin öğrenme yöntemi kullanarak şiddet ve intiharın gerçek zamanlı tespitini hedeflemektedir. Bunun için size şiddet ve intihar davranışı içeren yaklaşık 40-45 dk süresince video kaydı izletilecektir. Bu ankette videolar sırasında meydana gelen davranışların sıralı bir listesi yer almaktadır. Sizden istenilen bilgisayar ekranını takip etmeniz ve her eylemin başlangıç/bitişini dk/sn cinsinden yazmanızdır. Katılım sağladığınız için teşekkür ederim.

GECE (Meydana Gelen Eylem)	Başlangıç	Bitiş
Yatma		
Yüze Yastık Kapama		
Oturma		
Tokat Atma		
Giyinme		
Arkadan Boğazını Sıkma		
Soyunma		
Saç Çekme		
Su İçme		
Yürüme		
Yumruk Atma		
Duvara Dayama		
İtme		
Bir Cisimle Vurma		
İntihar		
Saç Tarama		
Kafa Atma		
Tekme Atma		
Pencereden Bakma		
Boğuşma		

GÜNDÜZ(Meydana Gelen Eylem)	Başlangıç	Bitiş
Yatma		
Bir Cisimle Vurma		
Yürüme		
Saç Çekme		
Saç Tarama		
Konuşma		
Tokat Atma		
Arkadan Boğazını Sıkma		
Su İçme		
Giyinme		
Dışarıya Bakma		
Yumruk Atma		
Yüze Yastık Kapama		
İtme		
Soyunma		
Yemek yeme		
Duvara Dayama		
Tekme Atma		
İntihar		
Kitap Okuma		
Kafa Atma		
Boğuşma		