

**Farelerde Ağrıya Bağlı Yüz İfadesinin Otomatik
Değerlendirilmesi (FARE-MİMİK)**

Program Kodu: 1001

Proje No: 115E248

**Proje Yürütücüsü:
Prof. Dr. Uğur HALICI**

Araştırmacı(lar):

Doç. Dr. Emine EREN KOÇAK

Prof. Dr. İlkay ULUSOY

Prof. Dr. Turgay DALKARA

Bursiyer(ler):

Fourough GHARBALCHI

Yousef Rezaei TABAR

Canan ÇAKIR AKTAŞ

Anisa DEHGHANI

Aslıhan BAHADIR VAROL

HAZİRAN 2018
ANKARA

Önsöz

Farelerde Ağrıya Bağlı Yüz İfadesinin Otomatik Değerlendirilmesi (FARE-MİMİK) projesinde, fare deneylerinde ağrı paradigmaları uygulanarak farelerin yüzlerinde oluşan ağrı mimiklerinin video kayıtlarından otomatik olarak derecelendirilmesini sağlayacak hesaplamalı yöntemlerin geliştirilmesi hedeflenmiştir.

Bu proje ortak doktora programı da açılmış bulunan, Hacettepe Üniversitesi (HÜ) Nörolojik Bilimler ve Psikiyatri Enstitüsü (NBPE) ile Orta Doğu Teknik Üniversitesi (ODTÜ) Fen Bilimleri Enstitüsü (FBE) Nörobilim ve Nöroteknoloji (NSNT) EABD ve Elektrik ve Elektronik Mühendisliği Bölümü'nün (EEMB) nörolojik bilimler ve teknoloji alanlarındaki deneyimleri bir araya getirilerek yürütülmüştür. Proje, TÜBİTAK tarafından 115E248 kodu altında desteklenmiştir.

Proje konusu ile ilgili olarak ODTÜ Elektrik ve Elektronik Mühendisliği Bölümünde iki adet yüksek lisans tezi tamamlanmıştır. Bunlar, Batuhan Akkaya "Mouse Face Tracking Using Convolutional Neural Networks" Tez Danışmanı: Uğur HALICI, ODTÜ, Eylül 2016 ve Mustafa Eral Deep Learning Approach For Laboratory Mice Grimace Scaling Tez Danışmanı: Uğur HALICI ODTÜ, Eylül 2016 tezleridir. Batuhan Akkaya ve Mustafa Eral'a katkılarından dolayı teşekkür ederiz.

İÇİNDEKİLER

TABLO LİSTESİ.....	v
ŞEKİL LİSTESİ.....	vii
Özet.....	x
Abstract.....	xi
SONUÇ RAPORU ANA METNİ.....	1
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ.....	3
3. GEREÇ VE YÖNTEM.....	10
3.1. FARE AĞRI İFADESİ DENEYLERİ.....	10
3.1.1. Deney Ortamı.....	10
3.1.2. Kullanılan Ağrı Modelleri.....	12
3.1.3. Deney Kayıt Prosedürü.....	14
3.1.4. Manuel işaretleme.....	16
3.1.4.1 <i>Yüz Bulma ve Takibi için Manuel İşaretleme</i>	16
3.1.4.2 <i>Ağrı İfadesinin Değerlendirilmesi için Manuel İşaretleme</i>	17
3.2. FARE YÜZÜNÜN TESPİTİ.....	19
3.2.1 Viola Jones Yöntemi İle Fare Yüzü Tespiti.....	19
3.2.2 Derin Öğrenme ile Fare yüzü Tespiti	20
3.2.2.1 <i>Odak alan belirleme</i>	20
3.2.2.2 <i>Yüz Onaylama için Kullanılan Evrişimsel Sinir Ağı</i>	22
3.2.2.3 <i>Odak Alanı Tarama Yöntemi</i>	23
3.3. FARE YÜZÜNÜN VİDEODA TAKİP EDİLMESİ.....	24
3.3.1. Yüz Takibi için Kullanılan Evrişimsel Sinir Ağı Mimarisi.....	25
3.3.2. Yüz takibi için Veri Seti.....	29
3.3.3. Verilerin Çoğaltılması.....	30
3.3.4. Takip için Çevrimdışı Eğitim.....	31

3.3.5. Çevrimiçi Takip.....	32
3.3.6. Tespit ve Takip algoritmalarının Çoklu Kamera için Entegrasyonu.....	34
3.4. FARELERDE AĞRININ OTOMATİK DERECELENDİRİLMESİ.....	36
3.4.1. Ağrı İfadesinin Eğitilmesi için Veri Seti Oluşturulması.....	36
3.4.2. Ağrı Derecelendirme için Kullanılan Evrişimsel Sinir Ağı Mimarisi.....	37
4. BULGULAR.....	41
4.1. FARE YÜZÜNÜN TESPİTİ.....	41
4.1.1 Viola Jones Yöntemi İle Fare Yüzü Tespiti.....	41
4.1.1.1 Viola Jones Sınıflayıcısının Eğitimi.....	41
4.1.1.2 Viola Jones için Sol/Karşı/Sağ Fare Yüzü Eğitme.....	43
4.1.2 Derin Öğrenme ile Fare yüzü Tespiti.....	48
4.1.2.1 Yüz Onaylama için Kullanılan Evrişimsel Sinir Ağı sonuçları.....	48
4.1.2.2 Odak Alanı Tarama Sonuçları.....	50
4.2. FARE YÜZÜNÜN VİDEODA TAKİP EDİLMESİ.....	50
4.2.1 Test için kullanılan ağlar.....	50
4.2.2. Takipçi için Test Prosedürü.....	51
4.2.3. MFT Test Videoları.....	52
4.2.4. MTFN takipçi performansları.....	52
4.2.5. Konvensiyonel takipçilerle karşılaştırma.....	54
4.2.6 Takipçi Sistem Performansı.....	55
4.2.7. Tespit-Takipçi Entegrasyonunda Takipçinin onaylanarak kullanılması.....	56
4.3. FARELERDE AĞRININ OTOMATİK DERECELENDİRİLMESİ.....	58
4.3.1. Ağrı Deneylerinden Veri Toplama ve Etiketleme.....	58
4.3.2 Fare Yüzü Otomatik Ağrı Derecelendirmesi Deneysel Sonuçları.....	61
4.3.2.1 Fare Yüzü Ağrı Derecelendirmesi için Ön Çalışmalar.....	62
4.3.2.2 ODTÜ-HÜ Gözlem Kutusu (6 kamera) Karın Ağrısı Derecelendirme Sonuçları	65
4.3.2.3. Langford Gözlem Kutusu (2 kamera) Deneysel Karın Ağrısı Derecelendirme Sonuçları.....	68
4.3.2.4. ODTÜ-HÜ Gözlem Kutusu (6 kamera) Baş Ağrısı (TBI) Derecelendirme Sonuçları.....	73
5.TARTIŞMA/SONUÇ.....	77

Kaynaklar.....	83
Yayınlar.....	91

TABLO LİSTESİ

Tablo 1. MGS derecelendirmesi.....	19
Tablo 2: FEN, FAN, ve RN ağlarında kullanılan katmanların detayları	27
Tablo 3: Dört MFTN versiyonunda FEN/c, FEN/p, FAN and RN kullanımı	29
Tablo 4. Her bir etiket objesinin karşılık geldiği özellikler	37
Tablo 5. Kullanılan evrişimsel sinir ağların özellikleri.....	39
Tablo 6. VJ Eğitiminde Kullanılan Parametreler.....	41
Tablo 7. VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi.....	42
Tablo 8. VJ Yönteminin Sağ/Sol/Karşı Fare Yüzü için Eğitimdeki Parametreler.....	44
Tablo 9. Sağa bakan fare yüzü grubu için VJ Yönteminin Duyarlılık, Geri-getirme ve F1 Skor değerlerinin minNeighbors sayısına göre değişimi.....	45
Tablo 10. Sola bakan fare yüzü grubu için VJ Yönteminin Duyarlılık, Geri-getirme ve F1 skor değerlerinin minNeighbors sayısına göre değişimi.....	45
Tablo 11. Karşıya bakan fare yüzü grubu için VJ Yönteminin Duyarlılık, Geri-getirme ve F1 skor değerlerinin minNeighbors sayısına göre değişimi.....	45
Tablo 12. Sağ, Sol ve Karşı yüz grupları için ayrı eğitilmiş VJ Yönteminin, birleştirilmiş kümede birlikte kullanımı için performansı karşılaştırılan parametre grupları.....	46
Tablo 13. Sağ, Sol ve Karşı yüz grupları için ayrı eğitilmiş VJ Yönteminin, parametre gruplarına göre birleştirilmiş kümede birlikte başarısı.....	46
Tablo 14. Yüz onaylama ağının performansı	50
Tablo 15. MFTN ve konvensiyonel takipçilerin verimleri.....	56
Tablo 16. Örtüşme için değişik eşik değerlerine göre P, R ve F1 değerlerinin değişimi.....	57
Tablo 17. Altı kameralı ODTÜ-HÜ deney ortamı karın ağrısı deneyleri.....	59
Tablo 18. İki kameralı Langford deney ortamı karın ağrısı deneyleri	60
Tablo 19. Altı kameralı ODTÜ-HÜ deney ortamı baş ağrısı deneyleri.....	61
Tablo 20. Video Segment Uzunluğuna Göre Ağrı Derecelendirme Başarısı.....	62
Tablo 21. Kullanılan ağların ortak bir test kümesi üzerindeki performansı.....	64
Tablo 22. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı.....	65
Tablo 23. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim kümesi üzerinde çift uzman, test kümesi üzerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı.....	66

Tablo 24. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için elde edilen karıştırma matrisi (Tablo 23 için, sayılar her bir satır içinde yüzde olarak verilmiştir).....	67
Tablo 25. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde çift uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı.....	68
Tablo 26. Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı.....	69
Tablo 27. Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim kümesi üzerinde çift uzman, test kümesi üzerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı.....	69
Tablo 28. Langford deney ortamında yapılan karın ağrısı deneyleri için elde edilen karıştırma matrisi (Tablo 27 için).....	70
Tablo 29. Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde çift uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı.....	71
Tablo 30. ODTÜ-HÜ ortamında karın ağrısı üzerinde çift uzman değerlendirmesi yapılan eğitim kümesi ile eğitilen ağın tek uzman değerlendirmeli TBI baş ağrısı test kümeleri üzerinde doğruluk oranı.....	73
Tablo 31. ODTÜ-HÜ deney ortamında kaydedilerek çift uzman değerlendirmesi yapılmış karın ağrısı ve TBI baş ağrısı eğitim verileri ile eğitilen ağın tek uzman değerlendirme yapılmış TBI baş ağrısı test kümesi üzerinde elde edilen doğruluk oranı.....	74
Tablo 32. ODTÜ HÜ ortamının TBI baş ağrısı deneyleri için karıştırma matrisi (Tablo 31 için).....	75
Tablo 33. ODTÜ HÜ deney ortamında kaydedilerek çift uzman değerlendirmesi yapılmış karın ağrısı ve TBI baş ağrısı eğitim verileri ile eğitilen ağın çift uzman değerlendirmesi yapılmış TBI test verisi üzerinde elde edilen doğruluk oranı.....	76

ŞEKİL LİSTESİ

Şekil 1. Farede MGS ölçütüne göre skor verilen yüz bileşenleri (Defensor vd. 2012).....	4
Şekil 2. MGS'deki kodlamaya göre ağrının derecelendirilmesi (Langford vd. 2010).....	4
Şekil 3. Deney Düzeneği: a) Langford vd. (2010) tarafından kullanılan düzenek, b) Projede önerilerek kullanılan 6 kameralı düzenek, c) Projede geliştirilerek cam gözlem kutusunun etrafına yerleştirilen pleksiglas dış kutu.....	11
Şekil 4. Projede geliştirilen dış kutunun fotoğraları a) Altıgen kutunun dıştan görünümü, b) kutu içinde Langford düzeneği, c) Kutu içinde yeni önerilen düzenek, d) Kutunun ışıklandırması.....	12
Şekil 5. Ağırlık düşürme düzeneği ile kafa tramvasının oluşturulması.....	14
Şekil 6. Fare-Mimik Projesi Video Kayıt Yönergesi.....	15
Şekil 7. Fare yüzünün yerinin işaretlenmesi için geliştirilen Grafiksel Arayüz.....	16
Şekil 8. Yüz yerinin ve yönünün hızlı etiketlenmesi için geliştirilen yeni arayüz.....	17
Şekil 9. Video kareleri üzerinde manuel ağrı derecelendirilmesinin yapıldığı ara yüz.....	18
Şekil 10. Seçici arama ile çıkarılan odak bölgeleri.....	21
Şekil 11. Elde edilen gri seviye görüntünün eşiklenmiş hali.....	22
Şekil 12. Önerilen yöntemle elde edilen odak alanı.....	22
Şekil 13. Yüz Onaylama için kullanılan evrişimsel sinir ağının yapısı.....	23
Şekil 14: Geliştirilen Evrişimsel Takipçideki Ağ Mimarisi.....	25
Şekil 15. Önerilen MFTN yapısının detaylı mimarisi.....	26
Şekil 16: Yeşil kare hedef bölgesini, mavi kare ise arama alanını gösterir.....	30
Şekil 17: Orjinal veriden çoğaltılan yapay veriler.	31
Şekil 18. Takipcinin hedefi kaybetmesi örneği.	34
Şekil 19. Videolarda yüzün otomatik bulunması için kullanılan algoritma.....	35
Şekil 20: Fare ağrı değerlendirmesi için geliştirdiğimiz Fare-Mimik-Net'in genel yapısı	38
Şekil 21. Fare-Mimik-Net3 ağının yapısı.....	40
Şekil 22. VJ Yönteminde Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi.....	43
Şekil 23. Sağa bakan fare yüzleri seti için VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi.....	46

Şekil 24. Sola bakan fare yüzleri seti için VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi.....	47
Şekil 25. Karşıya bakan fare yüzleri seti için VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi.....	47
Şekil 26. Sağ Sol ve Karşı yüz setleri için ayrı eğitilmiş VJ Yönteminin, birleştirilmiş kümede birlikte başarısı.....	48
Şekil 27. Eğitim için kullanılan örnek fare yüz kareleri a) Pozitif, b) Negatif.....	49
Şekil 28. Yüz Onaylama ağının eğitimi esnasındaki performans ölçümleri.....	49
Şekil 29. MFTN takipçileri için TP-ROT grafiği	53
Şekil 30. MFTN takipçileri için FR-RT grafiği	53
Şekil 31. MFTN takipçileri için A-R grafiği.	54
Şekil 32. Önerilen MFTN takipçilerinin bilinen takipçilerle karşılaştırılması	55
Şekil 33. Örtüşme için değişik eşik (T) değerlerine göre P, R ve F1 değerlerinin değişimi....	57
Şekil 34. Yığın boyutunun performans üzerindeki etkisi.....	63
Şekil 35. Ağrı Derecelendirme test ve train performansının eğitim iterasyonuna göre değişimi.....	64
Şekil 36. Langford deneyinden örnek kareler.....	72
Şekil 37. 6 kameralı düzeneden alınan örnek kareler.....	72

Özet

Moleküler ağrı mekanizmalarının temellerinin anlaşılmasındaki önemli ilerlemelere ve endüstrideki büyük yatırımlara karşın, ağrı kesici ilaç geliştirme için yapılan temel araştırma ile klinik uygulama arasındaki translasyonel çalışmalardaki başarılar oldukça sınırlı kalmıştır. Bu arayışın önündeki önemli engellerden biri mevcut hayvan modellerindeki sezinlenebilirlik (specifity) başarısının düşük olması, dolayısı ile geliştirilecek ilaçlar için hızlı ve güvenilir bir deneysel tarama testinin bulunmamasıdır.

Bu ihtiyacı karşılamaya yönelik olarak bu projede, fare deneylerinde ağrı paradigmaları uygulanarak farelerin yüzlerinde oluşan ağrı mimiklerinin video kayıtlarından otomatik olarak derecelendirilmesini sağlayacak hesaplamalı yöntemlerin geliştirilmesi hedeflenmiştir. Literatürde Langford ve ekibi (2010) tarafından geliştirilen Fare Yüzburuşturması Derecelendirmesi (Mouse Grimace Scaling, MGS) isimli manuel bir yöntem mevcuttur. Farelerde ağrı mimiklerinin otomatik derecelendirilmesi, hız ve daha tarafsız bir etiketleme başarısının sağlanmasının yanısıra etiketlemeyi manuel olarak yapabilecek uzmanların yetiştirilmesi zorunluluğunu ortadan kaldırmasından dolayı da önem taşımaktadır.

Proje, ortak doktora programı bulunan Hacettepe Üniversitesi (HÜ) ile Orta Doğu Teknik Üniversitesi'nin (ODTÜ) nörolojik bilimler ve teknoloji alanlarındaki deneyimleri bir araya getirilerek yürütülmüştür. Projede HÜ Nörolojik Bilimler ve Psikiyatri Enstitüsü (NBPE) tarafında yapılan çalışmalarda, iki değişik ağrı paradigması kullanılarak farelerde başağrısı ve karın ağrısı yaratılmış, farelerde oluşan ağrıya bağlı yüz ifadeleriyle ilgili video kayıtları toplanmış, ağrı miktarı uzmanlar tarafından manuel derecelendirilerek veri etiketlemesi yapılmıştır. ODTÜ Nörobilim ve Nöroteknoloji (NSNT) - Elektrik ve Elektronik Mühendisliği (EEMB) tarafındaki çalışmalarda ise toplanan video verilerinde fare yüzünün tespit ve takip edilmesini ve yüz ifadelerinden ağrının otomatik derecelendirilmesini sağlamak üzere bilgisayarla görme ve derin öğrenme adı verilen makine öğrenmesine dayalı hesaplamalı yöntemlerin geliştirilmesi yoluna gidilmiştir.

Serbest dolaşan farelerde otomatik ağrı derecelendirmek üzere, bu projede önerilerek geliştirilen 6 kameralı ODTÜ-HÜ gözlem kutusu, farenin hareketlerinin kısıtlandığı 2 kameralı Langford kutusuna göre daha kullanışlı ve başarılı olmuştur. Bu projeye geliştirilen yöntem, farklı ağrıların fare yüz ifadelerinden otomatik tespitinde ve potansiyel ağrı kesicilerin hızlı taranması için translasyonel tıp alanında nesnel, kolay uygulanır ve güvenilir bir yaklaşım getirmesi açısından önem taşımaktadır.

Anahtar Kelimeler: Ağrı, başağrısı, migren, ağrı paradigmaları, farede yüz buruşturma (ağrı) ifadesi, otomatik yüz ifadesi tanıma, bilgisayarla görme, video işleme, makine öğrenmesi, örüntü tanıma, biyomedikal sinyal işleme

Abstract

Despite important improvements in understanding of molecular pain mechanisms and big investments in pain industry, translational success of basic science findings into clinical practice remained limited. One important limitation is the low specificity of the present animal models, and thus, a lack of rapid and reliable experimental tests for screening potential analgesic molecules.

In order to meet this need, this project aims to develop computational methods that automatically grade pain mimics on mouse from video recordings of pain induced mice. In the literature there is a manual method named Mouse Grimace Scaling (MGS) developed by Langford et al. (2010). Automatic scoring of pain mimics in mice is also important because it speeds up and achieves a more neutral labeling success, as well as eliminates the need to train specialists who can do the labeling manually.

The project was carried out by bringing together the expertise of Hacettepe University (HU) and Middle East Technical University (METU) in neurological sciences and technology. Headache and abdominal pain were induced in mice using two different pain paradigms by the HU Institute of Neurological Sciences and Psychiatry (NBPE) group. Video recordings of pain-related face expressions in mice were collected and manually scored by trained experimenters for data labeling. METU Neuroscience and Neurotechnology (NSNT) group developed computational methods based on computer vision and machine learning (deep learning) for mice face detection, tracking and automatic scoring of pain from mice mimics in the video recordings collected.

The 6-camera METU-HU observation box, which was proposed and developed in this project for automatic pain rating in freely moving mice, has been more useful and successful than the 2-camera Langford box, which restricts the movement of mice. The methodology developed by this project provides an objective, easy-to-implement and reliable approach in the field of transcranial medicine for automatic detection of various painful mouse facial expressions and rapid screening of potential painkillers.

Keywords: pain, headache, migraine, pain paradigms, mouse grimace, automatic facial expression recognition, computer vision, video processing, machine learning, pattern recognition, biomedical signal processing

SONUÇ RAPORU ANA METNİ

1. GİRİŞ

Ağrı, pek çok klinik hastalığın tanısında önemli bir belirtidir, ağrının tedavi veya kontrol edilmesi hastanın yaşam kalitesinin artırılması için büyük önem taşımaktadır. Tıptaki birçok hastalık ağrıya yol açmaktadır. Bu hastalıkların altında yatan mekanizmaları inceleyen çalışmalarda hayvan modellerinden faydalanılmaktadır. Bu nedenle, ağrının hayvanlarda güvenilir biçimde ölçülebilmesine imkan veren modellere ihtiyaç vardır. Bu modeller sayesinde ilaçların ağrı kesici özelliği hızlı taranabilir. Langford ve ark. (2010) fare mimiklerinden ağrıyı manuel derecelendirilmesi için bir ölçek (Mouse Grimace Scale, MGS) geliştirmişlerdir. MGS ölçeği araştırmacının uzun süreli eğitimini gerektirmesi, çok vaktini alması ve öznel olması gibi dezavantajlara sahiptir. Bu projede, Langford ve arkadaşlarının geliştirdiği yöntemin her aşamasının, yani farelerde ağrıya bağlı yüz ifadesinin otomatik olarak bilgisayarla değerlendirilmesi amaçlanmıştır.

MGS kılavuzuna göre, ağrı değerlendirmesi için beş adet yüz aksiyon birimi uzmanlar tarafından manuel olarak incelenmektedir [5]. Ancak, insan değerlendirmesinin zaman, maliyet ve tekrarlanabilirlik ile ilgili belirli kısıtlamaları vardır. MGS'nin otomatikleştirilmesi bu içsel sınırlamaların üstesinden gelmek için önemlidir. FARE-MİMİK projesinde, fareler üzerindeki ağrı deneyleri sırasında kaydedilen videoların her bir karesi için ağrı derecesini otomatik olarak değerlendiren bir sistemin geliştirmesi amaçlanmıştır. Geliştirilen sistemin üç ana bileşeni vardır: 1) fare yüzü tespiti, 2) fare yüzü takibi ve 3) MGS'ye göre ağrı derecesinin otomatik değerlendirilmesi.

Son zamanlarda, derin öğrenme, yapay zekanın makine öğrenmesi alanında en popüler yöntemlerden biri haline gelmiştir. Makine öğrenmesindeki en zorlu kısım öznitelik çıkarılmasıdır. Derin öğrenme yaklaşımında kullanılan öznitelikler örnek verilerden otomatik çıkarıldığı için, derin öğrenme bir çok alanda verimli bir şekilde kullanılabilir. Nesne algılama ve tanıma, konuşma tanıma, dil çevirisi, poz tahmini, görüntü bölütleme, görüntü stilizasyonu, görüntü sınıflandırması, davranış anlama ya da nesne takibi gibi farklı alanlarda derin öğrenme başarı ile kullanılmaya başlanmıştır. Bu projede, fare yüzü tespiti, takibi ve ağrı derecesinin otomatik değerlendirilmesi için derin öğrenme yaklaşımı kullanılmıştır.

Literatürde, fare ve sıçanlarda yüzün yerinin otomatik tespiti için bir çalışma yapılmıştır (Sotocinal vd 2011). Ancak, sonrasında MGS ve RGS (Rat Grimace Scale) ölçütleri


uzmanlar tarafından elle derecelendirilmiştir. Ağrı ifadesini derecelendirmek üzere otomatik yöntem kullanılması ilk kez ekibimizdeki çalışmalar sonucunda yayımlanmıştır (Eral vd, 2016). Bunun yanısıra, fare yüzü takibi ile ilgili bir konferans bildirimiz (Akkaya vd. 2016) ve bir uluslararası dergi makalemiz (Akkaya ve Halici, 2018) yayımlanmıştır. Konuyla ilgili ODTÜ Elektrik Mühendisliğinde, fare yüzü takibi (Akkaya 2016) ve fare yüzü ağrı derecelendirmesi (Eral 2016) üzerine iki yüksek lisans tezi tamamlanmıştır. Bu çalışmalarımızın tümünde derin öğrenme kullanılmıştır. Bu çalışmaların daha sonrasında fare yüzünde ağrının derin öğrenme ile otomatik değerlendirilmesine yönelik bir çalışma literatürde yayımlanmıştır (Tuttle vd. 2018), ancak bu çalışmada ağrı yalnızca var/yok biçiminde ele alınmış, derecelendirilmemiştir. Otomatik ağrı derecelendirmek üzere, bu projede önererek geliştirdiğimiz 6 kameralı ODTÜ-HÜ fare ağrısı gözlem kutusu, 2 kameralı Langford kutusuna göre daha kullanışlı ve başarılı olmuştur.

2. LİTERATÜR ÖZETİ

Temel arařtırmalar, insanlar üzerinde yapılmasındaki sakıncalar dolayısı ile sıklıkla hayvanlar üzerinde yapılan alıřmaları ierir (Stanley ve Paice, 1997). Moleküler ađrı mekanizmalarının temellerinin anlařılmasındaki byk ilerlemelere ve endstrideki nemli yatırımlara karřın, ađrı kesici ila geliřtirmedeki temel arařtırma ile klinik uygulama arasındaki translasyonel bařarılar olduka sınırlı kalmıřtır. Bunun nemli sebeplerinden biri ađrı iin mevcut hayvan modellerindeki dřk sezinlenebilirlik (specifity) bařarısıdır (Mogil 2009). Diđer yandan, ađrı kesici ila geliřtirmede canlı hayvan arařtırmaları ana dayanak olmaya devam etmektedir (Mogil ve Crager 2004, Mogil, Simmonds ve Simmonds 2007). Son zamanlardaki birok arařtırma, laboratuvar hayvanlarındaki ađrı testi paradigmalarının yeniden incelenmesine ynelmiřtir. Kemirgen (rodent) ađrı duyarlılıđı ile ilgili klinik ncesi arařtırmalardaki mevcut durumla ilgili en nemli ortak eleřtirilerden biri, bu alıřmaların klinik aıdan nemli olan spontan ađrının incelenmesi yerine termal ve mekanik uyaranlardan kaınmanın llmesine ynelik olmasıdır. Kemirgen davranıřlarından bir kısmı zaman iinde spontan ađrı yarattıđı varsayılan yaralanmalarla korele edilmiř olsa da, birok durumda bu davranıřların ađrı lt olarak sezinlenebilirlik (specifity) ve duyarlılık (sensitivity) sergilediđinin gsterilmesi zorluk tařımaktadır (Mogil, Davis ve Derbyshire 2010). Biyomedikal arařtırmalarda ađrının yz ifadelerinden gvenilir bir biimde tespit edilebilir olduđu gsterilmiřtir (Prkachin 1992, Craig, Prkachin ve Grunau 2001). Ekman ve Friesen (1978) tarafından, grnr yz ifadelerinin bunu oluřturan kas hareketlerine ayrıřtırılabilmesini sađlayan Yz Aksiyonu Kodlama Sisteminin (Facial Action Coding System, FACS) geliřtirilmesiyle ađrı ifadeleri ile ilgili alıřmalar hız kazanmıřtır. İnsan yz aksiyonu kodlama sistemine dayalı olarak geliřtirilen insan yz ađrı kodlama dereceleri insanlarda ađrının szel bilgi olmadan derecelendirilmesi iin klinikte faydalı olmaktadır (Williams, 2002). FACS'a dayalı olarak Prkachin and Solomon (2008) tarafından geliřtirilen PSPI lt (Prkachin and Solomon Pain Intensity metric) ađrının yz ifadelerinden manuel tespitinde kullanılması geerlenmiř bir yaklařımdır.

Hayvanlarda da insana benzer biimde duygusal durumlara iliřkin yz ifadelerinin sergileneceđi ok nceden Darwin (1872) tarafından ifade edilmiřtir. ok yeni bir alıřmada ise fareler üzerinde eřitli modellerle ve farklı trlerde ađrı (peritonit, migren vb.) oluřturularak farelerin davranıřları videoya kaydedilmiřtir (Langford vd. 2010). Bu videolardan alınan karelerde fare yz ifadeleri incelenerek ađrı ifadeleri karakterize edilmiř ve MGS lđi geliřtirilmiřtir. MGS'de orbital kasılma, burun kabarıklıđı, yanak kabarıklıđı, kulak pozisyonu ve bıyıklarda deđiřim olmak zere beř aksiyon birimi yer almaktadır (řekil

1). Videolardan alınan karelerde bu aksiyon birimlerinin durumu, normal ve ağrılı durumları nitelemek üzere uzmanlar tarafından 0, 1 ve 2 olmak üzere derecelendirilmiştir (Şekil 2).



Şekil 1. Farede MGS ölçütüne göre skor verilen yüz bileşenleri (Defensor vd. 2012)



Şekil 2. MGS'deki kodlamaya göre ağrının derecelendirilmesi (Langford vd. 2010)

Geliştirilen bu ölçeğin yüksek doğruluk ve güvenilirlik sergilediği, birkaç dakikadan bir güne kadar uzayan sürelerde ağrının ölçülmesinde faydalı olduğu ve zayıf ağrı kesici ilaçların etkilerine duyarlı olduğu gözlenmiş ve hayvanların ağrıya verdikleri tepkilerde bir ölçüt temsil edeceği gösterilmiştir. Aksiyon birimlerinin durumuna göre ağrının nasıl derecelendirildiği ile ilgili detaylara grubun hazırladığı MGS el kitabından ulaşılabilir. Bu yöntemin en çok eleştiri alan tarafı, yüzü daha iyi görüntüleyebilmek amacıyla farelerin hareketlerini sınırlayan bir kutuya konmaları, video kayıtlarının bu koşullarda alınmasıdır. Hareketsizliğin farelerde strese neden olduğu çok iyi bilindiğinden, bu yaklaşım skorlanan mimiklerin ağrıyla mı, hareketsiz kalma stresiyle mi ilgili olduğunun tam olarak anlaşılamayacağı şeklinde eleştirilmektedir. Aynı grup tarafından yapılan daha sonraki bir çalışmada ise MGS deneyleri sıçanlar için uyarlanarak Sıçan Yüz Buruşturma Ölçeği (RGS) geliştirilmiştir (Sotocinal vd. 2011). MGS ve RGS ölçütleri halihazırda hayvanlar üzerindeki deneysel ağrı çalışmalarında kullanılmaya başlanmıştır (Defensor vd. 2012, Spinka 2012, Leach vd. 2012, Makowska ve Weary 2013, Karataş vd. 2013, Whittakera ve Howarth 2014).

İnsanda yüz ifadelerinden ağrının otomatik olarak tespit edilmesi son zamanlarda üzerinde çalışılmaya başlanan bir konudur. Klinik veya deneysel fayda için ağrı derecesinin doğru ölçülmesi gerekmektedir. Hem spontan ağrı için makine öğrenmesinde kullanılacak veri toplamadaki zorluklar hem de klinikteki gerçek kullanım ortamında yüz özellik bölgelerinin bölütlenmesi ve analizindeki zorluklar yüz ifadesinden ağrının otomatik tespiti konusunda zorluk teşkil etmektedir. UNBC-McMaster Ağrı Arşivi, klinik ortamda akut ağrı indüksiyonu sırasında kaydedilmiş ve iyi annotate edilmiş yüz ifadesi görüntülerine ihtiyaç olduğunu duyurmuştur. UNBC ve diğer veri kaynakları kullanılarak, ağrının varlığını tespit

etmek üzere birçok yaklaşım önerilmiştir (Monwar ve Siamak 2006, Littlewort, Bartlett ve Kang 2007, Ashraf vd. 2009, Lucey vd. 2011, Hammal 2009, Hammal ve Cohn 2012, Hammal ve Kunz 2012). AAM yöntemi (Active appearance models, Cootes vd. 1998), biyolojik bazlı öznitelikler yüz görüntüsünden yüz ifadesine ilişkin öz nitelik çıkarmak için kullanılmıştır (Martins 2008). Ağrı sınıflaması için K-NN (K-Nearest Neighbor Classifier) (Patil vd. 2012, Kim vd. 2014, Shoail ve Bhattacharya 2007, Wen ve Zhan, 2008, Suja 2014), SVM (Support Vector Machines) (Kostia ve Pitas, 2005, Patil vd. 2012, Bartlett vd. 2003, Bartlett vd. 2014, Kotsia vd. 2007, Lei vd. 2009), MLP(Multi-Layer Perceptron) (Cottrell ve Padgett, 1996) ve bazı kural bazlı metodlardır (Khanam vd. 2008, Pantic ve Rothkrantz 2000, Pantic ve Rothkrantz 2004, Mufti ve Khanam 2006). Bu yöntemlerle elde edilen sınıflandırma başarısı %60 ile %80 arası değişmektedir. Bazı çalışmalarda PCA (Principal Component Analysis) gibi boyut düşürme yöntemleri de kullanılarak bu başarı yüzdesi biraz daha arttırabilmiştir. Evrişimsel derin nöral ağlar ile yapılan çalışmalar ise son yıllarda gerçekleşmiştir. Bu ağlarla yapılan insanlarda yüz ifadesi kategorize etme deneylerinde %80 ile %95 arası başarı elde edilmiştir (Aifananti vd. 2010, Li vd. 2015, Hai vd. 2015, Sobral vd. 2014).

Yapay sinir ağları, biyolojik sinir hücrelerinden esinlenerek ortaya çıkmış, makine öğrenmesi kullanılarak sınıflandırma ve fonksiyon kestirimi yapma gibi işlerde yaygınca kullanılır hale gelmiş bir yaklaşımdır. Bu ağların eğitilmesi görece karmaşık bir süreçtir ve yüksek miktarda hesaplama gücü gerektirmektedir. Son yıllarda bilgisayarların önemli bir biçimde artan sayısal hesaplama gücü ve yeni yöntemler sayesinde bu ağları eğitme işi görece kolay hale gelmiştir.

LeCun ve ark. (1990) tarafından önerilen Evrişimsel sinir ağları (Convolutional Neural Networks, CNN), son yıllarda yoğun ilgi çekmektedir. Eğer öğretilecek veriler görüntü bazlı veriler ise, bu durumda derin bir yapay sinir ağı olan Evrişimsel Sinir Ağları(CNN), sığ ağlar olarak da adlandırılan klasik çok katmanlı sinir ağlarına göre daha iyi sonuçlar vermektedir. Bu ağlar nesnenin ya da parçalarının görüntü içerisinde konum değişimini tolere edebilmektedir. Aynı zamanda çok katmanlı klasik sinir ağlarına göre daha az değişken içerdiklerinden eğitilmesi daha az zaman almaktadır.

VGG-CNN-F (Simonyan ve Zisserman, 2014) ve AlexNet (Krizhevski vd., 2012) hayvanların, bitkilerin, gıdaların ve enstrümanların da dahil olduğu 1000 farklı sınıfın kabaca 1,2 milyon görüntüsünü içeren ImageNet veri seti (Russakovsky vd., 2015) ile eğitilmiş, iyi bilinen iki CNN'dir. Her iki ağ da bu veri kümesinde benzer hata oranları elde etmektedir. Birçok görüntü işleme uygulamasında, özellikle uygulamaya özgü veri kümesinin boyutu yeterince büyük değilse, önceden eğitilmiş VGG-CNN-F veya AlexNet'in evrişimsel katmanları, genelleştirilmiş bir öznitelik çıkarıcı olarak kullanılmaktadır. Bu nedenle,

ImageNet'te eğitilen konvolüsyon tabakalarının ağırlıkları ilk ağırlık olarak kullanılıp, daha sonra uygulamaya özel veri kümesi ile eğitilerek bu ağırlıklar daha iyi ayarlanmaktadır. VGG-CNN-F ağı hızlı eğitim ve çıkarım için geliştirilmiştir.

Geri Yayılım Algoritması (Rumelhart vd. 1986) derin ağları da eğitmede kullanılan yaygın bir yöntemdir. Ancak klasik yapıdaki tam bağlantılı çok katmanlı ağları eğitmek katman sayısı arttıkça zorlaşmaktadır. Bir katmandaki her bir nöron, komşu katmanlardaki her bir nörona bağlı olduğundan eğitilecek parametre sayısı artan katman sayısı ile beraber hızlı bir şekilde artmaktadır. Dahası, bu ağlar görüntü gibi girdilerdeki pikseller arası uzamsal ilişkiyi dikkate almaz, her bir piksele diğeriyle aynı davranır. Örneğin bir çerçevede göz ile alakalı bir özelliği çıkartmaya çalıştığımızda, göz ve çevresindeki pikseller ile ağız kenarındaki pikseller arasındaki korelasyon, gözün kenarındaki piksellerin kendi arasındaki korelasyon ile aynı kabul edilir.

Tam bağlı ağların aksine evrimsel ağlarda nöronlar komşu katmanlardaki her bir nörona bağlı değildir. Bir evrimsel katmandaki nöron, kendisinden önceki katmandaki nöronlara bölgesel olarak bağlanır. Örneğin ilk evrimsel katmandaki her bir nöron, girdi resmindeki belirli bölgelere bölgesel alıcı nöronlarla bağlıdır. Bu bölgesel alıcılardaki tüm nöronlar aynı bağlantı ağırlıklarını ve eşik değerlerini paylaşırlar. Bu şekilde bir bağlantı mantığı aranılan örüntünün resim içerisinde uzamsal bağımsızlığını sağlar (LeCun vd. 1998).

Görüntüler üzerinde otomatik fareyüzü ağı derecelendirmesi yapılabilmesi için fare yüzünün görüntüdeki yerinin bulunması gerekmektedir. Literatürde insan yüzünün otomatik tespiti ile ilgili bir çok çalışma bulunmaktadır. Bunlar arasında en bilinen yöntem Viola ve Jones (2001) tarafından geliştirilendir. Doğal ortamda (in the wild) yüz tespiti henüz tam çözülebilmemiş bir problem değildir, bir çok çalışma halen devam etmektedir. (Liao vd. 2015, Kumar vd. 2015, Yu vd. 2016, Wan vd. 2016, Yang vd. 2015). Doğal ortamda insan yüzü tespiti için de son yıllarda derin öğrenme önem kazanmış, başarılı sonuçlar alınmıştır (Chen vd. 2015, Zhang vd. 2016, Yang S vd 2015, Yang B vd 2015, Ranjan vd 2015, Ranjan vd 2016, Jiang ve Learned-Miller 2016, Li vd. 2016).

Video görüntüleri peşpeşe gelen çok sayıda video çerçevesinden oluşmaktadır. Videolarda fareyüzü ağı derecelendirmesi yapılabilmesi için, tek tek her bir video karesinde fare yüzünün manuel tespit edilmesi çok zaman alıcı bir işlemdir. Otomatik olarak tespit yapılırsa da, yine her bir karede tek tek tespit yapmak da zaman alıcıdır. İşlemin hızlandırılması için belirli karelerde yeri belli olan yüzlerin daha sonraki video karelerinde takip edilmesi gerekmektedir.

Takipçilerde, genellikle oluşturucu ve ayırıcı olmak üzere iki farklı yaklaşım kullanılmaktadır. Oluşturucu yaklaşımlı takipçiler, hedef bölge etrafında muhtemel hedef bölgeleri oluşturmakta ve bu muhtemel hedef bölgelerden en uygun olanını hedef noktası

olarak belirlemektedir. Ayırıştırıcı yaklaşımlı takipçiler ise verilen görüntü üzerinde hedef ve arkaplanı birbirinden ayırt ederek hedefin yeni yerini tahmin etmektedir.

Literatürde videolarda nesne takibi için çok sayıda yayın bulunmaktadır. Son senelerde Derin Öğrenme algoritmaları nesne takibinde kullanılmaya başlanmış, diğer yöntemlere göre daha yüksek başarı elde edilmiştir. 2013 yılından bu yana her yıl düzenlenen VOT (Visual Object Tracking) yarışmasında, bu yarışmaya katılan takipçi yöntemleri değişik özellikteki videolar üzerinden test edilmektedir. Derin öğrenmeye dayalı nesne takipçileri ilk kez 2015 yılındaki yarışmada yer almıştır. Bu yarışmada, isimleri MDNet (Nam ve Han, 2015), DeepSRDCF (Li vd. 2014) ve SODLT (Wang vd. 2015) olmak üzere derin öğrenme yöntemlerinden Evrışimsel Sinir Ağları'nı kullanan üç tane takipçi yer almıştır. Yarışmaya katılan 62 takipçi arasında bölge örtüşmesi başarı ölçütüne göre yapılan sıralama MDNet birinci, DeepSRDCF ise ikinci olmuştur.

Literatürde yer alan derin öğrenmeye dayalı takipçilerde çoğunlukla oluşturucu takipçi tercih edilmiştir. Wang ve Yeung (2013) tarafından geliştirilen takipçide 1 milyon küçük görüntü ile eğitilen istiflenmiş otomatik kodlayıcı öznelik çıkartıcı olarak kullanılmıştır. Bu ağ yapısını kullanarak çevrimiçi eğitim sayesinde hedefe adapte olan bir oluşturucu yaklaşımlı takipçi geliştirilmiştir. Hong vd. (2012) tarafından geliştirilen takipçide daha önceden eğitilmiş bir evrışimsel yapay sinir ağı öznelik çıkarıcı olarak kullanılmıştır. Bu öznelikler ile kodlanan görüntülerden SVM algoritması ile muhtemel pozitif görüntüler ayırıştırılmış ve yine yapay sinir ağı yardımıyla görsel çekicilik haritası çıkartılarak hedefin konumu belirlenmiştir. Pozitif görüntülerle SVM destek vektörleri çevrimiçi olarak güncellenmiştir. Li vd. (2014) tarafından geliştirilen takipçide de evrışimsel yapay sinir ağı kullanılmıştır. Fakat bu modelde herhangi bir çevrimdışı eğitim yapılmamıştır. Ağ, gelen ilk görüntüden itibaren bulunduğu hedefleri pozitif, hedefe uzak bölgeleri negatif alanlar kabul ederek çevrimiçi eğitim yapmaktadır. Bu yöntemlerden farklı olarak, Held vd. (2016) tarafından geliştirilen takipçide oluşturucu yaklaşım kullanılmamakta ve çevrimiçi eğitim yapılmamaktadır. Bu yöntem ayırıcı yaklaşım uyguladığı ve tamamen çevrimdışı eğitildiği için diğer yöntemlere göre ciddi ölçüde hız avantajı sağlamıştır. Bu takipçi genel bir takipçidir ve gündelik hedeflere ağırlık verecek şekilde eğitilmiştir.

Konvensiyonel takipçiler çoğunlukla ayırıcı yaklaşımı kullanmaktadırlar. Ayırıcı korelasyon filtreler (DCF), hedef takip uygulamalarında iyi performans göstermektedir. Ancak, DCF tek-çözünürlüklü özneliklerle sınırlıdır. Danelljan vd (2012), C-COT takipçide, farklı çözünürlüklere sahip çoklu özneliklerden bir evrışim operatörünü öğrenmek için bir yöntem önermişlerdir. Bu özellikler, hedef için bir güven haritası oluşturmak için kullanılmıştır. Birçok takipçi yönteminde, hedef model güncellenirken arka plan bilgileri de dikkate alınır. Li vd. (2015) RPT yönteminde, hedefe ait olan güvenilir kısımları tanımlamak ve kullanmak için

bir yöntem önermişlerdir. Arka plana ek olarak, bozuk örnekler de takipçi eğitimini etkileyebilir. Danelljan vd. (2015, 2016), SRDCFdecon takipçide, SRDCF takipçinin performansını arttırmak için örnek niteliği tahminini model güncellemesine dahil etmişlerdir. KCF (Henriques vd, 2015), en hızlı ve en iyi performans gösteren takipçilerden biri olan bir korelasyon tabanlı takipçidir. Ancak, kullanılan sabit şablon boyutu performansı sınırlamaktadır. Li ve Zhu (2014), SAMF takipçide farklı ölçeklerle hedefi örnekleyerek, KCF takipçi performansını iyileştirmişler.

Takip için derin öğrenme algoritmalarını kullanan yöntemler incelendiğinde, çoğunlukla üretici yaklaşımların uygulandığı görülmektedir. Literatürde ilk derin öğrenme kullanan takipçi (Wang ve Yeung, 2013), bir yığıtlı oto kodlayıcı (Stacked Auto Encoder, SAE) ağına dayanmaktadır. Bu takipçide, hedef olma olasılığı SAE tarafından hesaplanmaktadır. Daha sonra, bu olasılık kullanılarak, hedef konum bir parçacık filtresi ile belirlenmiştir. Chen vd (2016) tarafından SAE yerine CNN kullanılmış ve daha iyi performans elde edilmiştir.

Bazı çalışmalar, takipçiler için derin sinir ağlarının öznetelik çıkarma yeteneklerini kullanmıştır. Ma vd. (2015) tarafında yapılan çalışmada CNN tarafından çıkarılan öznetelikler, korelasyon filtrelerini eğitmek ve hedef konumlarını belirlemek için kullanılmıştır. Hong vd. (2015), CNN ve destek vektör makinesi (SVM) kullanan bir takipçi yöntemi önermişlerdir. CNN, SVM tarafından seçilen parçalar ile eğitilmiştir. CNN'in, farklı katmanları farklı hiyerarşik özellikleri öğrendiğinden dolayı farklı bilgiler içermektedir. FCNT'de (Wang vd., 2015), hedefi takip etmek için düşük ve yüksek seviyeli öznetelikler, bir seçme mekanizması ile birleştirilmiştir. Li vd. (2016) tarafından yapılan çalışmada takip için, paylaşılan ve alana özgü iki ağ grubunu birleştirerek derin bir sinir ağı oluşturulmuştur. Paylaşılan ağlar çevrimdışı olarak eğitilip bağlantı ağırlıkları doğrudan takipçi ağına aktarılmıştır. Alana özgü ağ ise çevrimiçi eğitilmiştir.

Literatürde yapılan pek çok çalışmada, transfer-öğrenme yaklaşımı, doğrudan bağlantı ağırlıkları aktararak kullanılmıştır. Ancak, Wang vd. (2015) öğrenilen özellikleri yeni video dizilerine uyarlamak için bir alan uyarlama modülü önermişlerdir. CNN'leri eğitmek çok sayıda eğitim örneği gerektirmektedir. Bu sorunun üstesinden gelmek için Li vd. (2014) sadece çevrimiçi olarak eğitilen bir CNN tabanlı takipçi önermiştir. Nöral ağ tabanlı üretici takipçiler yüksek performansa sahip olsalar da, çevrimiçi eğitim ve ayrıca çok sayıda hesaplama nedeniyle çok yavaşlardır.

Ayırıcı yaklaşımı kullanan sadece birkaç sinir ağı izleyicisi vardır. Wang vd. (2017) tarafından yapılan çalışmada, hedef konumu, genel nesne tespiti için çevrimdışı olarak eğitilen ve çevrimiçi takip sırasında ayarlanan bir CNN kullanılarak bulunmaktadır. Held vd.

(2016) tarafından önerilen GOTURN, tek bir ileri geiř ile takip etmek iin tamamen evrimdiři olarak eđitilen bařka bir ayrımcı takipidir. İki ardarda video karesinden semantik zellikleri ıkarmak iin iki nceden eđitilmiř zdeř ađ kullanılmıřtır. Hedefin bu zelliklerin birleřiminden bulunması iin ek bir tam bađlantılı ađ kullanılmıřtır. GOTURN, 100 fps'de alıřabilen son teknoloji bir takipi olarak bilinmektedir. Genel olarak, nral ađ tabanlı izleyiciler, evrimii eđitim nedeniyle 0.8 FPS'den 15 FPS'ye kadar hızla alıřmaktadırlar.

Literatrdeki alıřmalara bakıldıđında hem nesne tespiti ve takibi hem de insan yz ifadesi zerine yapılan alıřmalarda son yıllarda derin renmenin kullanılmaya bařlandıđı ve derin renmeye dayalı yntemlerin diđer yntemlere gre daha bařarılı olduđu gzlenmiřtir. Dolayısı ile bu projede geliřtirilen yntemlerde de Derin renme kullanılmasına karar verilmiřtir.

3. GEREÇ VE YÖNTEM

3.1. FARE AĞRI İFADESİ DENEYLERİ

3.1.1. Deney Ortamı

Fare ağrı deneyleri için deney ortamı Hacettepe Üniversitesi Nörolojik Bilimler ve Psikiyatri Enstitüsü, Davranış Deneyleri Araştırma Laboratuvarı'nda oluşturulan ortamda kaydedilen fare videolarından oluşturulmuştur. Proje kapsamında veri seti oluşturmak için farenin bazal durumda olduğu (ağrılı uyarın verilmeden önce) ve ağrılı olduğu 2 farklı türde video kaydedilmiştir. İki tür video da fare yüz takibi algoritmasının eğitiminde kullanılmaktadır. Fare yüzünde ağrının otomatik derecelendirilmesi için geliştirilen yöntemde ise sadece farenin ağrılı olduğu videolar kullanılmıştır. Fakat farenin bazal durumda olduğu videolarda fare daha hareketli olduğundan, bu türdeki videolar takipçi algoritması için daha değerli bilgiler içermektedir.

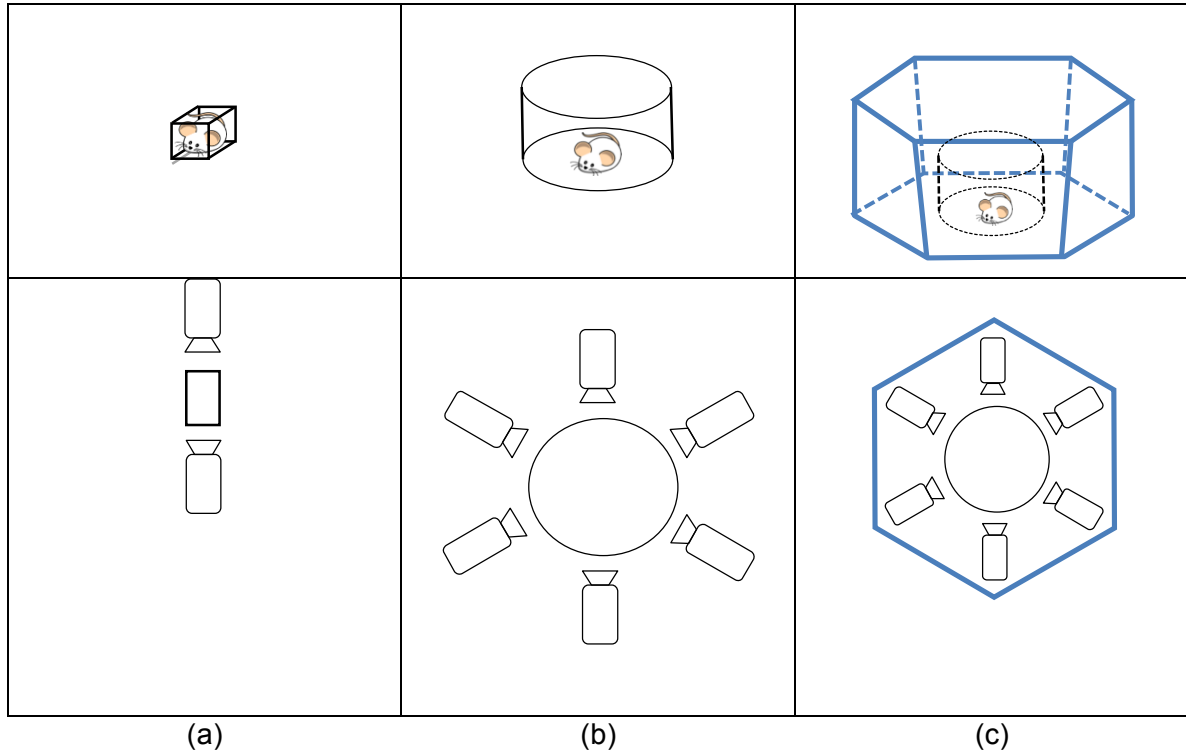
Fare ağrı deneyleri sırasında çekilen videolar UHD (3840 x 2048) çözünürlüğünde 25 FPS hızla kaydedilmiştir. Farenin bazal durumda olduğu videolar 30 dakika uzunluğunda iken, farenin ağrılı olduğu videoların uzunluğu 45 ile 60 dakika arasında değişebilmektedir. Farenin zamana bağlı ağrı değişiminin incelenmesi için videolar aralıksız olarak çekilmiştir.

HÜ NBPE tarafından farelerde ağrıya bağlı yüz ifadeleriyle ilgili veri toplamak üzere yapılan deneylerde, MGS el kitabında açıklanan benzer deney ortamı koşulları sağlanmıştır (Langford vd. 2010). Kamera kayıtları için iki farklı gözlem kutusu kullanılmıştır:


- 1. Langford 2 kameralı ortam:** Langford ve ark. (2010) tarafından MGS el kitabında tanımlanan düzendir (Şekil 3.a). 9x5x5 cm boyutlarında şeffaf pleksiglas kübik kutu içine yerleştirilen farelerin video kayıtları prizmanın iki ucuna yerleştirilen birer kamera ile alınmıştır. Bu düzenek, yüzü daha iyi görüntüleyebilmek amacıyla farelerin hareketlerini sınırlamaktadır. Dolayısıyla skorlanan mimiklerin ağrıyla mı, hareketsiz kalma stresiyle mi ilgili olduğunun tam olarak anlaşılamayacağı şeklinde eleştirilmektedir.
- 2. ODTÜ-HÜ 6 Kameralı Ortam:** Projede önerilerek geliştirilen düzendir (Şekil 3.b). 18 cm çaplı silindirik biçimindeki cam kaba yerleştirilen farelerin video kayıtları silindirik kabın etrafına eşit aralıklarla yerleştirilen 6 kamera ile alınmıştır. Lanford kutusunun aksine, bu düzende farelerin serbestçe dolaşmalarına izin verilmektedir. Bu da Langford kutusunun kullanımıyla ilişkili kısıtlılığın aşılması için önemlidir.

Bu projede ağrı derecelendirmesinin otomatik yapılması hedeflendiğinden ışık koşullarının değişmemesi önem taşımaktadır. Projenin ilk döneminde karşılaştığımız en önemli

sorunumuz deneyin yapıldığı laboratuvarında ışık koşullarının değişkenliği olmuştur. Işık koşullarını standart hale getirmek üzere projenin sonraki aşamalarında içten ışıklandırılmalı kapalı altıgen pleksiglas dış kutu kullanıma sokularak optimize edilmiştir (Şekil 3.c). Optimize ederek kullandığımız altıgen kutunun fotoğrafı Şekil 4'de almaktadır. 2 kameralı Langford gözlem kutusu ve 6 kameralı ODTÜ-HÜ gözlem kutusu kullanılarak yapılan deneylerde, bu gözlem kutuları optimize ışıklandırılmış altıgen kutu içine yerleştirilerek kamera kayıtları alınmıştır.



Şekil 3. Deney Düzeneği: a) Langford vd. (2010) tarafından kullanılan düzenek, b) Projede önerilerek kullanılan 6 kameralı düzenek, c) Projede geliştirilerek cam gözlem kutusunun etrafına yerleştirilen pleksiglas dış kutu.



Şekil 4. Projede geliştirilen dış kutunun fotoğraları a) Altıgen kutunun dıştan görünümü, b) kutu içinde Langford düzeneği, c) Kutu içinde yeni önerilen düzenek, d) Kutunun ışıklandırması

3.1.2. Kullanılan Ağrı Modelleri

Projede iki tür ağrı modeli kullanılmıştır:

1. **Karın Ağrısı:** Karın ağrısının geliştirilmesi için periton içine 10 µl/kg dozunda % 0.9'luk asetik asit çözeltisi enjekte edilerek, peritonit tablosu oluşturulmuştur. Bu modelde başa ve yüze herhangi bir müdahale yapılmadığından fare yüzü görünümünde herhangi bir bir artefakt oluşmamaktadır. Proje önerisinde de yer alan bu model, deneylerde başarıyla kullanılmıştır.
2. **Baş ağrısı:** Baş ağrısı oluşturabilmek için ön çalışmalarda aşağıda açıklanan 4 farklı model gözönüne alınmış ve sonunda orta şiddette kafa travması ile baş ağrısı yaratılarak kullanılması kararlaştırılmıştır

Baş ağrısı için kullanılan modellerden ilki proje önerisinde de yer alan, kafatasında açılan bir delikten dura üzerine KCl uygulaması sonucunda gelişen baş ağrısıdır. Migren baş ağrısını modellemek için daha önce HÜ NBPE'de başarıyla uygulanmış olan bu modelde beyin zarına KCl uygulanması amacıyla kafatasında bir delik açılması ve ağrı deneyleri esnasında bu bölgeye KCl emdirilmiş pamuk uygulaması yapılması gereklidir (Karatas vd 2013). Deney esnasında hayvana ağrı vermeden KCl uygulamanın tek yolu, birkaç gün öncesinde kafatasında açılan deliği bir plastik tüp yardımıyla dışarı açmaktır. Ancak bu cerrahi işlemler


sonucunda farenin başına yerleştirilen plastik tüp fare yüzü görünümünü etkilemekte ve otomatik tanımda sorun yaşanmaktadır. Dolayısı ile bu proje kapsamında bu modelin kullanılmasından vazgeçilmiştir.

İlk modeldeki sorunu çözmek üzere, ikinci bir baş ağrısı modeli olarak ışıkla aktive edilen proteinleri ifade eden transgenik hayvanların kullanılması düşünülmüştür. Bu amaçla, kortekslerinin 4-5. tabakalarındaki nöronlarda kafa derisi altında kemik üzerine yerleştirilmiş fiber optik kablo kullanarak mavi lazer ışığı ile uyarılmaya elverişli optogenetik gen ifade eden ve yakın zamanlı bir çalışmada migreni modelleyebildiği gösterilmiş fareler gözönüne alınmıştır. Ancak, hem bu ağrı modelinin optimizasyonu için gerekli işlemlerin proje süresinde tamamlanamaması riskinden, hem de deneylerde kullanılacak transgenik farelerin siyah renkli olmasından dolayı yüz ifadesi tanımda ortaya çıkabilecek sorunlar göz önüne alınarak bu modelden vazgeçilmiştir.

Bir üçüncü model olarak insanlarda baş ağrısına yolaçtığı iyi bilinen ve kafatasında cerrahi işlem gerektirmeyen subaraknoid kanama modeli kullanılmıştır. Bu modelde kısaca cerrahi sırasında boynun orta kısmında insizyon ile ana (common) ve eksternal karotit arterler ortaya çıkarılmıştır. Ana karotit arter bağlandıktan sonra damarın orta kısmından bir kesikle internal karotit arter içine doğru giden bir filament yerleştirilip, filamentin yuvarlak ucu orta serebral artere ulaşmaya kadar itilmiştir. Kanama oluşumunu takiben filament çıkarılıp, kesik atılan karotit arter bağlanmıştır. Ağrı derecelendirmesi için 60 dakika kamera kaydı alınmıştır. Ancak farenin genel durumunun çok bozulması (yürüyememe, vb) ve tek gözün kuruluğa bağlı renk değiştirmesinin yolaçtığı asimetrik yüz ifadesi nedenleriyle, bu modelin otomatik ağrı derecelendirmesi için uygun olmadığı sonucuna varılmıştır.

Denenen hayvan modelleri ve yapılan araştırmalar sonucunda, kortikal yayılan depolarizasyona (migren baş ağrısının öncesinde görülen nörolojik belirtilerin hayvan modeli) yol açtığı bilinen kafa tramvası modeline karar verilmiştir. Bu model, kafatasında cerrahi işlem gerektirmemesi, oluşturulacak hasar şiddetinin kolaylıkla ayarlanabilmesi ve migrene benzer ağrı oluşturması nedeniyle tercih edilmiştir. Kafa tramvası hafif, orta ve ağır olmak üzere derecelendirilmektedir. Bu çalışmada orta şiddette kafa tramvası modeli kullanılmıştır. Orta şiddette kafa travması yaratmak üzere gerçekleştirilen işlemlerin detayları şöyledir: Deney başlangıcında farelerin ağırlık ölçümü yapılmış, arkasından %4'lik izofloran inhalasyonu ile genel anestezi indüksiyonu gerçekleştirilmiş ve %2'lik izofloran ile (tüm işlemler süresince) anestezi idame edilmiştir. Arka ayak sıkıştırma yöntemi ile anestezi derinliği kontrol edildikten sonra fareler yüz üstü pozisyonda ağırlık düşürme düzeneğine yerleştirilmiştir. Şekil 5'te görülen 75 g serbest ağırlık fare kafatasının "sagittal suture" bölgesine 7,5 cm yükseklikten düşürülmüştür. Tramvanın hemen sonrasında izofloran anestezi kesilerek farelerin uyanması sağlanmıştır. Daha sonra 90 dakikalık kayıt alınarak

ağrının hangi zaman noktasında başladığı tespit edilmiştir. İlk 5 dakika içinde ağrıya bağlı mimik değişimleri gözlenmiş ve 60 dakika kayıt süresinin yeterli olduğu sonucuna varılmıştır.



Şekil 5. Ağırlık düşürme düzeneği ile kafa tramvasının oluşturulması. Silindirik tüp içerisine vertikal olarak yerleştirilmiş (6 mm çaplı 10 cm uzunluğunda) 75 gram ağırlığında metal ağırlık, üzerindeki horizontal kol yardımıyla istenilen yükseklikten düşürülmektedir. Orta şiddette kafa tramvası oluşturmak için ağırlık 7,5 cm'den düşürülmüştür (n=6).

3.1.3. Deney Video Kayıt Prosedürü

Deneylerin aynı koşullarda gerçekleşebilmesi için, proje ekibimiz tarafından bir deney prosedürü hazırlanmıştır. Yapılan tüm deneyler bu prosedüre bire bir uyularak yapılmıştır. Hazırlanan prosedür yönergesi Şekil 6'da gösterilmiştir.

FARE-MİMİK PROJESİ DENEYLERİNDE VİDEO KAYIT YÖNERGESİ

Tamamladığınız işlemlerle ilgili kutucuğu işaretleyiniz.

- Gözlem kutusunu platformda işaretli yere yerleştiriniz.
- Tüm kameraların kayıt özelliklerinin doğru olduğunu kontrol ediniz (50 fps, HD, autofocus, no zoom).
- Tüm kameraları, kamera numarası etiketlerine göre platformdaki işaretli yerine yerleştiriniz.
- Kameraları dış kutu duvarına işaretli yerlerden sabitleyiniz.
- Kameraların LCD ekranlarını yere paralel hale getiriniz.
- Tüm kameralarda gözlem kutusunun görüntünün yatay olarak ortasına geldiğini ve eğri gözükmediğini LCD ekranlardan kontrol ediniz.
- Her bir kameranın kayıt düğmesine basarak, video kayıtlarını başlatınız. (LCD ekranlara dokunmayınız. Zoom parametrelerini değiştirmeyiniz.)
- Kutu ışık ayarını 9'a getiriniz.
- Kutu ışığını önce 0'a getirerek kapatınız, sonra tekrar 9'a getiriniz (**sadece 1 kez**).
- 30 dakika bazal kayıt yapınız.
- Kamera şartlarını kontrol ederek 50 dakika ağırlı kayıt yapınız.
- Bilgisayarda aşağıdaki protokole göre **isimlendirilen** bir klasör açınız.
<Yıl>_<Ay>_<Gün>_<GözlemKabı><DeneyTürü>_<Çekim Türü>
Çekim Türü: B: Bazal, P: Ağrı
Gözlem Kabı: Cu=Kübik, Cy=Silindirik,
Deney Türü: Ab=Karın Ağrısı, Hd: Baş Ağrısı
Örnek: 2017_02_28_CuAb_B
- Kamera kayıtlarını aşağıdaki protokole göre **isimlendirerek** yukarıda belirtilen klasör altında saklayınız.
<Yıl>_<Ay>_<Gün>_<GözlemKabı>&<DeneyTürü>_<Çekim Türü>_<KameraNo>
Örnek: 2017_02_28_CuAb_B_1.avi
- Kayıtların saklandığı klasörü videolarla birlikte harici diske kopyalayınız.
- Harici diskteki video sayısını ve isimlerini kontrol ediniz.

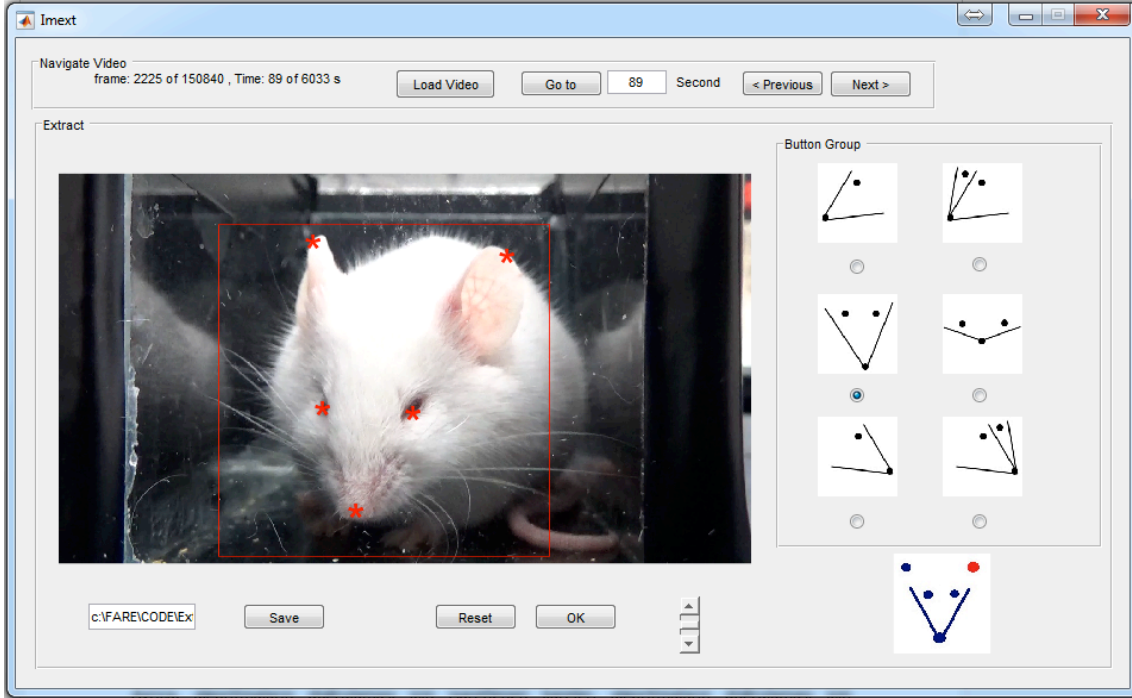
Şekil 6. Fare-Mimik Projesi Video Kayıt Yönergesi

3.1.4. Manuel İşaretleme

3.1.4.1 Yüz Bulma ve Takibi için Manuel İşaretleme

Fare yüz bulma ve takip algoritmalarının eğitilmesi için, öncelikle fare yüz karelerinin elle işaretlenmesi gerekmiştir. Kaydedilen videolardaki fare yüzünün bulunduğu yerin bilgisi ODTÜ Bilgisayarla Görme ve Akıllı Sistemler Laboratuvarında el ile işaretlenmiştir. Bu amaçla hem ağırlı hem de bazal video çekimleri kullanılmıştır.

Bu işlemi kolaylaştırmak için bir arayüz geliştirilmiştir. Geliştirilen ara yüzün görüntüsü Şekil 7'de gösterilmiştir.

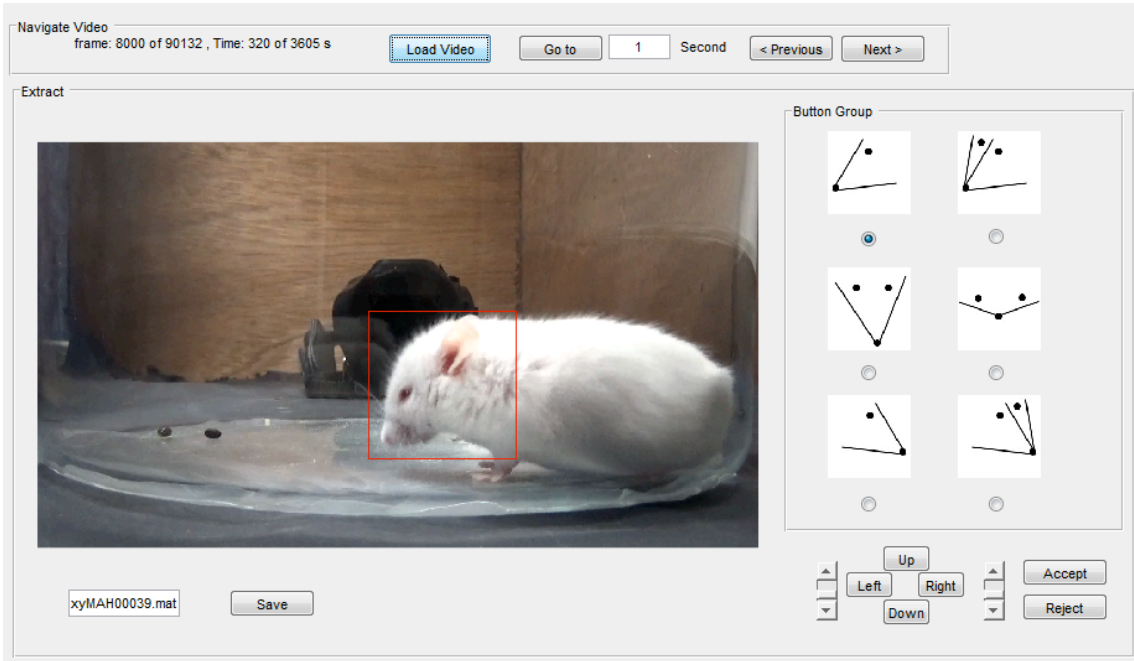


Şekil 7. Fare yüzünün yerinin işaretlenmesi için geliştirilen Grafikselsel Arayüz

Bu arayüzde, öncelikle sağ kulak, sol kulak, sağ göz, sol göz ve burun odak noktaları kullanıcı tarafından işaretlenmektedir. İşaretlenmesi gereken nokta, ekranın sağ alt köşesindeki şemada kırmızı ile belirlenerek kullanıcıya yardımcı olmaktadır. Daha sonra yüzün formu sağdaki yüz formlarının biri seçilerek belirlenmektedir. Yüz karesi işaretlenen noktalar kullanılarak hesaplanmakta ve kullanıcıya gösterilmektedir. Kullanıcı yüz karesini isteğe göre büyütüp küçültebilir. Odak noktalarının koordinatları, yüz bakış yönü ve yüzü çerçeveleyen karenin koordinatları her video karesi için kaydedilmekte ve bir MATLAB .mat

dosyasına yazılmaktadır. Bu arayüz, fare yüzünün yerinin işaretlenerek fare yüzü takip algoritmalarının eğitilmesinde kullanılacak verinin çıkarılması için geliştirilmiştir.

Her bir video karesinde fare yüzünün yukarıda anlatılan biçimde işaretlenmesinde kaybedilen zamanı azaltmak üzere yukarıda anlatılan elle işaretleme arayüzünde, küçük değişiklikler yapılmıştır. Yeni arayüzde, fare yüzünü çerçeveleyen karenin yeri tuşlarla değiştirilip, farenin yüzüne oturtulmakta ve boyutu ayarlanmaktadır. Bir sonraki video karesinde ise yüzü çerçeveleyen kare aynı yerde gösterilmekte ve kullanıcı karenin yerini veya boyutunu değiştirerek yeni kareyi onaylayabilmektedir. Bu şekilde işaretleme işi eskisine göre daha hızlandırılmıştır. Yeni arayüz Şekil 8'de gösterilmiştir.



Şekil 8. Yüz yerinin ve yönünün hızlı etiketlenmesi için geliştirilen yeni arayüz

Her iki arayüz kullanılarak bazal ve ağırlı video çekimlerinde 39.300 adet video karesinde fare yüzünün yeri işaretlenerek etiketlenmiştir. İşaret yerleri Referans Doğru (Groundtruth) oluşturmak için kullanılarak, bu etiketlenmiş video karelerinden Bölüm 3.3.2'de anlatıldığı biçimde Fare Yüzü Takibi veri seti oluşturulmuştur.

3.1.4.2 Ağrı İfadesinin Değerlendirilmesi için Manuel İşaretleme

ODTÜ proje ekibi tarafından geliştirilen yüz tespit ve yüz takip entegre sistemi kullanılarak konumları belirlendikten sonra seçilen video kareleri üzerinde HÜ NBPE ekibi tarafından ağrı derecelendirmesi yapılarak bu yüz görüntüleri etiketlenmiştir. Verilerin manuel etiketlenmesi sırasında yine ODTÜ ekibi tarafından geliştirilen Şekil 9'daki arayüz kullanılmıştır. Bu

arayüzde fare yüzünün yeri HÜ ekibindeki uzmana gösterilmekte ve uzmanın MGS kılavuzuna (Langford vd. 2010) uygun olarak göz, kulak, burun, ağız ve bıyık için ağrı derecesini belirlemesi beklenmektedir.

MGS kılavuzunda belirtilen ölçütler Tablo 1'de özetlenmiştir. Bu ölçeğe göre farelerde gözlerin kısıklığı, kulakların arkaya yatıklığı, burun üzerinde kırışıklık, yanaklarda şişkinlik ve bıyıklarda pozisyon değişikliği olmak üzere beş parametre değerlendirilmektedir. Bu parametreler 0, 1, 2 şeklinde derecelendirilmiştir (0: Ağrı yok; 1: Orta şiddetli ağrı; 2: Şiddetli ağrı).



Şekil 9. Video kareleri üzerinde manuel ağrı derecelendirilmesinin yapıldığı ara yüz

Tablo 1. MGS derecelendirmesi.

Derecelendirilen parametreler	0 (Ağrı yok)	1 (Orta şiddetli ağrı)	2 (Şiddetli ağrı)
Gözler	Açık	Yarı açık	Kapalı
Kulaklar	Ortada	Hafif arkaya yatık	Arkaya yatık
Burun	Kırışiklik yok	Orta derecede kırışık	Kırışık
Yanaklar	Şişkinlik yok	Yarı şişkin	Şişkin
Bıyıklar	Dağınık	Hafif toplanmış	Bir araya gelmiş

3.2. FARE YÜZÜNÜN TESPİTİ

Fare yüzünün tespiti için Viloa Jones yöntemi denenmiş, ayrıca Yüz Onaylama ağı adını verdiğimiz evrimsel sinir ağı kullanılan bir yöntem geliştirilmiştir. Geliştirilen yöntemde, tespit zamanını hızlandırma üzere önce farenin bulunduğu alan, odak alanı belirleme yöntemiyle bulunmuştur. Daha sonra o alan Yüz Onaylama ağı kullanılarak taranıp, fare yüzünün görüntü üzerindeki yeri tespit edilmiştir.

3.2.1 Viola Jones Yöntemi İle Fare Yüzü Tespiti

Viola Jones (VJ) yöntemi (Viola ve Jones 2001), yüz tespiti için literatürde en yaygın kullanılan yöntemdir. VJ yönteminde, NxN büyüklüğünde bir girdi görüntü üzerinde çoklu ölçek Haar filtreleri kullanılarak öznelik çıkarılmaktadır. Bu öznelik değerleri üzerinde eşikleme uygulanarak zayıf sınıflayıcı kararları elde edilmektedir. Zayıf sınıflayıcı kararları Adaboost yöntemi ile birleştirilerek sınıflama yapılmaktadır. VJ Sınıflayıcının (VJ Yüz Onaylayıcı cevabı girdi görüntüde yüz var ya da yok biçimindedir. VJ Yüz Onaylayıcı'nın eğitiminden sonra görüntüde yüzlerin yerlerinin tespit edilebilmesi için görüntü üzerinde büyüklüğü (scale) de değiştirilen bir pencere gezdirilerek her bir pencere içindeki görüntü NxN boyutuna getirilmekte ve VJ yüz onaylayıcıya beslenmektedir. VJ Yüz Onaylayıcı'nın ürettiği değere göre o pencere içinde bir yüz olup olmadığına karar verilmektedir. İnsanlar üzerinde yapılan deneylerde VJ yöntemi ile ilgili olarak literatürde belirtilen zayıflık, yüzün karşıdan görüldüğü durumlarda iyi tespit edilmesi, yüzün karşıdan görünmediği durumlarda ise performansının düşmesidir. VJ yöntemi genellikle $\pm 15^\circ$ pan açısını ve $\pm 10^\circ$ tilt açısını tolere edebilmekte, bu açıların dışına çıkıldığında ise performansı hızlı bir şekilde düşmektedir.

Bu çalışmada Viola Jones algoritması fare yüzü tespiti için bir alternatif olarak göz önüne alınmıştır. Yazılımlar, Opencv Viola Jones uygulaması kullanılarak Python ortamında geliştirilmiştir. Viola Jones algoritması, projemizde çekilen videolar ve elle çıkarılan yüz kareleri kullanılarak eğitilmiştir. Farklı parametrelerle eğitimler ve ilgili başarı sonuçları raporun bulgular bölümlerinde detaylı olarak anlatılmıştır.

3.2.2 Derin Öğrenme ile Fare yüzü Tespiti

3.2.2.1 Odak alan belirleme

Fare yüzü tespit algoritması, kendisine girdi olarak verilen video çerçevesindeki fare yüzünün yerini bulmaya çalışmaktadır. Farenin yüzünün bulunması için, video çerçevesindeki görüntünün farklı boyutlardaki kayan pencerelerle taranıp Yüz Onaylama algoritması çalıştırılmalıdır. Bu işlem 3840x2160 çözünürlükte olan 4k görüntüler için oldukça uzun sürmektedir. Bu problemi gidermek için literatürde farklı yöntemler önerilmiştir. Bunlardan en başarılı olan ve sıkça nesne bulma uygulamalarında kullanılan yöntem, Girshick ve ark. (2014) tarafından geliştirilen R-CNN yöntemidir. Bu yöntemde, önce Seçici Arama (Selective search) (Uijlings ve ark., 2013) yöntemi kullanılarak olası hedef kareler belirlenir. Daha sonra belirlenen kareler CNN derin öğrenme yöntemi kullanılarak sınıflandırılır. Bu çalışmada, fare yüzünün yerinin belirlenmesi için önce Seçici Arama yöntemi kullanılmıştır. Bu yöntemde, önce hiyerarşik gruplama yöntemi kullanılarak başlangıç alanlar seçilir ve daha sonra benzerlik metrikleri kullanılarak bu alanlar birleştirilir.

Seçici Arama yöntemi, proje videoları üzerine uygulanmıştır. Yöntemin sonucunda elde edilen örnek görüntüler Şekil 10'da gösterilmiştir. Bulunan odak alanlar, farklı renklerdeki dikdörtgenler ile gösterilmiştir.


Yöntem, farklı parametreler kullanılarak çeşitli videolar üzerinde uygulanmıştır. Ancak bazı video karelerinde farenin bulunduğu yer odak alan olarak seçilmemektedir. Ayrıca, genelde farenin gövdesinin tamamı odak alanı olarak belirlenmektedir. Bu yöntem 4k videonun her çerçevesi için yaklaşık 120 saniye sürmektedir.

Seçici Arama yönteminde görüntünün histogramı incelenerek, olası odak alanları renk dağılımına göre seçilmektedir. Ancak bizim uygulamamızda, hedef obje ve arka plan renkleri her zaman sabittir (beyaz fare ve siyah arka plan). Bu uygulamaya özel durumdan yola çıkarak, bizim uygulamamıza özel etkin bir çözüm önerilmiştir.

Önerdiğimiz yöntemde, önce görüntüler gri seviyeye çevrilip bir eşikten geçirilmiştir. Daha sonra Morfolojik Operatörler ve Bağlantılı Bileşen (connected component) analizi

kullanılarak, büyük beyaz alan birleştirilip, küçük alanlar elenmiştir. Bu yöntemden sonra elde edilen eşik çıktısı Şekil 11'de , sonuç görüntüsü ise Şekil 12'de gösterilmiştir.


Bu yöntem kullanılarak farenin gövdesi tüm çerçevelerde başarılı olarak belirlenmektedir. Bu yöntem 4k videonun bir çerçevesi için yaklaşık 0.05 saniye sürmektedir. Video çekimleri aynı ışık koşullarında yapıldığından dolayı, bu yöntem tüm videolar için benzer sonuçlar elde etmektedir. Daha sonra bu alan Fare Yüzü Onaylama ağı kullanılarak taranıp, fare yüzünün konumu bulunmaktadır.



Şekil 10. Seçici arama ile çıkarılan odak bölgeleri



Şekil 11. Elde edilen gri seviye görüntünün eşiklenmiş hali



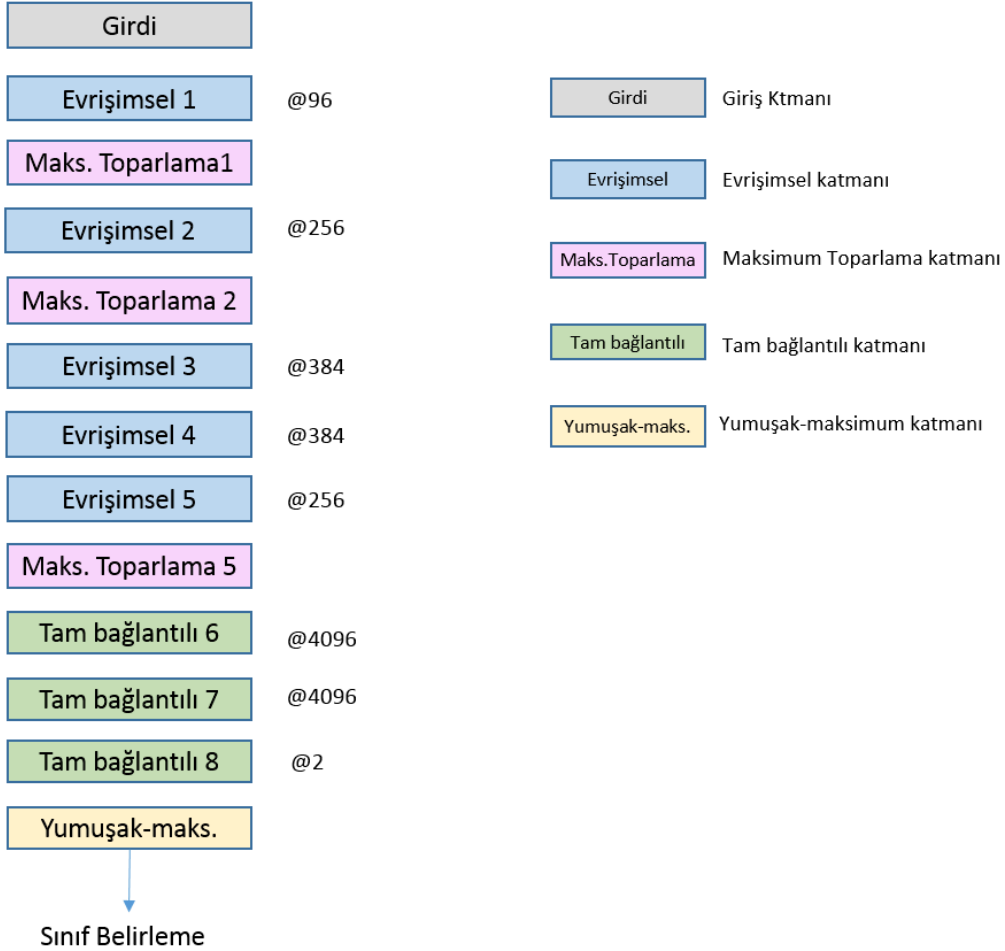
Şekil 12. Önerilen yöntemle elde edilen odak alanı

3.2.2.2 Yüz Onaylama için Kullanılan Evrişimsel Sinir Ağı

Yüz Onaylama için evrişimsel sinir ağı eğitilmiştir. Yüz Onaylama ağının girdisi 256x256 renkli görüntü, çıktı ise girdi görüntünün fare yüzü olması olasılığıdır (p).

Videolardaki aday görüntü parçalarında yüz olup olmadığının onaylanması için farklı sinir ağı mimarileri fare veri tabanı üzerinde denenmiştir. Üstün performansından dolayı, Smolyan ve Zisserman (2014) tarafından genel anlamda nesne tanıma için geliştirilen, VGGNET isimli evrişimsel sinir ağı fare yüzü bulmak için uygun bulunmuştur. VGGNET ağı, eğitim transferi yapılmadan, yalnızca grubumuz tarafından fare yüzü bulmak amacıyla kaydedilen veriler kullanılarak en baştan eğitilmiştir.

Kullanılan VGGNET ađının yapısı Őekil 13'de gsterilmiŐtir. Kullanılan ađ, toplam 8 katmandan oluŐmaktadır. Bu yapıda bir giriŐ katmanı, 5 adet evriŐimsel katman, 3 maksimum toplama, 3 tam bađlantılı katman ve son olarak da yumuŐak-maksimum katmanı bulunmaktadır. Son yumuŐak-maksimum katmanında girdinin sınıfı belirlenmektedir. Girdi katmanında 256x256 boyutunda renkli gdrntler kullanılmıŐtır. Her evriŐimsel katmanda kullanılan kernel sayısı da aynı Őekil iŐinde gsterilmiŐtir.



Őekil 13. Yüz Onaylama iŐin kullanılan evriŐimsel sinir ađının yapısı

3.2.2.3 Odak Alanı Tarama Yöntemi

Fare yüzünün bulunması iŐin, odak alanının Fare Yüzü Onaylama ađı kullanılarak taranması gerekmektedir. Odak alanının taranması iŐin iki farklı yaklaŐım kullanılmıŐtır:

1. YaklaŐım: farklı büyüklükte olan pencereler (50x50 boyutlu kareden 720x720 boyutlu kareye kadar) odak alanı iŐinde 20 piksel kaydırma ile gezdirilmektedir. Her bir pencere iŐinde yer alan kare biçimindeki gdrntü parŐası Fare Yüzü Onaylama ađına girdi olarak

verilmekte ve bu ağ tarafından üretilen yüz olma olasılığı kaydedilmektedir. Daha sonra yüz olarak etiketlenen karelerden en yüksek olasılığı elde eden karenin odak alanı içindeki yeri, hedef kare olarak belirlenir.

2. Yaklaşım: Odak alanı önce büyük bir pencere ile taranır. Daha sonra Fare Yüzü Onaylama ağı kullanılarak, en yüksek olasılığı elde eden pencere seçilir ve yeni odak alanı olarak belirlenir. Yukarıda anlatılan tarama işlemi yeni odak alanı için tekrarlanır ve artık yüz bulunmayacağına karar verilene kadar devam eder.

1. yaklaşım kullanılarak, olası tüm bölgeler kontrol edilmektedir. Ancak bu yöntem oldukça uzun sürmektedir. 2. Yaklaşımında ise çok daha kısa sürede güvenilir sonuçlar elde edilmiştir.

3.3. FARE YÜZÜNÜN VİDEODA TAKİP EDİLMESİ

Fare yüzü takip etmek için geliştirmiş olduğumuz takipçi yöntemi evrimsel yapay sinir ağlarına dayanmaktadır. Takipçi algoritması, farenin bir önceki video karesindeki konum bilgisini kullanarak, güncel video karesindeki konum bilgisini çıktı olarak vermektedir. İncelediğimiz fare yüzü video görüntülerinde, fare yüzü hedefinin genellikle kare bir çerçeveye oturması nedeniyle geliştirilen takipçide, yüz bölgesini gösteren çıktı da kare olacak şekilde gözönüne alınmıştır.

Yapay sinir ağlarının daha önce pek çok nesne takibi uygulamasında kullanılmasına karşın, uygulanan yöntemlerin çoğu çevrimiçi eğitim içerdiğinden oldukça yavaştır ve pratik değildir. Bu uygulamaların aksine geliştirdiğimiz takipçi, çevrimiçi eğitim kullanmaksızın sadece çevrim dışı eğitimle çalışmaktadır. Bu sayede geliştirdiğimiz takipçi, test videosu üzerinde hızlı bir şekilde çalışabilmektedir.

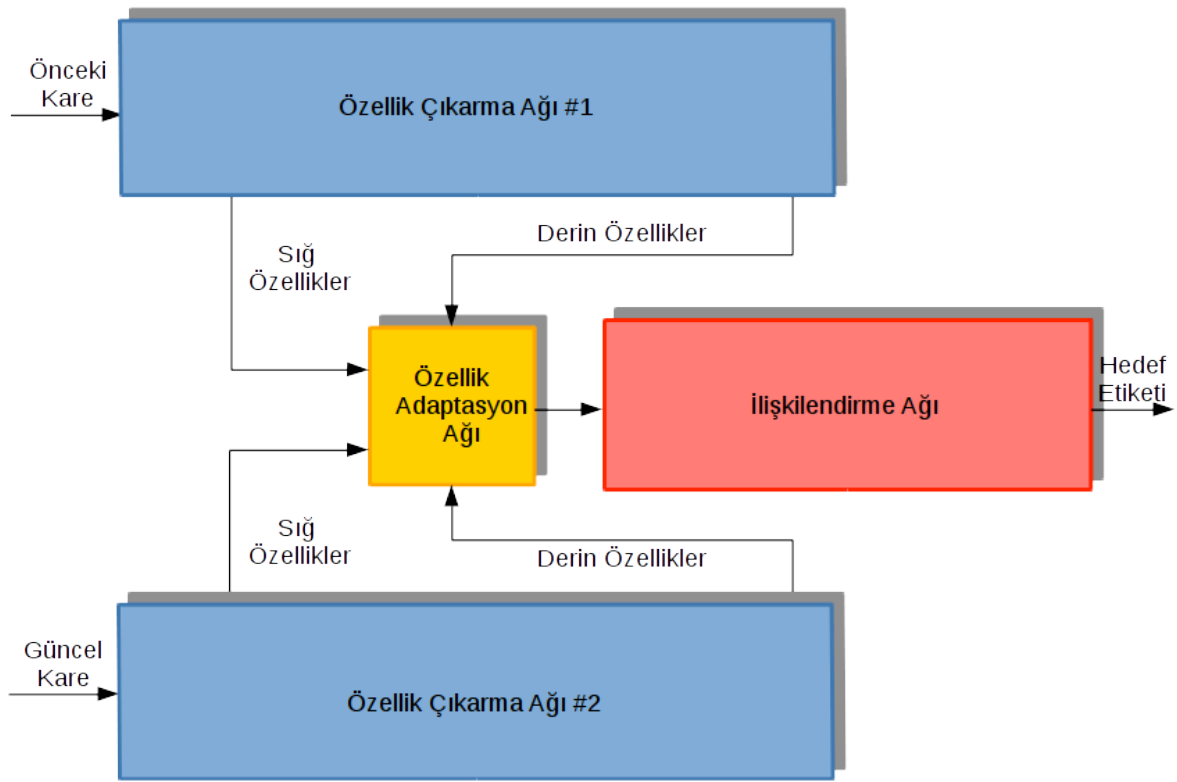
Takipçide kullanılacak evrimsel sinir ağlarını eğitmek için milyonlar mertebesinde veri (video karesi) barındıran çok büyük veri setlerine ihtiyaç olmasına karşın elimizdeki veri seti kısıtlıdır. Bu sorun, daha önceden çok çeşitli nesnenin durağan görüntülerini içeren zengin bir veri setinde nesne bulmak için eğitilmiş olan bir yapay sinir ağının bilgilerini eğitim transferi ile kendi ağımıza aktararak ve sonrasında bu ağ elimizdeki işaretlenmiş video karesi çiftleriyle çevrimdışı eğitilerek çözülmüştür. Bu yöntem sayesinde hem çok farklı hedeflerin verilerini barındıran bir veri seti ile eğitilmiş olan bir evrimsel ağın öznelik çıkarma yeteneği kullanılmış, hem de bu genel öznelikler aracılığıyla özel türde bir hedef olan fare yüzünün takip edilebilmesi mümkün olmuştur.

Geliştirdiğimiz algoritma, bu raporun literatür kısmında açıklanan kaynak [19] 'da önerilen GOTURN takipçiye dayanmaktadır. Ancak, bu takipçi genel nesnelere eğitilmiştir. Fareye özgü zorlukların üstesinden gelmek için, sinir ağı adapte edilmelidir. Bu nedenle, farelere özgü bir veri kümesi, yani fare yüz takibi (Mouse Face Tracking, MFT) veri kümesi, sinir

ağını eğitmek için üretilmiştir. Geliştirdiğimiz takipçinin literatüre en önemli katkısı, GOTURN izleyiciye eklenen özellik uyarlama ağı'dır (FAN). Bu değişiklik, takipçinin performansını, doğruluk ve sağlamlık açısından önemli ölçüde artırmıştır. Buna ek olarak, çalışmamızda, öznelik çıkarıcı olarak kullanılan özdeş ağlardan birinin çıkarılması, özellikle hız açısından daha iyi bir performans elde edilebilmesine olanak sağlamaktadır.

3.3.1. Yüz Takibi için Kullanılan Evrimsel Sinir Ağı Mimarisi

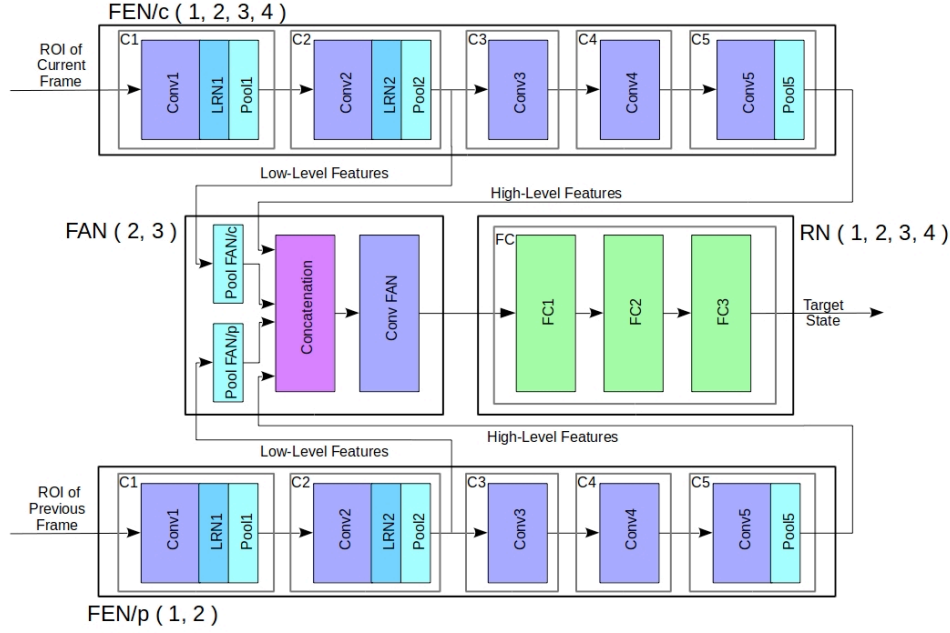
Geliştirdiğimiz Fare yüzü takip (Mouse Face Tracking, MFT) ağının (MFTN) genel yapısı Şekil 14'de , detaylı yapısı ise Şekil 15'te verilmiştir.



Şekil 14: Geliştirilen Evrimsel Takipçideki Ağ Mimarisi

MFTN'nin girişi, önceki ve güncel karelerden kesilen bir çift ilgi alanıdır (ROI). ROI'nin konumu, önceki karedeki hedef dikkate alınarak belirlenmektedir. Bu konum, bir önceki karedeki hedefin merkezinde bulunan bölgedir ve boyutu, önceki hedefin boyutunun 1,5 katıdır. Aynı koordinatlarla kırılan ROI'ler ağı girişi olarak beslemeden önce 227x227 piksele yeniden boyutlandırılır. Ağı çıkışı, ROI içindeki hedefin yeni konumu olup, basit işlem ile güncel çerçeve içindeki konuma kolayca aktarılabilir. Fare yüzünün genellikle bir kare kutuya uyduğundan dolayı hedef alanın kare olarak seçildiği belirtilmelidir. Bu nedenle,

ağın çıkışının, sol üst köşedeki x ve y koordinatları ve kutunun genişliğine karşılık gelen üç bileşeni vardır.



Şekil 15. Önerilen MFTN yapısının detaylı mimarisi. MFTN versiyonları, 1) MFTN-GOTURN, 2) MFTN/cp, 3) MFTN/c ve 4) MFTN-VGG-CNN-F'dir. FEN/c ve FEN/p alt ağları, sırasıyla güncel ve önceki karelerden öznitelik çıkarımından sorumludur, FAN alt ağı, FEN çifti tarafından çıkartılan düşük seviyeli ve yüksek seviyeli özellikleri uyarlar ve RN, hedef konumunu oluşturur. Her bir alt ağ adından sonra, ilgili MFTN versiyonları parantez içinde belirtilmiştir. Orijinal VGG-CNN-F ağı beş adet evrimsel ve bir tam bağlantılı (FC) bloktan oluşmaktadır. Ek olarak, bazı bloklar bir yerel yanıt normalizasyonu (LRN) ve/veya bir maksimum toplama katmanından oluşmaktadır. Diğer detaylar için Tablo 2 ve 3'e bakınız.

MFTN, güncel ve önceki video karelerinden öznitelik çıkarmadan sorumlu iki ağdan (FEN/c ve FEN/p), bir özellik uyarlama ağından (FAN) ve giriş özelliklerinden hedef konumu oluşturan bir regresyon (RN) ağından oluşmaktadır. Bu ağlarda kullanılan tabakalar Tablo 2'de özetlenmiştir.

Şimdiki ve önceki video karelerinden kesilen ROI'ler sırasıyla FEN/c ve FEN/p'ye beslenir. FEN çiftinden her biri, girdi ROI'den düşük ve yüksek seviyeli özellikleri çıkarır. Önerilen ağ, özellik çıkarıcı olarak VGG-CNN-F ağını (Simonyan ve Zisserman, 2014) kullanmaktadır. FEN'de, sadece VGG-CNN-F ağının evrimsel blokları kullanılmıştır. FC bloğu, FEN'e dahil edilmek yerine RN'ye taşınmıştır.

Tablo 2: FEN, FAN, ve RN ağlarında kullanılan katmanların detayları

Ağ Adı	Blok Adı	Katman Adı	Kernel sayısı	Kernel boyutu	Stride	Nöron Sayısı	Nöron Tipi
FEN	C1	Conv1	64	11	4		ReLU
		LRN1	-	5	-		
		Pool1	-	3	2		
	C2	Conv2	256	2	5		ReLU
		LRN2	-	5	-		
		Pool2	-	3	2		
	C3	Conv3	256	1	3		ReLU
	C4	Conv4	256	1	3		ReLU
	C5	Conv5	256	2	5		ReLU
		Pool5	-	3	2		
FAN		Pool FAN/c	-	3	2		
		Pool FAN/p	-	3	2		
		Concatenation					
		Conv FAN	256	1	3		ReLU
RN	FC	FC1		-	-	4096	ReLU
		FC2		-	-	4096	ReLU
		FC3		-	-	3	Linear

FEN'in ilk katmanları, kenarlar ve köşeler gibi basit özellikleri, derin katmanlar ise görüntüdeki nesnelere ilgili anlamsal bilgileri çıkarır. Yüksek düzey özellikler, görüntüdeki belirli bir nesneyi tanımak için kullanışlıdır. Ancak, geniş algı alanları nedeniyle hedefin yerini tam olarak tespit edemezler. Oysa düşük düzeydeki öznitelikler hedefin ne olduğunu tanımakta daha az kullanışlı olmasına karşın, yerini belirlemede daha kullanışlıdır. Bu nedenle, FEN'in hem düşük hem de yüksek seviyeli öznitelik haritaları derinlemesine peş peşe eklenerek birlikte kullanılır. Bu birleştirme için, öznitelik haritalarının uzamsal büyüklükleri aynı olmalıdır. FAN düşük ve yüksek seviyeli özellikleri aynı büyüklüğe getirmek ve birleştirmek için kullanılır. Bu ağ, maksimum toparlama, birleştirme ve evrimsel katmanlardan oluşur. Maksimum toparlama katmanı, düşük seviyeli öznitelik haritasının büyüklüğünü yüksek düzey öznitelik haritasının büyüklüğüne düşürmeyi amaçlamaktadır. Bu özelliklerin birleştirilmesinden sonra, bir ReLU çıkışı ile evrimsel tabakasına aktarılmaktadır.

FAN tarafından üretilen öznitelikler hedef lokasyonu sağlamak için RN'ye beslenir. RN, üçüncü tabaka hariç, VGG-CNN-F'deki ile aynı FC katmanlarından oluşmaktadır. Ağ, regresyon için kullanıldığı ve üç çıktısı olduğu için, son FC katmanı, orijinal ağdaki 1000 softmax nöronunun yerine, lineer çıktıya sahip üç nörona dönüşmektedir.

Bu çalışmada, her biri farklı bir FEN/c, FEN/p, FAN ve RN kombinasyonuna sahip dört farklı MFTN versiyonu ele alınmıştır (bakınız Tablo 3):

1) MFTN-GOTURN: Bu, fare yüzünü izlemek için uyarlanmış GOTURN takipçisidir. FEN/c, FEN/p ve RN'den oluşur. MFTN-GOTURN orijinal GOTURN [19] takipçi ile aynı genel

yapıya sahiptir. Genel nesnelere eğitildiği için GOTURN, toplar, arabalar ve insanlar gibi standart hedeflerle daha iyi performans gösterir. Ancak, bir fare veri setinde doğrudan değerlendirildiğinde, performansı tatmin edici olmamaktadır. Bu nedenle, adil bir karşılaştırma yapabilmek için, çıktı katmanını dışında aynı mimariye sahip bir fare yüz takipçisi uygulanmıştır. Dikdörgen hedef pozisyonu belirleyen orijinal dört-nöronlu çıkış tabakası, fare yüzü kare biçiminde seçildiği için üç nöron içeren çıkış tabakası ile değiştirilmiştir. Buna ek olarak, FC1 ile aynı özelliklere sahip bir FC tabakası, GOTURN ile uyumlu olacak şekilde RN'ye eklenmiştir. Orijinal GOTURN uygulamasında, AlexNet'in evrimsel katmanları özellik çıkarma ağı olarak kullanılmıştır. Ancak, önerilen MFTN-GOTURN, ImageNet'te AlexNet'e benzer bir hata oranı elde eden VGG-CNN-F ağını kullanmaktadır, bu ağ hızlı eğitim ve çıkarım için daha fazla uzmanlaşmıştır. FAN, GOTURN yapısında kullanılmadığından dolayı, sadece FEN/c ve FEN/p ile çıkarılan yüksek seviyeli özellikler, birleştirme sonrasında doğrudan RN'ye beslenmiştir.

- 2) MFTN/cp: Hedeflerin takibi için düşük seviyeli öznelik kullanmayan orijinal GOTURN'un aksine, önerilen ağda, düşük seviyeli özellikleri FAN aracılığıyla hem önceki hem de geçerli karelerin yüksek seviyeli öznelikleri birleştirilmiştir. Bu nedenle, bu MFTN sürümü FEN/c, FEN/p, FAN ve RN'yi içermektedir.
- 3) MFTN/c: Fare yüzü takibi için önceki karenin özneliklerinin gerekli olup olmadığını kontrol etmek için MFTN/c olarak adlandırılan üçüncü bir versiyon önerilmiştir. MFTN/c yapısı, FEN/p'nin çıkarılması dışında MFTN/cp ile aynıdır.
- 4) MFTN-VGG-CNN-F: Araştırmadaki bütünselliği sağlamak açısından, sadece FEN/c ve RN'den oluşan dördüncü bir versiyonda göz önüne alınmıştır. Bu ağ, son tam bağlantılı katmanın modifikasyonu hariç, orijinal VGG-CNN-F ağına eşdeğerdir. Bağlantı kuvvetleri fare veri kümesi kullanılarak ayarlanmıştır. FEN/p ve FAN bu yapıda kullanılmadığından, sadece FEN/c tarafından çıkarılan yüksek seviyeli özellikler doğrudan RN'ye beslenmektedir.

Tablo 3: Dört MFTN versiyonunda FEN/c, FEN/p, FAN and RN kullanımı


MFTN Versiyonu	FEN/c	FEN/p	FAN	RN
MFTN-GOTURN	Evet	Evet	Hayır	Evet
MFTN/cp	Evet	Evet	Evet	Evet
MFTN/c	Evet	Hayır	Evet	Evet
MFTN-VGG-CNN-F	Evet	Hayır	Hayır	Evet

3.3.2. Yüz takibi için Veri Seti

MFT veri seti, Hacettepe Üniversitesi Nörolojik Bilimler ve Psikiyatri Enstitüsü, Davranış Denepleri Araştırma Laboratuvarında farelerden çekilen videolardan elde edilmiştir. Proje kapsamında yapılan deneylerde, Albino Swiss fareleri kullanıldı ve her deney başka bir nesne içermeyen şeffaf bir gözlem kutusuna yerleştirilmiş farklı bir fare ile gerçekleştirildi. Her deney, sırasıyla ağrı paradigmasının uygulanmasından önce ve sonra durumlara karşılık gelen bir bazal faz ve bir ağrı fazına sahiptir.

Bu çalışmada MFT eğitim veri setini oluşturmak için üç video kullanılmıştır. Bu videolarda, farenin yüzünün görünmediği çerçeveler atılmıştır. Kalan çerçeveler arasında geçerli kareler belirlenmiştir. Farenin yüzü önceki ve şimdiki kareler arasında yer değiştirdiyse, şimdiki çerçeve geçerli olarak etiketlenmiştir, yer değiştirmediyse durumlar işe geçersiz olarak işaretlenip veri kümesine alınmamıştır. Hem ağrı hem de bazal videoyu içeren geçerli çerçeveler, takipçiyi farenin durumundaki değişikliklere karşı daha sağlam kılmak için eğitimde kullanılmıştır. Ancak, farenin bazal durumda olduğu videolar, fare daha hareketli olduğundan takipçi eğitimi için daha değerlidir. MFT veri kümesi için toplam 3583 çerçeve, geçerli kareler olarak etiketlenmiştir.

Geçerli karelere karar verildikten sonra, veriler ve eğitim veri seti için etiketleri aşağıdaki gibi hazırlanmıştır: Bir geçerli çerçeve rasgele seçilip önceki çerçevesi kaydedilmiştir. Güncel çerçeve için ROI, önceki karedeki hedef konumu dikkate alınarak belirlenmiştir. Hedef şekli bir kare olarak tanımlanmıştır (bkz. Şekil 16).



Şekil 16: Yeşil kare hedef bölgesini, mavi kare ise arama alanını gösterir.

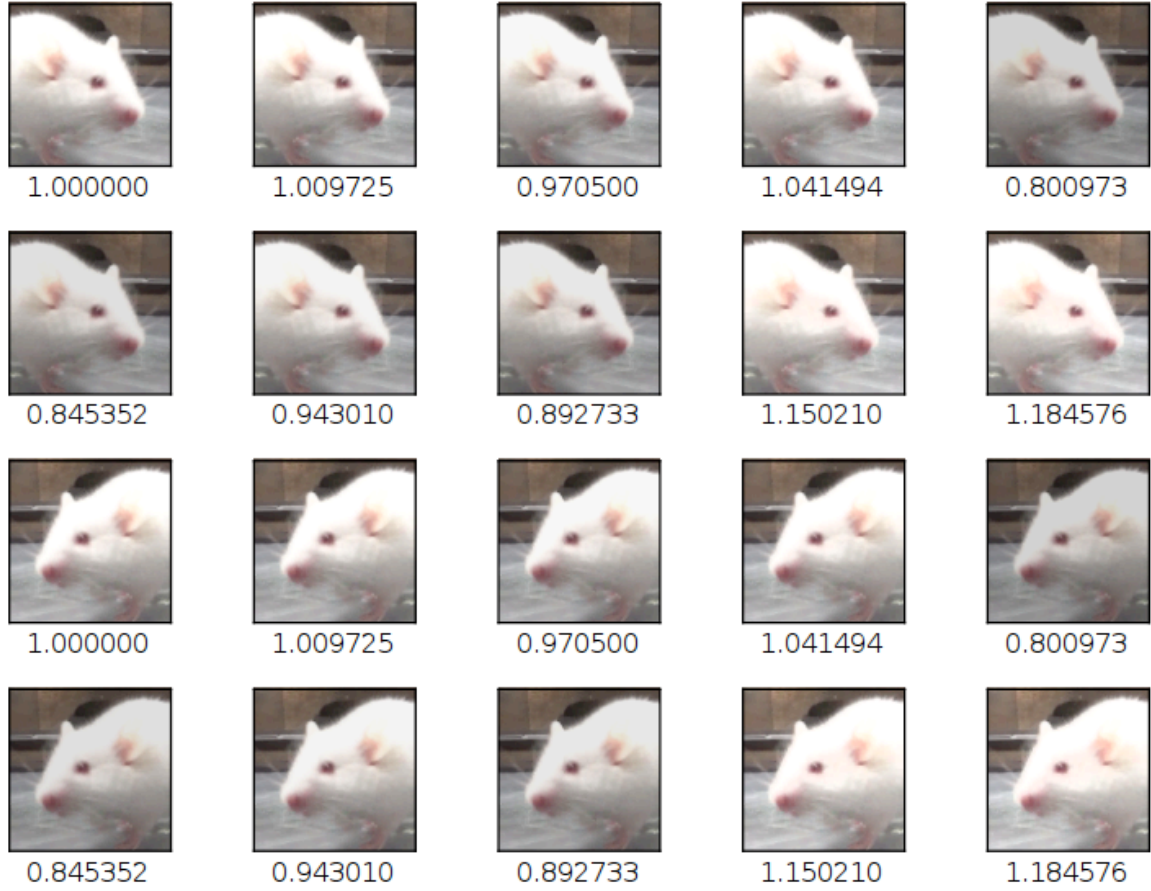
ROI'ler, önceki ve şimdiki karelerden kesilmiştir. ROI'nin VGG-CNN-F için uyumlu bir formatta olmasını sağlamak için ROI çifti, RGB'den BGR'ye dönüştürülmüş, 227x227 piksele boyutlandırılmıştır ve ImageNet veri setinin ortalaması bu değerlerden çıkarılmıştır. Bu verilere ait etiketler, güncel çerçevede ROI'ye göre hedefin konumunu ve boyutunu temsil eden üç boyutlu bir vektördür.

3.3.3. Verilerin Çoğaltılması

Veri çoğaltma işlemi veri setinin zenginleştirilmesi için önemli bir uygulamadır. Yapay sinir ağları ne kadar zengin bir veri setiyle eğitilirse o kadar genelleme yeteneğine sahip olurlar. Önerilen yöntemde veri çoğaltma metodu olarak dikey simetri alma ve parlaklık değiştirme yöntemleri uygulanmıştır. Bu yöntemlerle oluşturulan yapay veriler gerçek videolarda karşılaşılabilecek verilerle benzerlik göstermektedir. Aynı zamanda parlaklık değişimi yöntemi sayesinde, geliştirilen takipçi ortamın aydınlık seviyesi değişimlerine karşı daha dirençli olmaktadır. Veri çoğaltmak için aşağıda anlatılan yöntem kullanılmıştır.

Öncelikle, 0.8 ile 1.2 arasında değişen 9 sayı rastgele seçilir. Bu rakamlar parlaklık değişiminde çarpan olarak kullanılacaktır. Güncel ve önceki kareler HSV renk uzayına çevrilir. Bu renk uzayında V değerleri parlaklık bilgisi içermektedir. Karelerin V değerleri oluşturulan rastgele sayılarla çarpılarak orijinal resimden farklı olarak 9 resim daha üretilmiş olur. Çarpım işleminden sonra tüm kareler RGB renk uzayına çevrilir.

Sonrasında üretilen ve orijinal karelere dikey simetri alma işlemi uygulanır. Bu yöntem sayesinde de yapay olarak 10 adet veri üretilmiş olur. Toplamda bakılacak olursa bir veriden 19'u yapay üretilmiş olacak şekilde, 20 adet veri üretilmiş olur. Şekil 17'de orijinal veriden üretilen yapay verileri görebilirsiniz. Burada sadece güncel arama kareleri üzerinden üretilen veriler gösterilmiştir. Önceki arama karesi de aynı şekilde çoğaltılmıştır.



Şekil 17: Orjinal veriden (sol üst köşedeki görüntü) çoğaltılan yapay veriler. Her karenin altında parlaklık çarpanı verilmiştir.

Karelerin dikey simetrisi alındığında veriye ait etiketteki yer bilgisi de değişmektedir. Etiket güncellemek için hedefin orijinal sol üst köşesinin yataydaki konumu 227'den çıkartılır. Farkın sonucundan da hedef genişliği çıkartılarak yeni konum bulunmuş olur. Bu değer 10 ile çarpılarak orijinal etiket formatına getirilir.

Burada açıklandığı şekilde veri seti büyüklüğü 20 katına çıkarılmıştır. Daha önce Bölüm 3.3.2'de açıklanan 3583 geçerli video karesinden 2675 tanesi kullanılarak 53500 eğitim örneği oluşturulmuş, geriye kalan 908 geçerli video karesi ise doğrulama için kullanılmıştır.

3.3.4. Takip için Çevrimdışı Eğitim

Takipçi, daha önce Bölüm 3.3.1'de anlatıldığı gibi önerilen MFT Ağı, 4 farklı alt ağdan oluşmaktadır. FEN/c ve FEN/p ağlarının evrimsel katmanları, ImageNet veri kümesi ile eğitilen orijinal VGG-CNN-F ağının ağırlıkları kullanılarak başlatılmıştır. Ancak, bu ağırlıklar

eđitim sırasında ayarlanmıřtır. RN'deki FAN ve FC katmanlarındaki evriřimsel tabaka Caffederin öğrenme yazılımı (Shelhamer vd. 2014) çerçevesinde uygulanan Xavier başlatıcısı (Glorot ve Bengio 2010) ile başlatılmıřtır. Eđitimde, öğrenme hızını ayarlayan Adam optimizer (Kingma ve Adam, 2017) kullanılmıřtır. Genelleme kabiliyetini arttırmak için, FC'nin FC1 ve FC2 katmanlarında "dropout "deęeri 0.5 olarak kullanılmıřtır.

Ađ, çoęaltılmıř MFT veri kümesi ile eđitilmifitir. Etiketli veri aęa rastgele bir sırada beslenmiřtir. FEN/p'nin kullanılmadıęı MFTN versiyonları için (yani, MFTN/c ve MFTN-VGG-CNN_F), sadece güncel karedeki ROI dikkate alınmıřtır. Kayıp fonksiyonu olarak Ortalama kare hata (RMS) kullanılmıřtır. Bu fonksiyonun deęeri doęrulama setinde artmaya başladıda eđitim durdurulmuřtur. FEN alt aęı baęlantı aęırlıkları başlangıç deęeri olarak VG-CNN-F'den eđitim transferi yapılmasından sonra, her bir MFTN versiyonu için, FEN'in ince ayar eđitimine (fine tuning) devam edilme ve edilmemesi olmak üzere her iki durum da göz önüne alınıp, bunlardan daha iyi performans gösteren durum seçilmifitir.

Eđitim transferi sonrası ince ayar eđitim FEN çiftinden sadece FEN/c'yi içeren MFTN/c ve MFTN-VGG-CNN-F versiyonları için daha iyi bir kayıp deęeri elde etmiřtir. Ancak, FEN/c yanısıra FEN/p'yi de içeren MFTN/cp ve MFTN-GOTURN versiyonları için ince ayar eđitim yapılmadıęında performansın daha iyi olduęu gözlenmiřtir. Bu durum, FEN/c yanısıra FEN/p'nin de kullanılmasının aęlara çok fazla parametre getirdiđini ve MFT veri setindeki sınırlı örnek sayısından dolayı ezberlemeye (overfitting) neden olduđunu göstermektedir.

3.3.5. Çevrimiçi Takip

Bu bölümde, çevrimiçi takip sırasında kullanılan yöntem açıklanacaktır. Geliřtirilen yöntemdeki, takipçi algoritmasının hedef konumunu belirlemesi için ařađıdaki prosedür uygulanır.

Fare yüzünü takip etmek için, önceki ve řimdiki video karelerinden kesilen ROI çifti, VGG-CNN-F uyumlu formata dönüřtürdükten sonra MFTN'ye beslenmektedir. Bu iki ROI den gelen bilgi ile aę üzerinde ileri besleme (feed forward) yapılarak güncel çerçevedeki hedefin pozisyonu hesaplanmaktadır. FEN/c'nin hariç tutulduęu MFTN sürümleri için, yalnızca güncel çerçevedeki ROI aęa beslenmektedir. Aę çıkıřından alınan ROI'ye göre hesaplanan konum bilgisi, ROI'nin yeri ve büyüklüęü dikkate alınarak çerçevedeki mutlak konuma dönüřtürölmektedir. Hedef konum belirlendikten sonra, güncel çerçeve bir önceki çerçeve olarak tanımlanmaktadır. Sonraki çerçeve videodan okunup ve yeni çerçevede hedefi bulmak için aynı prosedür uygulanmaktadır. Bu süreç, video sona erene veya hedef kayboluncaya kadar devam etmektedir.

Görsel inceleme ile, fare yüzü takipçisi hedefi kaybettiğinde, hesaplanan hedef büyüklüğünün hızla küçülerek sifıra düştüğünü gözlemledik. Hedef kaybı tanımlamak için basit bir sezgisel kod kullanıldı. Güncel hedefin genişliği önceki hedefin genişliğine bölündüğünde, bu oran bir eşik değerinden küçükse, takipçi algoritmasının güncel çerçeve için başarısız olduğu varsayılmıştır.

Eşik değerine karar vermek için, takipçi algoritması 10 dakika 25 fps video segmenti üzerinde çalıştırılmıştır. Takipçi fare yüzü görünmüyorsa durdurulup ve tekrar görünür olduğunda kesin referans üzerinden yeniden başlatılmaktadır. Fare yüzünün videoda görülebildiği çerçeveler için genişlik oranları incelenmiş ve genişlik oranının en çok 0.94 ile 1.04 arasında değiştiği gözlenmiştir. Bu nedenle, bu uygulama için eşik değeri 0.9 olarak seçilmiştir. Takipçinin başarısızlık durumunun bir örneği Şekil 18'de verilmiştir. Takipçi, farenin kameraya arkasını döndüğü 5325 numaralı çerçeveden sonra hedefi kaybetmektedir. 0,9'dan küçük bir genişlik oranına sahip takipçi çıkışları, kırmızı kareler olarak gösterilmiştir. Kırmızı karelerin farenin yüzünü içermediğine dikkat edilmelidir.

Fare yüzü takipçisinin fare yüzü tespiti modülü ile entegrasyonu sırasında, bu bahsedilen oranı kullanmak yerine fare Yüzü Takipçisi çıktısının Fare Yüzü Onaylama ağına beslenerek onaylanması için bir çalışma yapılarak entegre sistemde bu yaklaşım kullanılmıştır. Takipçinin bulunduğu her bir yüz bölgesi Yüz Onaylama ağına verilmekte, eğer onaylanırsa sonraki çerçeveye geçilmektedir. Onaylanmadığı durumda ise Fare Yüzü Tespiti algoritması devreye girmektedir.

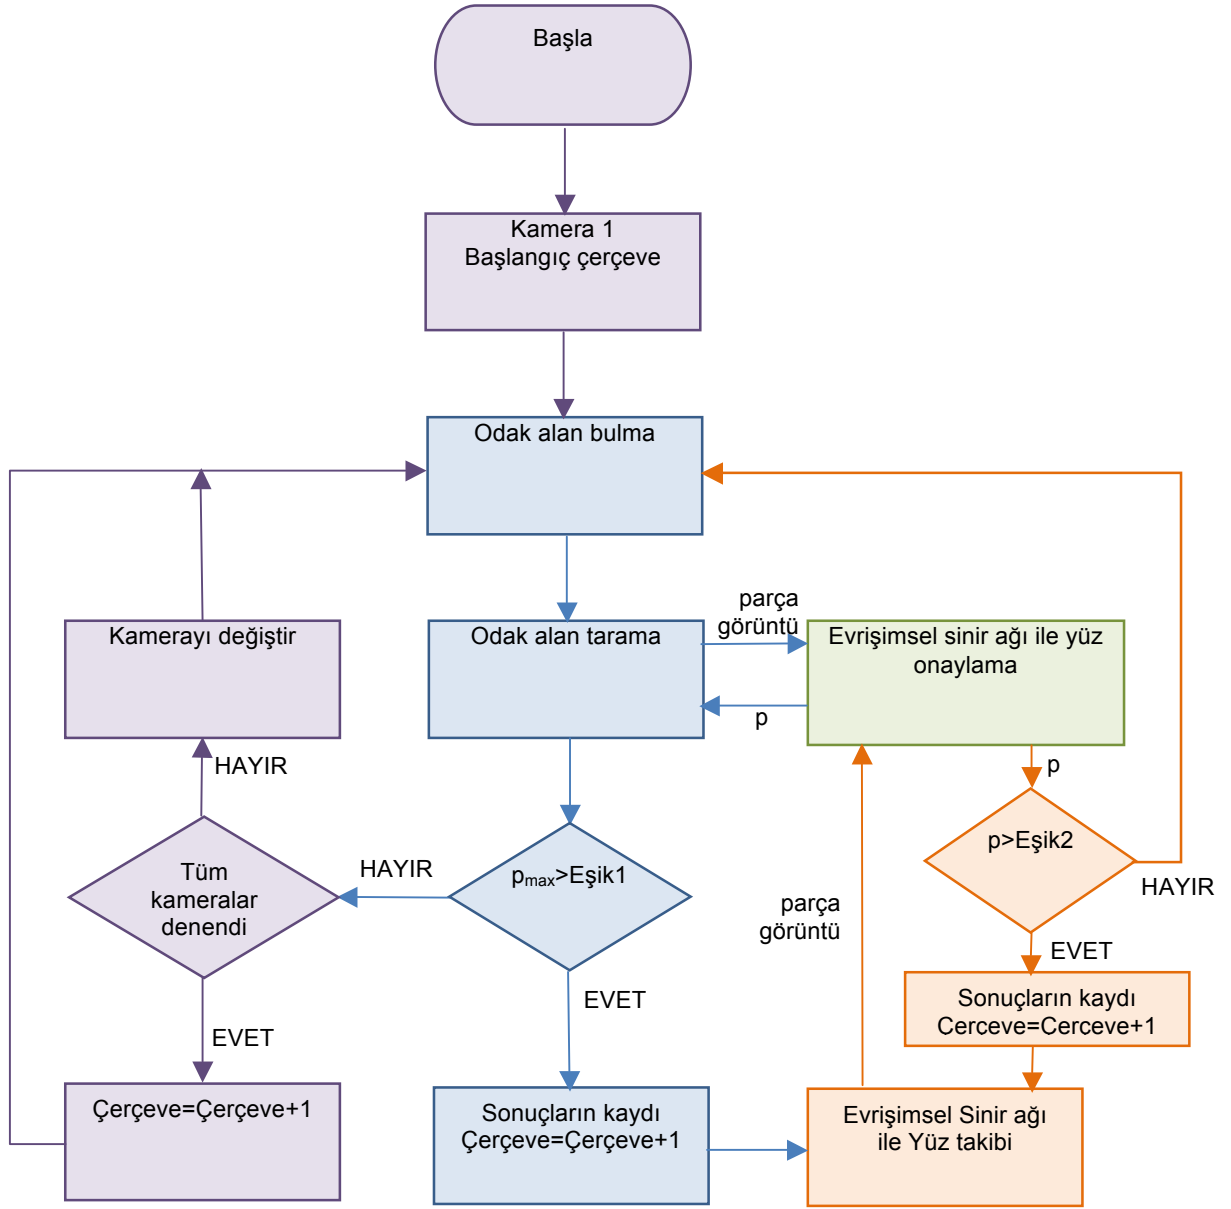


Şekil 18. Takipcinin hedefi kaybetmesi örneği. Önceki karelere göre hesaplanan çerçeve sayıları ve genişlik oranları, her bir çerçevenin altında verilmiştir. Başarılı sonuçlar yeşil olarak ve başarısız girişimler kırmızı olarak gösterilmektedir. Fare arkasını döndüğünde takipçi hedefi kaybetmektedir. Aynı zamanda, hedef kaybını tanımlamak için kullanılan genişlik oranı 0.90'dan daha küçük değerlere düşmektedir.

3.3.6. Tespit ve Takip algoritmalarının Çoklu Kamera için Entegrasyonu

Daha önce anlatılan deney düzeneğinde, farenin bulunduğu kutunun etrafında 6 kamera eşit mesafede yerleştirilmiştir. Bu şekilde, deney boyunca farenin yüzü en az bir kamerada görünmektedir. Bu nedenle 6 kameradan elde edilen görüntülerin eş zamanlı işlenmesi, her video karesi için 6 kameradan birinde fare yüzünün konumunun bulunmasını sağlamaktadır. Videoların aynı zamanda işlenebilmesi için, videolar arası zaman senkronizasyonunun sağlanması gerekmektedir. Bunun için her deney başlamadan önce ışık kapatılıp açılmıştır. Daha sonra videoları işlemeyen önce, her videoda ilk karanlık fotoğraf karesi bulunup tüm videolar aynı zamana taşınmıştır.

Videoların işlenmesi için kullanılan algoritma, Şekil 19'daki akış diyagramında gösterilmiştir. İlk video çerçevesinden başlanarak, önce odak alan bulunup, sonrasında yüz onaylama ağı kullanılarak taranmaktadır. Eğer yüz karesi bulunmadıysa, bir sonraki kamera için aynı işlem yapılmaktadır.



Şekil 19. Videolarda yüzün otomatik bulunması için kullanılan algoritma

Yüz karesi bulunduktan sonra, karenin konum ve büyüklük bilgileri aktararak takipçi algoritması çalıştırılmaktadır. Takipçi algoritmasının her fotoğraf karesi için ürettiği çıktı, yüz onaylama ağı kullanılarak kontrol edilmektedir. Çıktı karenin yüz olarak onaylanmadığı durumda, tekrar yüz bulma adımları yapılmaktadır.

6 kameralı düzenek için geliştirilmiş entegre yöntemde yaklaşık 10.000 video karesi üzerinden yapılan denemede fare yüzünün yeri ağırlı çekim videolarında %99.2 oranında doğru bulunmuştur. Bazal çekim videolarında ise fare çok fazla hareketli olduğundan bu başarı oranı %91.1 civarındadır. Projemizin temel amacı ağıri derecelendirme olduğundan

ağırlı çekimlerdeki başarı daha fazla önem taşımaktadır. Entegre sistemin bazal ve ağırlı çekim için hazırlanan kısa video demolarına ARDEB'e yuklenmiştir.

Burada kamera sayısında bir kısıtlama bulunmamaktadır. Tek kamera olduğu durumda sadece yüz tespit ve takip algoritmalarının entegrasyonu sağlanmaktadır. Çoklu kamera olması durumunda ise kullanılan kameralar üzerinden entegrasyon sağlanmaktadır. Bizim deneylerimizdeki düzeneklerde 2 ya da 6 kamera bulunmaktadır.

3.4. FARELERDE AĞRININ OTOMATİK DERECELENDİRİLMESİ

Ağrı derecelendirme için kullanılan MGS yönteminin bilgisayar ortamında otomatik hale getirilmesi için yapılan çalışmalar bu bölümde açıklanmıştır. Ağrı sınıflandırması için evrışimsel derin sinir ağıları kullanılmıştır.

3.4.1. Ağrı İfadesinin Eğitilmesi için Veri Seti Oluşturulması

Bu veri seti, ağrı denyelerinde kaydedilen videolaradan elde edilen renkli fare yüzü görüntülerini ve bunlara karşılık gelen ağrı derecelerini içeren bilgileri taşımaktadır. Fare yüzünü çerçeveleyen karelerin büyüklüğü farenin kameraya yakın ya da uzak olmasına göre değişmektedir. Ancak çerçevelenmiş bu yüz görüntüleri veri setine aktarılırken 256x256 piksel boyutuna normalize edilmiştir. Resimler python npz dosya formatında tek bir dosyaya sıkıştırılıp etiketleriyle birlikte kaydedilerek bir veri seti oluşturulmuştur.

Veri setinde aşağıdaki bilgiler yer almaktadır: Veri setindeki örnek sayısı, her bir örnek için 256x256 piksel boyutuna getirilmiş fare yüz resmi ve bu resim için manuel işaretlenen etiket bulunmaktadır. Manuel işaretlemenin nasıl yapıldığı Bölüm 3.1.4'de açıklanmıştır. Her bir yüz kısmının (göz, kulak, burun, ağız, yanak) ağrı derecesi tutulmaktadır. Ağrı derecesi daha önce belirtildiği gibi 0, 1 ya da 2 değerini almaktadır. Ayrıca her bir yüz elemanı için o biginin geçerli olup olmadığını belirleyen bir işaret de etiketted saklanmaktadır. Tablo 4'de her bir etiketin hangi indeksinde hangi değerlerin gösterildiği özetlenmiştir. Toplam skor ağrı derecesini gösteren beş parametre degerinin ortalaması olarak hesaplanmaktadır. Veri seti için etiketlenen örnek sayıları Bölüm 4.3.1'de detaylı olarak açıklanmıştır.

Tablo 4. Her bir etiket objesindeki özellikler (PS:Pain Scale)

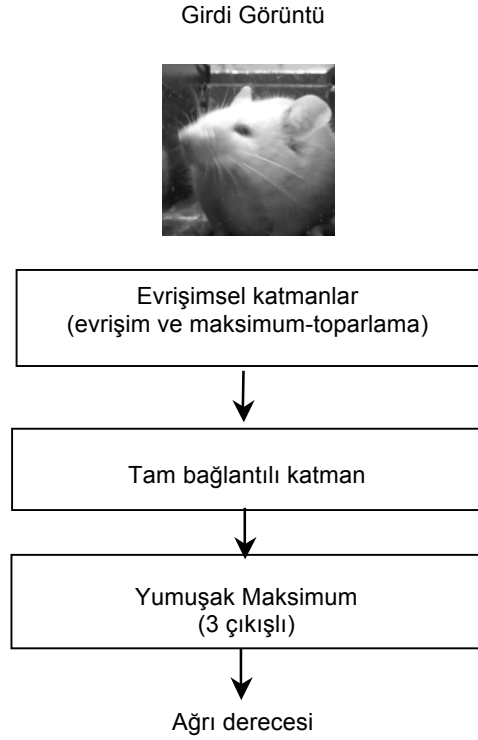
index	Özellik
1	Gözlerdeki Ağrı Derecesi ($PS_{göz}$)
2	Kulaklardaki Ağrı Derecesi (PS_{kulak})
3	Burundaki Ağrı Derecesi (PS_{burun})
4	Ağızdaki Ağrı Derecesi ($PS_{ağız}$)
5	Bıyıklardaki Ağrı dercesi ($PS_{bıyık}$)

3.4.2. Ağrı Derecelendirme için Kullanılan Evrişimsel Sinir Ağı Mimarisi

Projenin ilk döneminde yapılan ön çalışmalarda, Destek Vektör Makinası (Support Vector Machine SVM), Temel Bileşen Analizi (Principal Component Analysis, PCA), K Yakın Komşu Sınıflayıcısı (K Nearest Neighborhood Classifier K-NN), Çok Katmanlı Perceptron: (Multi-layer Perceptron, MLP) ve Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) ile elde edilen performanslar sınırlı bir veri set üzerinden karşılaştırılmış ve bunlar arasında derin öğrenme kullanılmasına karar verilmiştir

Çalışmada farelerdeki ağrı derecesini belirlemek için oluşturduğumuz evrişimsel sinir ağı Fare-mimik-net olarak adlandırılmıştır. Fare-mimik-net'in yapısı Şekil 20'de verilmiştir.

Fare-mimik-net'in yapısında bir giriş katmanı, iki adet evrişimsel katman, bir tam bağlantılı katman ve son olarak da yumuşak-maksimum (soft-max) katmanı bulunmaktadır.



Şekil 20: Fare ağrı değerlendirme için geliştirdiğimiz Fare-mimik-net'in genel yapısı

Kullanılan ağıın yapısı ve parametreleri, evrişimsel sinir ağların performansını büyük ölçüde etkilemektedir. Ağıın yapı, veri kümesinin özelliklerine göre ve farklı parametreler deneyerek seçilmektedir. Ağrı derecelendirme için çeşitli evrişimsel sinir ağı yapıları denenmiştir. Tablo 5'te yapıları özetlenen bu ağılar arasında Fare-Mimik-Net3 en iyi performansa ulaşmış olan ağıdır ve farklı parametrelerin analizi sonucu ortaya çıkmıştır. Bu parametreler ilerleyen kısımlarda anlatılmıştır.

Yapılan denemelerde, evrişimsel katmanlardaki filtrelerin daha büyük seçilmesi performansın artmasını sağlamıştır. Katmanlardaki filtrelerin sayısının daha fazla seçilmesi ise daha karmaşık özniteliklerin bulunmasına yardımcı olmuştur. Fare-Mimik-Net3 ağı için denemelerin sonucunda en iyi performansı elde eden parametre değerleri kullanılmıştır. Bu üç ağıın performansı Bölüm 4.3.2'de açıklanmıştır. Sonrasında, bulgular kısmında açıklanan tüm deneylerde, ağrı derecelendirme için Fare-Mimik-Net3 ağı kullanılmıştır.

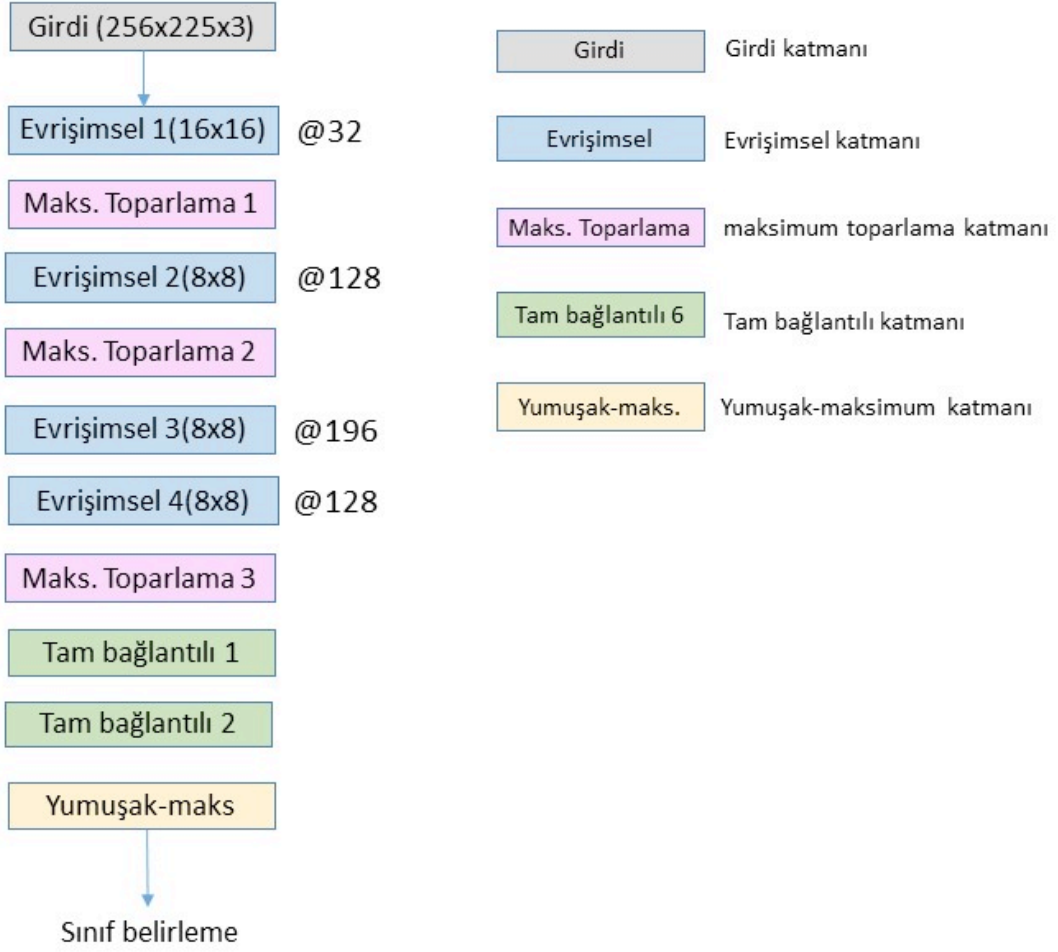
Tablo 5. Kullanılan evrişimsel sinir ağların özellikleri

Ağ	Girdi Görüntü	Katman Sayısı	Ağ yapısı (CONV: Evrişimsel katman, Pool:Toparlama Katman, FC: Tam bağlantılı katman, Softmax: Yumuşak-maksimum katman)
Fare-Mimik-NET1	64x64	6	CONV(10@64)-Pool(3)- CONV(32@32)-Pool(3)-FC(1024)-Softmax
Fare-Mimik-NET2	64x64x3	9	CONV(8@16)-Pool(3)- CONV(16@64)-Pool(3)-CONV(8@128)- CONV(8@128)- Pool(2)-FC(4096) -Softmax
Fare-Mimik-NET3	256x256x3	10	CONV(32@16)-Pool(4)- CONV(8@128)-Pool(4)- CONV(8@196)- CONV(8@128)-Pool(2)-FC(4096)-FC(4096)-Softmax

Bu ağın yapısı Şekil 21’de gösterilmiştir. Bu yapıda bir giriş katmanı, 4 evrişimsel katman, 3 toparlama Katmanı, 2 tam bağlantılı katman ve son olarak da yumuşak-maksimum (softmax) katmanı bulunmaktadır. İlk evrişimsel katmanında 32x32x3 piksel boyutunda 16 adet kernel, ikinci evrişimsel katmanında 8x8x16 boyutunda 128 adet kernel, üçüncü evrişimsel katmanında 8x8x128 boyutunda 196 adet kernel, dördüncü evrişimsel katmanında ise 8x8x196 boyutunda 128 adet kernel, kullanılmıştır.

Maksimum toparlama için 4x4 ve 2x2 piksellik filtreler kullanılmış ve adım boyu 4x4 için 4 ve 2x2 için 2 olarak alınmıştır. Son maksimum toparlama katmanından sonra iki 4096 boyutunda tam bağlantılı katman kullanılmıştır. Tam bağlantılı katmanlar, daha fazla öznelik kombinasyonlarının öğrenilmesini sağlayarak performansın artmasına sebep olmaktadır. Son katman olan yumuşak-maksimum katmanı 3 adet nörondan oluşmaktadır. Her bir nöron 3 ağırlı sınıftan birini temsil etmektedir.

Fare-Mimik-Net3 yapısının ilk evrişimsel katmanından sonra bir yığın (batch) normalizasyonu katmanı kullanılmıştır. Bu katmanda, evrişimsel katmanın çıktıları ortalama ve varyansa göre normalize edilir ve daha hızlı ve daha başarılı sınıflandırma sağlar (Lofe ve ark., 2015). Ağırlı derecelendirme uygulamasında “batch normalization” kullanımının performans artışına neden olduğu gözlemlenmiştir.



Şekil 21. Fare-Mimik-Net3 ağının yapısı

4. BULGULAR

Daha önce 3. bölümde detayları anlatılan gereç ve yöntemler için elde ettiğimiz bulgular bu bölümde detaylı olarak açıklanmış açıklanmıştır.

4.1. FARE YÜZÜNÜN TESPİTİ

Fare yüzü tespiti için Viola Jones (VJ) ve Evrişimsel Sinir Ağı (CNN) olmak üzere iki yöntem kullanılmıştır. Aşağıda bu iki yöntemle ilgili performans sonuçları sunulmuştur.

4.1.1 Viola Jones Yöntemi İle Fare Yüzü Tespiti

4.1.1.1 Viola Jones Sınıflayıcısının Eğitimi

VJ algoritması elle işaretlenmiş olan fare yüz kareleri kullanılarak eğitilmiştir. Algoritmanın eğitilmesi için bazal 1 videosundan, 2700 pozitif ve 5000 negatif yüz karesi kullanılmıştır. Eğitim esnasında kullanılan tüm parametreler Tablo 6'da gösterilmiştir.

Tablo 6. VJ Eğitiminde Kullanılan Parametreler

numPos	numNeg	numStages	minHitRate	max FalseAlarmRate	Boyut (piksel)	Eğitme süresi (gün:saat:dakika)
2700	5000	20	0.998	0.4	24x24	0:11:31

Eğitilen algoritma daha sonra tek bir video üzerinden alınan çok sayıda video çerçevesi üzerinde test edilmiştir. Test videosu toplam 4.606 adet işaretlenmiş fare yüz karesi içermektedir. Test için, videonun her çerçevesi farklı boyutlu pencereler ile taranıp, yüz bölgesinin tespit edilen parçaları belirlenmektedir. Bir parçayı doğru tespit olarak kabul etmemiz için bir kaç tane parçanın örtüşmesi gerekebilir. Bu değer minNeighbors parametresi ile belirlenmektedir. Örneğin minNeighbors 9 olduğunda, ancak 9 tane üst üste gelen parça (her biri kare biçiminde) tespit edilirse, doğru yüz parçası olarak belirlenir.

Performans ölçümü için minNeighbors parametresi, 1-20 arasında değiştirilip Duyarlılık (Precision), Geri-getirme (Recall) ve F1 skoru aşağıdaki gibi hesaplanmıştır:

$$\text{Duyarlılık} = (\text{Doğru bulunan yüz sayısı}) / (\text{Toplam bulunan yüz sayısı}),$$

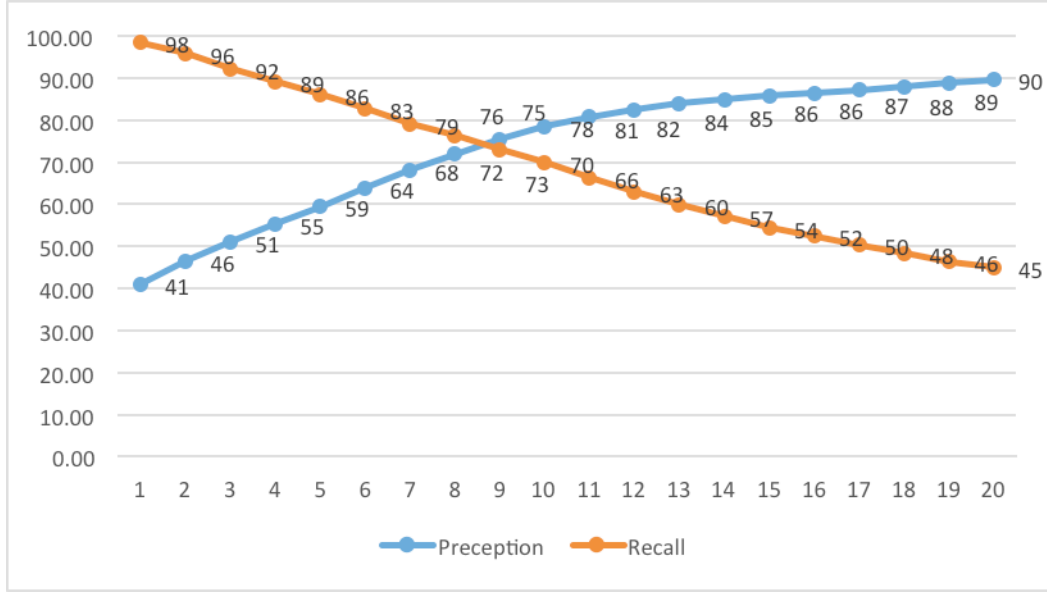
$$\text{Geri-getirme} = (\text{Doğru bulunan yüz sayısı}) / (\text{İşaretlenen doğru yüz sayısı}),$$

$$\text{F1} = 2 * (\text{Duyarlılık} * \text{Geri-getirme}) / (\text{Duyarlılık} + \text{Geri-getirme}).$$

Elde edilen sonuçlar Tablo 7 ve Şekil 22'de gösterilmiştir. En yüksek F1_skoru minNeighbors=9 için 74.18 olarak elde edilmiştir. Buna karşılık gelen Duyarlılık=%75.34 ve Geri-Getirme=%73.05 olarak gözlenmiştir. Ayrıca en iyi duyarlılık %89.62 ve en iyi Geri-getirme %98.43 olarak kaydedilmiştir.

Tablo 7. VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi

minNeighbors	Doğru bulunan yüz sayısı	Toplam bulunan yüz sayısı	İşaretlenen doğru yüz sayısı	Duyarlılık %	Geri-getirme %	F1 Skoru
1	4534	11054	4606	41.01	98.43	57.90
2	4408	9483	4606	46.48	95.70	62.57
3	4245	8325	4606	50.99	92.16	65.65
4	4101	7427	4606	55.21	89.03	68.16
5	3962	6662	4606	59.47	86.01	70.32
6	3808	5962	4606	63.87	82.67	72.06
7	3645	5360	4606	68.00	79.13	73.14
8	3518	4890	4606	71.94	76.37	74.09
9	3365	4466	4606	75.34	73.05	74.18
10	3224	4109	4606	78.46	69.99	73.98
11	3049	3774	4606	80.78	66.19	72.76
12	2894	3514	4606	82.35	62.83	71.28
13	2762	3291	4606	83.92	59.96	69.94
14	2629	3100	4606	84.80	57.07	68.22
15	2503	2916	4606	85.83	54.34	66.55
16	2413	2791	4606	86.45	52.38	65.23
17	2317	2660	4606	87.10	50.30	63.77
18	2220	2523	4606	87.99	48.19	62.27
19	2134	2402	4606	88.84	46.33	60.90
20	2073	2313	4606	89.62	45.00	59.92



Şekil 22. VJ Yönteminde Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi

4.1.1.2 Viola Jones için Sol/Karşı/Sağ Fare Yüzü Eğitim

VJ yüz tespiti yönteminin performansının artırılması için farklı bir eğitim yöntemi uygulanmıştır. İlk olarak yüz kareleri, sol, karşı ve sağ olmak üzere 3 farklı gruba ayrılmıştır. Her grup ayrı ayrı eğitilip sonuçları test videosu üzerinde hesaplanmıştır. Son olarak eğitilen algoritmalar art arda test videoya uygulanıp, sonuçlar toplanarak birleştirilmiştir.

Eğitmek için çıkarılan yüz kareleri, Kamera 1 ağırlı ve bazal videolarından eşit sayıda alınmıştır. Fare yüzlerinin işaretlenmesi için, daha önce eğitilen VJ algoritması kullanılarak yüz kareleri çıkarılmıştır. Otomatik olarak çıkarılan yüz kareleri, bir arayüz kullanılarak manuel temizlenmiştir. Bu yaklaşım kullanılarak, her videodan 6000 fotoğraf karesi işlenip toplam 3000 adet yüz karesi elde edilmiştir. Toplam işaretlenen karşıdan gözüken yüz sayısı (label 3 ve 4) 202'dir. Bu yüzlerden her bir grup için 202 pozitif örnek seçilmiştir. Negatif örnekler için toplam 440 görüntü parçası seçilmiştir. Bunlar fare vücudundan alınan çeşitli parçalardır.

VJ algoritması yukarıdaki üç grup için ayrı ayrı eğitilmiştir. Eğitilen algoritmaların başarı oranının ölçülmesi için, algoritmalar daha önceden manuel işaretlenen test videosu üzerinde uygulanmıştır. Test videosu, Kamera 2 ağırlı videosunun ilk 8000 çerçevesinden alınmıştır. Bu video 3539 sağ, 389 karşı ve 2247 sol olmak üzere toplam 6175 fare yüz karesi içermektedir.

Algoritmaların eğitilmesi için farklı parametreler denenmiştir. İlk denemelerde test videosundan elde edilen sonuçların %50 gibi düşük seviyelerde kaldığı gözlenmiştir.

Algoritmanın performansını arttırmak için, sağ ve sol fare yüz karesi setleri incelenmiş ve setler farklı görüntüler içermek üzere yeniden manuel olarak seçilmiştir. Negatif örnekler seti ise daha çok farenin gövdesini içeren görüntülerden seçilmiştir. Ayrıca daha önce 24x24'e alt-örnekleme (down sample) yapılarak kullanılan görüntüler, bu kez 64x64 piksele alt-örnekleme yapılarak algoritmayı eğitmek için kullanılmıştır. Eğitmek için kullanılan parametreler Tablo 8'de gösterilmiştir. Bu değerler, farklı denemeler sonucunda optimum değerler olarak tespit edilmiştir.

Tablo 8. VJ Yönteminin Sağ/Sol/Karşı Fare Yüzü için Eğitimindeki Parametreler

Grup	numPos	numNeg	numStages	min HitRate	maxFalse AlarmRate	Boyut (piksel)	Eğitme süresi (gün:saat:dakika)
Sol	180	440	12	0.998	0.2	64x64	3:1:59
Ön	180	440	11	0.998	0.2	64x64	0:7:31
Sağ	180	440	12	0.998	0.2	64x64	2:16:27

Test için, videonun 1-8000 aralığındaki çerçeveleri her grup için ayrı ayrı taranmıştır. Sol, Ön ve Sol grupları için performans kendi içinde hesaplanmıştır. Örneğin Karşı yüz örnekleriyle eğitilmiş algoritma performansı, sadece Karşı olarak işaretlenmiş olan karelerle karşılaştırarak Duyarlılık ve Geri-getirme hesaplanmıştır. Üç algoritmanın minNeighbors parametresinin farklı değerleri için elde edilen test sonuçları, Şekil 23, 24 ve 25'de ve Tablo 9, 10 ve 11'de gösterilmiştir.

Daha sonra, test için üç algoritmanın kararları birleştirilerek kullanılmıştır. Videonun her bir fotoğraf karesi için üç algoritma arka arkaya uygulanıp, bulunan yüz karelerin toplamı işaretlenen yüz kareleri ile karşılaştırılmıştır. Performans hesaplaması daha önce anlatıldığı gibi yapılmıştır. Ancak işaretlenen yüz kareleri grubu düşünmeksizin kullanılmıştır.

Duyarlılık, Geri-getirme ve F1 skoru sonuçları farklı parametre grupları için hesaplanmıştır. Parametre grupları, üç algoritma için kullanılan minNeighbors değerlerini içermektedir (Tablo 12).

Elde edilen sonuçların toplamı Şekil 26 ve Tablo 13'de verilmiştir. Bu sonuçlara göre en iyi F1 skoru 6. parametre grubu için, %80.99 olarak bulunmuştur. Burada Duyarlılık=%80 ve Geri-getirme=%82 olarak elde edilmiştir. Ayrıca en iyi duyarlılık %93 ve en iyi geri-getirme %94 olarak kaydedilmiştir.

Tablo 9. Sağa bakan fare yüzü grubu için VJ Yönteminin Duyarlılık, Geri-getirme ve F1 Skor değerlerinin minNeighbors sayısına göre değişimi

minNeighbors	Doğru bulunan yüz sayısı	Toplam bulunan yüz sayısı	İşaretlenen doğru yüz sayısı	Duyarlılık %	Geri-getirme %	F1 Skoru
10	3417	9045	3539	37	96	53.41
30	3307	5465	3539	60	93	72.94
50	3230	4462	3539	72	91	80.39
70	3165	3839	3539	82	89	85.36
90	3066	3483	3539	88	86	86.99
110	2951	3199	3539	92	83	87.27
130	2812	2953	3539	95	79	86.26
150	2730	2812	3539	97	77	85.85
170	2626	2667	3539	98	74	84.33
190	2466	2481	3539	99	69	81.32

Tablo 10. Sola bakan fare yüzü grubu için VJ Yönteminin Duyarlılık, Geri-getirme ve F1 skor değerlerinin minNeighbors sayısına göre değişimi

minNeighbors	Doğru bulunan yüz sayısı	Toplam bulunan yüz sayısı	İşaretlenen doğru yüz sayısı	Duyarlılık %	Geri-getirme %	F1 skoru
11	1823	2858	2247	63	81	70.88
21	1689	2233	2247	75	75	75.00
31	1539	1900	2247	81	68	73.93
41	1434	1665	2247	86	63	72.72
51	1307	1476	2247	88	58	69.92
61	1195	1320	2247	90	53	66.71
71	1117	1211	2247	92	49	63.94
81	1040	1103	2247	94	46	61.77
91	952	997	2247	95	42	58.25

Tablo 11. Karşıya bakan fare yüzü grubu için VJ Yönteminin Duyarlılık, Geri-getirme ve F1 skor değerlerinin minNeighbors sayısına göre değişimi

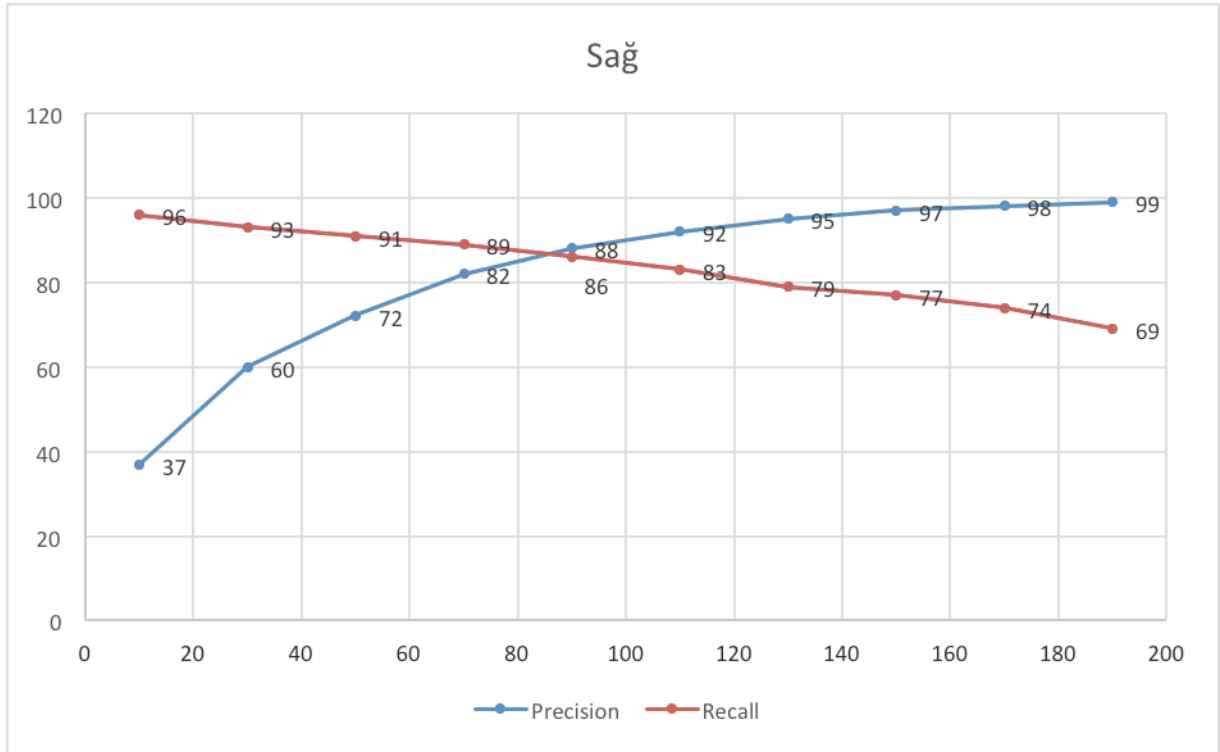
minNeighbors	Doğru bulunan yüz sayısı	Toplam bulunan yüz sayısı	İşaretlenen doğru yüz sayısı	Duyarlılık %	Geri-getirme %	F1 Skoru
101	102	433	389	23	26	24.41
121	57	217	389	26	14	18.20
141	36	119	389	30	9	13.85
161	18	62	389	29	4	7.03
181	8	30	389	26	2	3.71
201	3	18	389	16	0	0.00
221	2	11	389	18	0	0.00
241	2	6	389	33	0	0.00
261	1	5	389	20	0	0.00
281	1	4	389	25	0	0.00

Tablo 12. Sağ, Sol ve Karşı yüz grupları için ayrı eğitilmiş VJ Yönteminin, birleştirilmiş kümede birlikte kullanımı için performansı karşılaştırılan parametre grupları

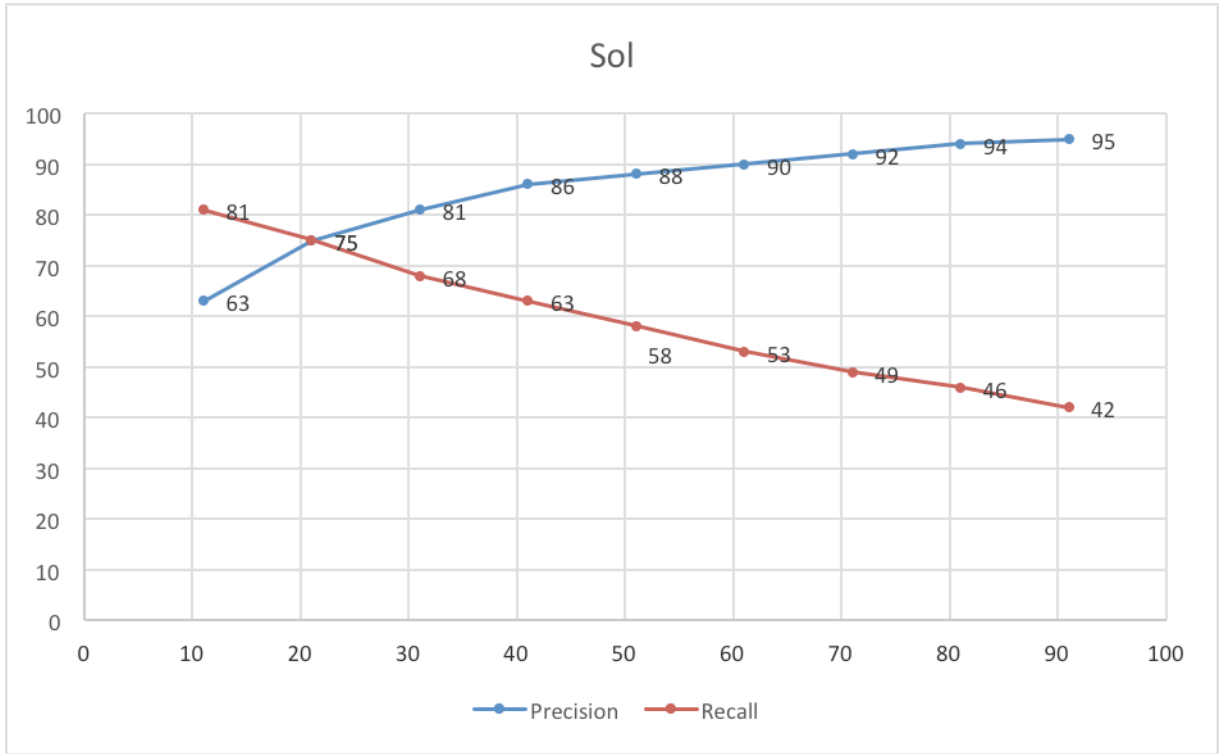
Parametre grubu	1	2	3	4	5	6	7	8	9	10
minNeighbors sol	272	100	332	352	392	200	250	300	432	300
minNeighbors frontal	11	150	41	51	71	200	200	200	91	200
minNeighbors sağ	22	40	82	102	142	100	100	80	182	150

Tablo 13. Sağ, Sol ve Karşı yüz grupları için ayrı eğitilmiş VJ Yönteminin, parametre gruplarına göre birleştirilmiş kümede birlikte başarısı

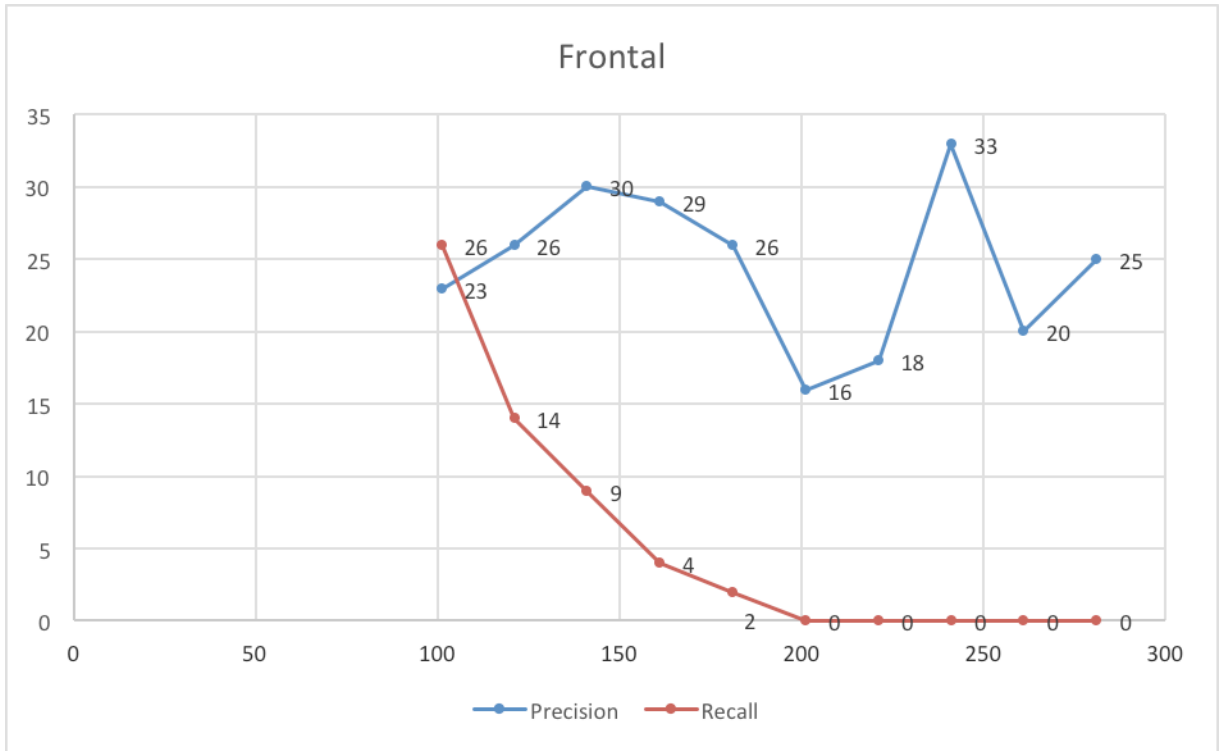
Parametre grubu	Doğru bulunan yüz sayısı	Toplam bulunan yüz sayısı	İşaretlenen doğru yüz sayısı	Duyarlılık %	Geri-getirme %	F1 skoru
1	5865	23878	6175	24	94	38.24
2	5577	11943	6175	46	90	60.88
3	5293	9916	6175	53	85	65.29
4	5073	7541	6175	67	82	73.74
5	4476	5688	6175	78	72	74.88
6	5082	6322	6175	80	82	80.99
7	4980	5789	6175	86	80	82.89
8	4924	5613	6175	87	79	82.81
9	4040	4525	6175	89	65	75.13
10	4479	4814	6175	93	72	81.16



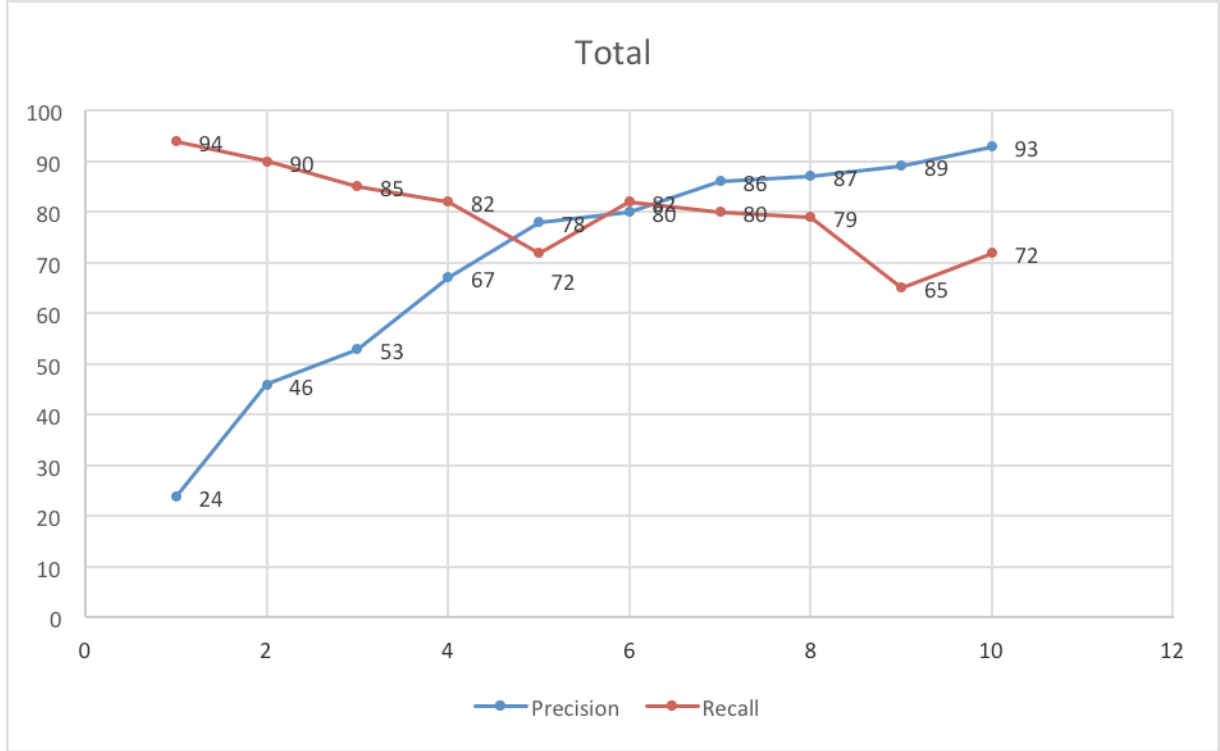
Şekil 23. Sağa bakan fare yüzleri seti için VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi



Şekil 24. Sola bakan fare yüzleri seti için VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi



Şekil 25. Karşıya bakan fare yüzleri seti için VJ Yönteminin Duyarlılık ve Geri-getirme değerlerinin minNeighbors sayısına göre değişimi




Şekil 26. Sağ Sol ve Karşı yüz setleri için ayrı eğitilmiş VJ Yönteminin, birleştirilmiş kümede birlikte başarısı


4.1.2.1 Yüz Onaylama için Kullanılan Evrişimsel Sinir Ağı sonuçları

Yüz onaylama için kullanılan evrişimsel ağın eğitimi için, 6777 pozitif ve 6898 negatif olmak üzere toplam 13675 fare yüz karesi görüntüsü kullanılmıştır. Eğitim esnasında kullanılan validasyon seti içinse, 1500 pozitif ve 1493 negatif olmak üzere toplam 2993 görüntü kullanılmıştır. Eğitim için kullanılan veri setinden pozitif ve negatif örnekler Şekil 27'de gösterilmiştir.

Ağın eğitiminde "Adam" eniyileyici kullanılmıştır. Eğitim esnasındaki performans ölçümleri iterasyon sayısına göre Şekil 28'de gösterilmiştir. Şekilde görüldüğü gibi, iterasyon sayısı arttıkça, başarı oranı artıp, kayıp oranı düşmektedir.



Şekil 27. Eğitim için kullanılan örnek fare yüz kareleri a) Pozitif, b) Negatif



Şekil 28. Yüz onaylama ağının eğitimi esnasındaki performans ölçümleri

Eğitilen derin sinir ağının performansını ölçmek için, 1000 negatif ve 1000 pozitif görüntüden oluşan bir test veri seti kullanılmıştır. Görüntüler, eğitim için kullanılmayan yeni bir videodan elle seçilmiştir. Pozitif görüntüler, farklı açılardan çekilen fare yüz karelerini içermektedir. Negatif görüntüler ise, farenin gövdesi ya da arka plan karelerini içermektedir. Elde edilen sınıflandırma sonuçları Tablo 14'de gösterilmiştir.

Tablo 14. Yüz onaylama ağının performansı

	Görüntü sayısı	Doğru	Yanlış	Başarı oranı
Pozitif	1000	1000	0	%100
Negatif	1000	998	2	%99.8

Tablo 14'de görüldüğü gibi, 256x256 büyüklüğündeki 1000 tane fare yüzü örneğinin (pozitif örnekler) tamamı doğru bulunmuştur. Fare yüzüne karşılık gelmeyen 1000 negatif örnekten ise sadece iki örneğe yüz olarak karar verilmiştir. 256x256 büyüklüğündeki her bir girdi örnek için Fare Yüzü Onaylama ağının hesaplama süresi ortalama PC için 160 milisaniye, iş istasyonu üzerinde 9.9 milisaniyedir.

4.1.2.2 Odak Alanı Tarama Sonuçları

Fare yüzünün bulunması için, odak alanının Fare Yüzü Onaylama ağı kullanılarak tarama yapılırken iki farklı yaklaşım kullanılmış ve bu yaklaşımlar Bölüm 3.2.2.3 'de açıklanmıştır. Ortalama yüz bulma süresi 1. yaklaşım için PC'de 300 saniye, iş istasyonunda 31 saniye, 2. yaklaşım içinse PC'de 40 saniye ve iş istasyonunda 3.8 saniyedir. Bu süre odak alanı büyüklüğü ve fare yüzü büyüklüğüne göre değişmektedir. Bu çalışmanın devamında, odak alanı taramak için 2. yaklaşım kullanılmıştır.

4.2. FARE YÜZÜNÜN VİDEODA TAKİP EDİLMESİ

Bu bölümde fare yüzü takibi için geliştirilen yöntemin performans sonuçları sunulmuştur.

4.2.1 Test için kullanılan ağlar

Önerilen takipçi performansını değerlendirmek için dört MFTN versiyonu; yani MFTN-GOTURN, MFTN/cp, MFTN/c ve MFTN-VGG-CNN-F, eğitilip ve test edilmiştir. Daha önce de belirtildiği gibi, takipçi ile ilgili çalışmanın literatüre en önemli katkısı, FAN'ın MFTN yapısına eklenmesidir. FAN içermeyen MFTN versiyonları, MFTN-VGG-CNN-F ve MFTN-GOTURN ağlarının orijinal formları literatürde zaten mevcuttur. FAN'ın kullanıldığı yeni önerilen ağlar için, yani MFTN/cp ve MFTN/c, en iyi FAN yapısı ön deneyler aracılığıyla FEN'in farklı katmanlarının çıkışlarını FAN'a düşük veya yüksek seviyeli özellikler olarak besleyerek ve

aynı zamanda FAN'da kıvrım katmanlarının sayısını değiştirerek araştırılmıştır. FAN için bulduğumuz en iyi yapı, daha önce Şekil 15'te göstermiştir.

4.2.2. Takipçi için Test Prosedürü

Tek hedef nesne takipçisinin performansını değerlendirmek için literatürde çeşitli performans ölçütleri kullanılmıştır. Cehovin vd. (2014) yaygın olarak kullanılan bazı popüler performans ölçümlerini bir video dizisi ($n = 25$) üzerinde farklı takipçileri ($n = 13$) değerlendirmişlerdir. Analiz ettikleri performans ölçüm yaklaşımları arasında, doğruluk oranını ölçmek için gerçek pozitif karşı bölge örtüşmesi eşiği (TP-ROT) grafiğini ve sağlamlık oranını ölçmek için başarısızlık oranı karşı yeniden başlatma eşiği (FR-RT) grafiğini kullanmayı önermişlerdir. Ayrıca, doğruluk ve sağlamlığı birlikte değerlendirmek için, doğruluk karşı sağlamlık (A-R) grafiğinin kullanımını önermişlerdir.

Takipçilerin objektif bir değerlendirmesi için, bölüm 3.3.5'te açıklanan takipçi hedef kaybetme tespit mekanizması kapatılmıştır. Hedef ve kesin referans sınırlayıcı kutunun örtüşmesi yeniden başlatma eşiğinin (RT) altına düşmesi durumunda takipçinin başarısız olduğu varsayılmıştır. Takipçi başarısız olduğu durumda, hedef konum yerin kesin referansdan yeniden başlatılmaktadır.

TP-ROT grafiği, RT değeri 0 değerine ayarlanarak hazırlanmıştır. Her takipçi tüm test videolarında çalıştırılmış ve son grafiklerin elde edilmesi için sonuçların ortalaması alınmıştır. TP değeri, örtüşme oranı değerlerinin ROT değerinden daha büyük olan video karelerinin sayısının toplam video karelerinin sayısına bölünmesiyle hesaplanmaktadır. Eğri altında alan (Area under curve, AUC) için elde edilen daha yüksek bir değer daha iyi bir performansın göstergesidir. Doğruluk oranı TP-ROT grafiğinin altında kalan alan (Area Under Curve, AUC) hesaplanarak elde edilmektedir.

FR-RT grafiği, RT değiştirilerek hazırlanmıştır. Bu grafiğinin hazırlamak için, takipçiler tüm test videolarında, 0 ile 0.98 arasında değişen ve 0.02'lik bir adım değeri olan 50 farklı RT değeriyle çalıştırılmıştır. FR değeri, yeniden başlatma durum sayısını toplam video karesi sayısına bölerek hesaplanır. FR-RT grafiğinde, daha düşük bir AUC değeri daha iyi performans göstergesidir. Sağlamlık, FR-RT grafiğinin altında kalan alan 1'den çıkarılarak hesaplanmaktadır.

A-R grafiği hesaplanan doğruluk ve sağlamlık değerleri kullanılarak hazırlanmıştır. A-R grafiğinin sağ üst köşesi en iyi performansa karşılık gelmektedir.

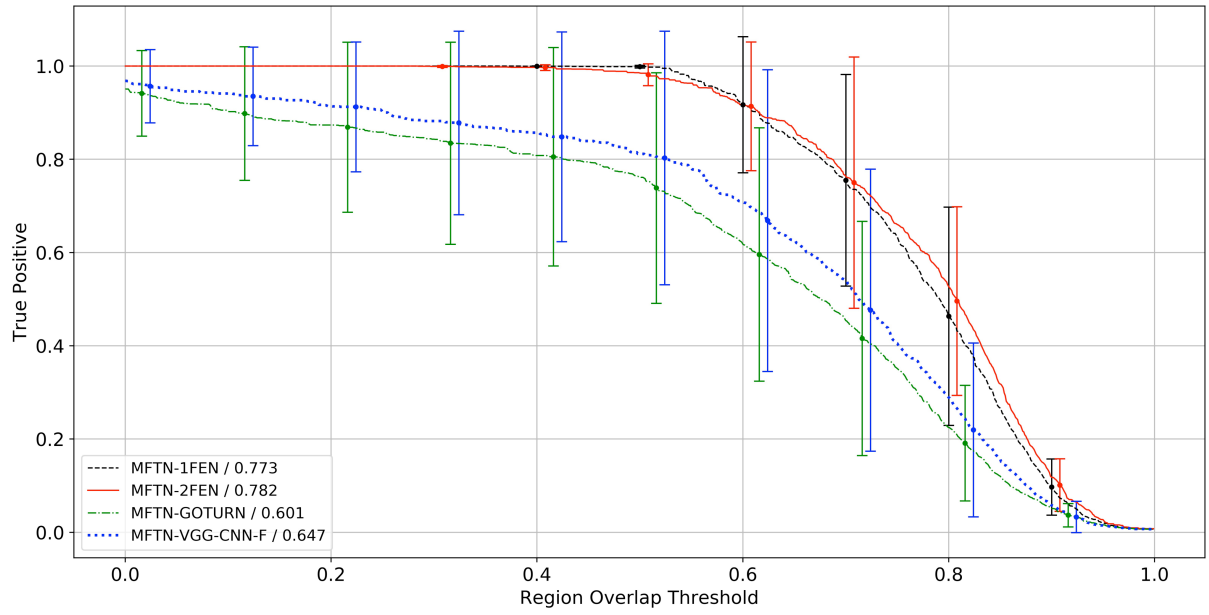
Takipçinin verimi (throughput), çevrim dışı olarak, toplam video karesi sayısının toplam işlem süresine bölünmesiyle hesaplanmıştır. Bu değer aşağıda açıklanan yedi adet test videosunun her birinde 50 farklı RT değeri için tekrarlanmış ve sonra ortalaması alınmıştır.

4.2.3. MFT Test Videoları

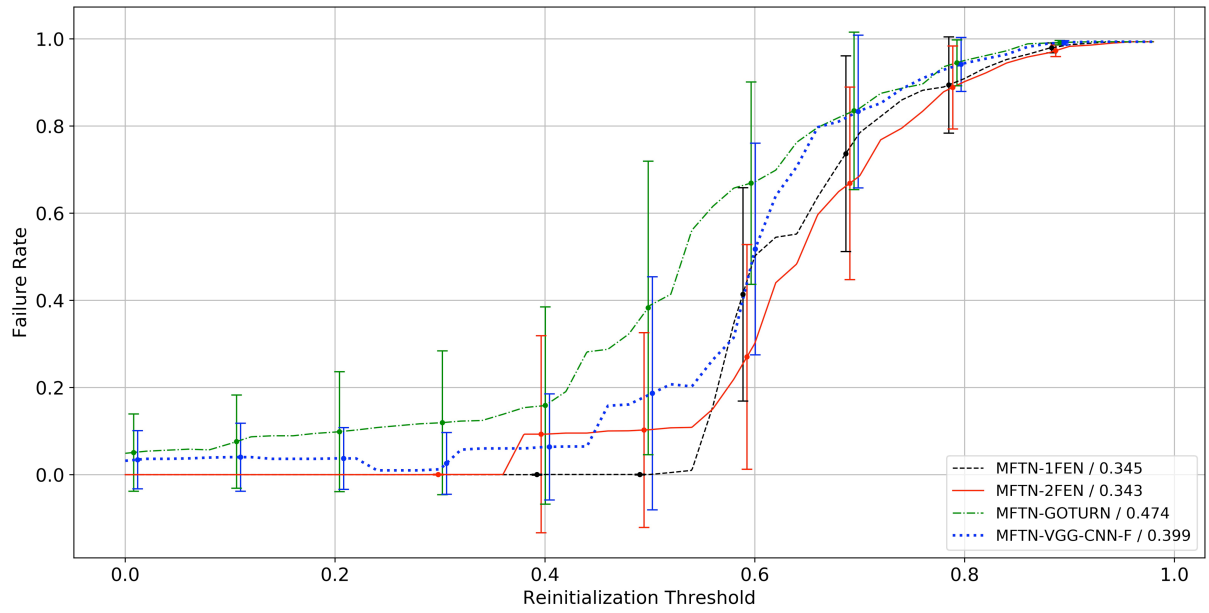
Önerilen takipcinin performansını ölçmek için bir dizi test videosu hazırlanmıştır. Bu amaçla, MFT veri setinde yer almayan dördüncü bir deneyde kaydedilen bir videodan yedi test video sekansı kesilmiştir.. Sekanslar, fare yüzünün görünürlüğü ve hareketi dikkate alınarak seçilmiştir. Ayrıca, bu diziler, fare yüzünün kısmen görülebilmesi veya bazı çerçevelerde farenin çok hızlı hareket etmesi nedeniyle takip edilmesi zor dizilerdir. Bu test videolarındaki video karesi sayısı 56 ile 435 arasında değişmektedir, ortalama ve standart sapma değerleri 234 ve 136 olarak hesaplanmıştır. Bu test videolarının, her bir video karesinde fare yüzünün konumu performans ölçümleri için elle işaretlenmiştir. Sonuç olarak, toplam 1640 kare işaretlenmiştir.

4.2.4. MTFN Takipçi Performansları


Bu bölümde, FAN'ın MFTN performansına etkisi, deneysel sonuçlarla açıklanmış ve iki FEN kullanımı gerekliliği tartışılmıştır. Şekil 29'da, MFTN-GOTURN, MFTN/cp, MFTN/c ve MFTN-VGG-CNN-F ağları için TP-ROT grafikleri, bu yöntemler için hesaplanan doğruluk değerleri ile birlikte sunulmuştur. Şekil 30'da, FR-RT grafiği sağlamlık değerleri ile birlikte verilmektedir. A-R grafiği Şekil 31'de sunulmuştur. Bu sonuçlar, FAN'ın kullanıldığı MFTN/cp ve MFTN/c takipçilerinin, FAN içermeyen MFTN-GOTURN ve MFTN-VGG-CNN-F takipçilerinden bariz olarak daha iyi çalıştıklarını göstermektedirler. Bu, FAN'ın takipçi performansını hem doğruluk hem de sağlamlık açısından arttırdığını göstermektedir. Ayrıca, MFTN/c ve MFTN/cp performansları hemen hemen aynı ve MFTN-VGG-CNN-F'nin performansı her iki metrikle de MFTN-GOTURN performansından daha iyi olmaktadır. Bu sonuçlar FEN/p kullanımının herhangi bir avantaj sağlamadığını göstermektedir.



Şekil 29. MFTN takipçileri için TP-ROT grafiği (hedef kaybı ve yeniden başlatılma durumunda). Doğruluk değerleri AUC'leri kullanarak hesaplanmış ve takipçilerin adlarının hemen ardından verilmiştir.



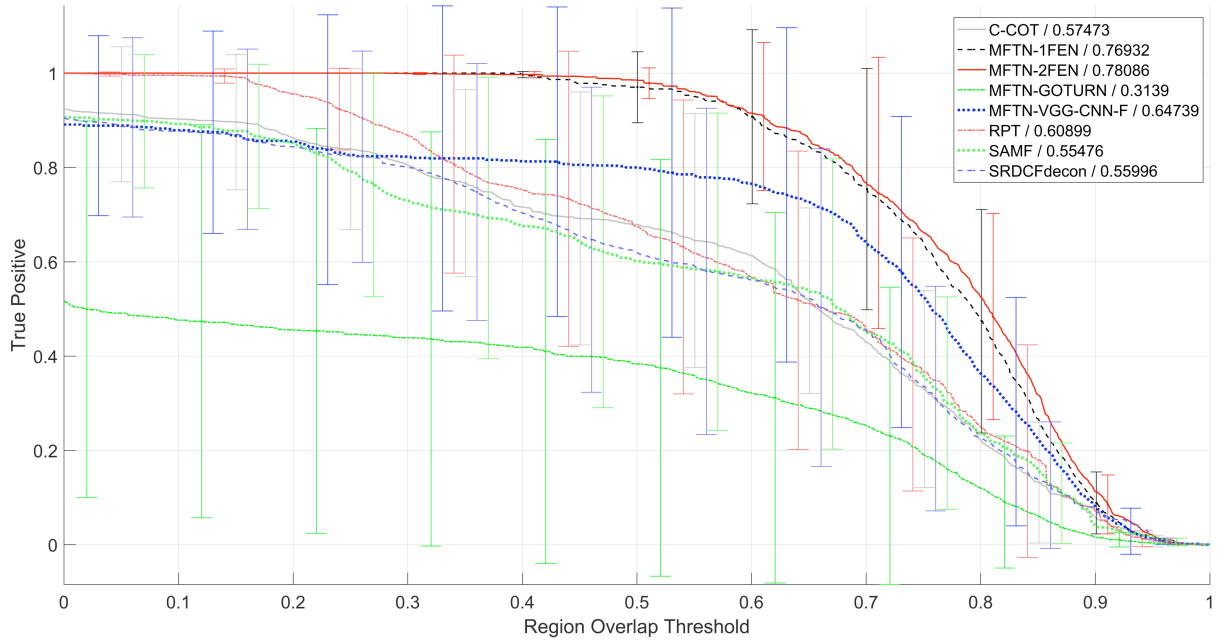
Şekil 30. MFTN takipçileri için FR-RT grafiği (hedef kaybı ve yeniden başlatılma durumunda). Sağlamlık değerleri 1-AUC değeri kullanarak hesaplanmış ve takipçilerin adlarının hemen ardından verilmiştir.



Şekil 31. MFTN takipçileri için A-R grafiği. Grafiği hazırlamak için Şekil 29 ve 30'da hesaplanan doğruluk ve sağlamlık değerleri kullanılmıştır.

4.2.5. Konvensiyonel takipçilerle karşılaştırma

MFTN takipçileri, kaynak kodları olan bazı konvensiyonel takipçilerle karşılaştırılmıştır. Bunlar, C-COT (Danneljan 2016), RPT (Yang vd. 2015), SAMF (Yang ve Zhu, 2014) ve SRDCFdecon (2016) takipçileridir. Deneylerimizde, C-COT algoritması HOG özelliklerin çoklu çözünürlüklerinde kullanılmıştır. Doğruluk değerleri de dahil olmak üzere tüm takipçiler için TP-ROP grafiği Şekil 32'de verilmiştir. Bilinen takipçiler için yeniden başlatma mekanizması kaynak kodlarında açık olmadığı için, bu deneyde, ne bilinen ne de MFTN takipçileri hedef kaybı durumunda yeniden başlatılmamıştır. FAN kullanan MFTN takipçileri en iyi performansı vermektedir. Yeniden başlatma durumu kaldırıldığında MFTN/c MFTN/cp'den biraz daha iyi performans göstermektedir. MFTN-GOTURN, MFT veri seti ile eğitilmiş olsa da, hedefi kolayca kaybetmekte ve böylece, performansı diğer takipçilerden daha düşük olmaktadır. MFT-VGG-CNN-F'nin, fare yüzünü takip etme görevlerinde konvensiyonel takipçilerden daha iyi performans gösterdiği görünmektedir, ancak bu performans MFT/c ve MFT/cp performanslarından oldukça düşüktür.



Şekil 32. Önerilen MFTN takipçilerinin bilinen takipçilerle karşılaştırılması (hedef kayıp durumunda yeniden başlatma olmaksızın). Doğruluk değerleri, eğri altındaki alan (AUC) değerleri kullanarak hesaplanmış ve takipçilerin adlarının hemen ardından verilmiştir.

4.2.6 Takipçi Sistem Performansı

Tüm takipçiler Intel Core i7 3.3 GHz merkezi işlem birimi (CPU) ve NVidia TitanX grafik işlem birimi (GPU) içeren bir iş istasyonunda test edilmiştir. Bu iş istasyonu Intelligent Systems ve Computer Vision araştırma laboratuvarında (ODTÜ VISION) bulunmaktadır. Ağların uygulanmasında Caffe derin öğrenme çerçevesi kullanılmıştır. Yapay sinir ağlarının mimarisi paralel hesaplama için çok uygun olduğundan, GPU üzerinde daha hızlı çalışmaktadır. Önerilen MFTN takipçileri, GPU'da CPU'dan neredeyse 35 kat daha hızlı çalışmaktadır.

Optimize edilmemiş koddaki takipçilerin verimlilikleri Tablo 15'te verilmiştir. FEN/p'nin kullanılmadığı MFTN/c ve MFTN-VGG-CNN-F takipçileri, FEN/p'yi içeren MFTN/cp ve MFTN-GOTURN'den bariz olarak daha hızlı çalışmaktadır. MFTN-VGG-CNN-F, FEN/p ve FAN'ı içermeyen en küçük ağa sahip olduğu için MFTN takipçileri arasında en hızlı takipçi olarak bulunmaktadır. Bu ağda hem FEN/p hem de FAN kullanıldığı için MFTN/cp en yavaş takipçi olmaktadır. Bilinen takipçilerle karşılaştırıldığında, MFTN ağları GPU birimi nedeniyle çok daha hızlıdır. Takipçiler için çıktılar sadece CPU kullanılarak da test edilmiştir. SAMF dışındaki tüm takipçiler benzer verim elde edilmiş. Bunlar arasında MFTN-VGG-CNN-F ve MFTN/c biraz daha hızlı olmaktadır.

Tablo 15. MFTN ve konvensiyonel takipçilerin verimleri.

Ağın Adı	Verim(fps)	
	GPU ile	Sadece CPU ile
MFTN-VGG-CNN-F	294.9	6.1
MFTN/c	213.9	4.3
MFTN-GOTURN	127.6	3.1
MFTN/cp	113.7	3.0
RPT	-	3.5
C-COT	-	3.7
SRDCFdecon	-	3.0
SAMF	-	16.5

4.2.7. Tespit-Takipçi Entegrasyonunda Takipçinin onaylanarak kullanılması

Tespit ve takip algoritmalarının uyumluluğu bu algoritmaların bulunduğu alanların piksel bazında ara kesitinin (örtüşme) piksel bazında alanı, takip ve tespit algoritmalarının bulunduğu alanlara bölünerek incelenmiştir. Daha sonra değişen eşik değerlerine (T) göre kaç tane fotoğraf karesi için eşik değerinin üstüne geçildiğine bakılarak P ve R değerleri hesaplanmıştır.

$$P = \left(\frac{\text{Örtüşme Alanı/Takip Alanı} > T}{\text{Toplam video karesi sayısı}} \right) \text{ şartını sağlayan video karesi sayısı} /$$

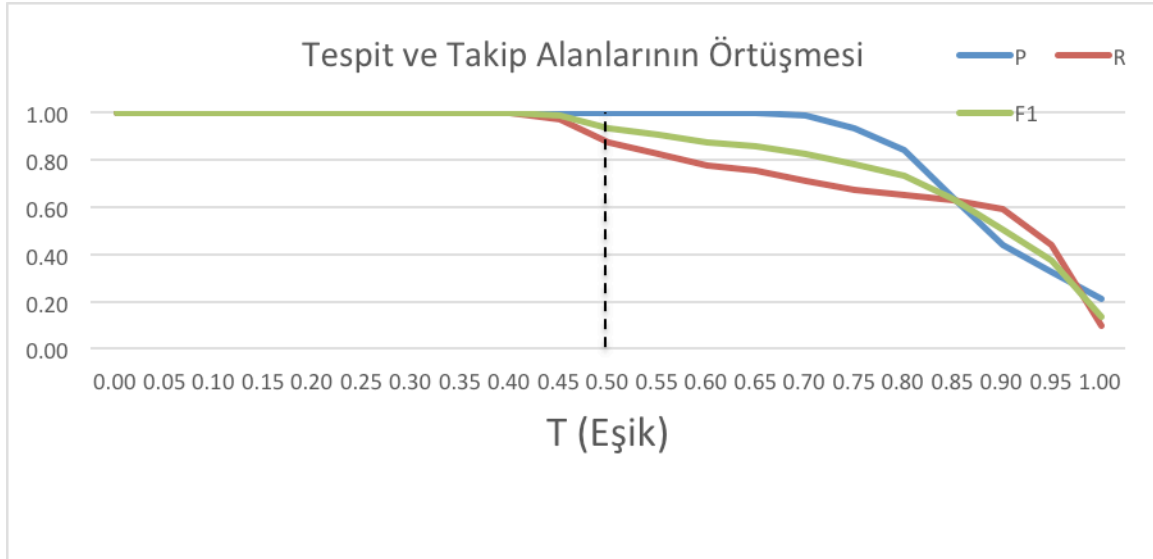
$$R = \left(\frac{\text{Örtüşme Alanı/Tespit Alanı} > T}{\text{Toplam video karesi sayısı}} \right) \text{ şartını sağlayan video karesi sayısı} /$$

$$F1 = 2 * (P * R) / (P+R)$$

Uyumluluğun ölçülebilmesi için, toplam 935 adet fotoğraf karesi içeren bir videoda eşik değeri T değiştirilerek P, R hesaplanmıştır. Elde edilen sonuçlar Tablo 16'da verilmiş ve Şekil 33'te gösterilmiştir. Ayrıca bu iki değerlerin harmonik ortalaması olan F1 değeri hesaplanmıştır. Bu ölçümler Fare Yüzü Tespit ve Takip yöntemlerince bulunan alanlar arasındaki uyumu göstermektedir.

Tablo 16. Örtüşme için değişik eşik değerlerine göre P, R ve F1 değerlerinin değişimi

T (Eşik)	P	R	F1
0.00	1.00	1.00	1.00
0.05	1.00	1.00	1.00
0.10	1.00	1.00	1.00
0.15	1.00	1.00	1.00
0.20	1.00	1.00	1.00
0.25	1.00	1.00	1.00
0.30	1.00	1.00	1.00
0.35	1.00	1.00	1.00
0.40	1.00	1.00	1.00
0.45	1.00	0.97	0.98
0.50	1.00	0.87	0.93
0.55	1.00	0.82	0.90
0.60	1.00	0.77	0.87
0.65	1.00	0.75	0.86
0.70	0.98	0.71	0.82
0.75	0.93	0.67	0.78
0.80	0.84	0.65	0.73
0.85	0.64	0.63	0.63
0.90	0.44	0.59	0.50
0.95	0.33	0.44	0.37
1.00	0.21	0.10	0.13



Şekil 33. Örtüşme için değişik eşik (T) değerlerine göre P, R ve F1 değerlerinin değişimi

Değişik T değerleri için örtüşme eşiği olarak literatürde genel kabul gören 0.5 eşik değeri için $P=1.0$, $R=0.87$, $F1=0.93$ 'dür, bu durum takipçinin bulunduğu alanla tespit edilen alanın hemen hemen en az %50 çakıştığını göstermektedir. Görüntülerin bir kısmında tespit alanı takip alanından büyük, bir kısmında ise küçüktür. Takipçi çıktı olarak her hangi bir büyüklük üretebilmekte, Tespit algoritması ise görüntüyü kesikli ölçekler için taramaktadır. Genelde farklılık bundan kaynaklanmaktadır.

4.3. FARELERDE AĞRININ OTOMATİK DERECELENDİRİLMESİ

4.3.1. Ağrı Deneylerinden Veri Toplama ve Etiketleme

Takip ve Tespit Algoritmalarının Entegrasyonu Çoklu Kamera düzeneğinde başarıyla yapılmış Bölüm 3.3.6'da detaylı olarak anlatılmıştı. Karın ve baş ağrıları için çekilen deney videoları entegre tespit ve takip sistemini kullanılarak analiz edilmiştir. Ağrı denelerinde ilk 30 dakika farenin bazal videosu kaydedilip ardından ağrı geliştirilip 40-60 dakika daha video kaydı yapılmıştır.

6 kameralı ODTÜ-HÜ gözlem kutusunda 6 tane karın ağrısı ve 6 tane baş ağrısı deneyi yapılmıştır. 2 kameralı Langford gözlem kutusunda, sadece 6 tane karın ağrısı deneyi yapılmıştır. Bu bölümün sonunda daha detaylı açıklandığı üzere, Langford kutusundaki başarının ODTÜ-HÜ gözlem kutusuna göre oldukça düşük olmasından ve ODTÜ-HÜ gözlem kutusunun farenin hareketini sınırlamama avantajından dolayı, en düşük sayıda hayvan kullanma etik kuralı çerçevesinde Langford gözlem kutusunda baş ağrısı deneylerinin yapılmasından vazgeçilmiştir.

Ağrı deneylerinde çekilen videolardaki fare yüzü bölgesi tespit ve takip sisteminde analiz edilerek bulunmuştur. Ardından sistemin bulunduğu fare yüzlerindeki ifadeye ekip uzmanları tarafından bakılarak ağrının derecesi manuel olarak video karelerinde etiketlenmiştir.

İlk deneyler 6 kameralı ODTÜ-HÜ gözlem kutusunda karın ağrısı oluşturularak yapılmıştır. Bu deneylerin video kayıtlarından toplamda bulunan ve derecelendirilen video karelerin sayısı Tablo 17'de sunulmuştur.

Tablo 17. Altı kameralı ODTÜ-HÜ deney ortamı karın ağrısı deneyleri.

Karın ağrısı deneyi	Ağrılı Video	
	Tespit olunmuş fare yüzü içeren kare sayısı	Ağrı derecelendirilmesi yapılan kare sayısı
Deney no		
1	92,825	50,617
2	93,625	16,600
3	88,475	16,071
4	93,925	17,117
5	94,275	17,414
6	89,275	3750
TOPLAM	552,400	121,569

Karın ağrılı 6 kameralı deney düzeneğinde farenin karın ağrısı olan videolarda toplam 121,569 kare tespit edilip ve manuel olarak derecelendirilmiştir. Bu ağrılı videolarda, ağrısız olarak etiketlenmiş fare yüzü görüntüsünün az olmasından dolayı ayrıca bazal videolardan da toplam 4800 kare seçilerek etiketlenmiştir.

Bu deneyler ilk yapıldığından çok sayıda video karesi uzmanlar tarafından etiketlenmiştir. Ancak, yapılan incelemelerde ağrı deneylerinde farenin, ağrıdan dolayı daha az hareket ettiği ve bu sebepten peşpeşe karelerde aynı yerde, aynı pozisyonda durduğu ve mimiklerinin değişmediği gözlemlenmiştir. Dolayısıyla bu video karelerinden eğitim için faydalı yeni bir bilgi gelmediği sonucuna varılmıştır.. Ağrı derecelendirmesi çok zaman alıcı bir işlem olduğu ve aynı görünümdeki video kareleri için aynı ağrı derecesini sisteme girmek uzmanlarımıza çok zaman kaybına sebep olduğu için tespit ve takip sisteminin sonucunda elde edilen kareler gözden geçirilip farenin kırdamadığı kareler veri kümesinden elenmiştir. Bu işlem sayesinde daha küçük bir veri seti oluşturulup grubumuzdaki uzmanlara derecelendirmek üzere aktarılmıştır.

Benzer şekilde 2 kameralı Langford deney düzeneğinde karın ağrılı toplam 6 tane deney yapılmıştır. Ardından fare yüzü tespit edilip, benzer kareler atılıp ve grubumuzun uzmanları tarafından derecelendirilmiştir. Bu deneylerden elde edilen toplam kare sayıları ve derecelendirilen kare sayıları altındaki Tablo 18'de sunulmuştur.

Tablo 18. İki kameralı Langford deney ortamı karın ağrısı deneyleri. Bazal videolarda ayrıca 3658 video karesi işaretlenmiştir.

Karın ağrısı deneyi	Ağrılı Video	
Deney no	Tespit olunmuş fare yüzü içeren kare sayısı	Ağrı derecelendirilmesi yapılan kare sayısı
1	75,150	4,750
2	92,650	8,469
3	88,500	7460
4	85,725	764
5	99,800	364
6	93,825	479
TOPLAM	535,650	22,286

Karın ağrılı 2 kameralı Langford deney düzeneğinde farenin karın ağrısı olan videolarda toplam 22,286 video karesi, bazal videolarda ise toplam 3658 kare seçilerek manuel olarak derecelendirilmiştir.

Daha önce anlatıldığı gibi, başağrısı kafa tramvası ile modellenmiştir. 6 kameralı ODTÜ-HÜ deney düzeneğinde baş ağrılı toplam 6 tane deney yapılmıştır. Bu deneylerden elde edilen toplam video karesi sayıları ve derecelendirilen kare sayıları Tablo 19'da sunulmuştur.

Tablo 19. Altı kameralı ODTÜ-HÜ deney ortamı baş ağrısı deneyleri

Baş ağrısı deneyi	Ağrılı Video	
Deney no	Tespit olunmuş fare yüzü içeren kare sayısı	Ağrı derecelendirilmesi yapılan kare sayısı
1	103,600	978
2	101,425	981
3	102,275	454
4	91,800	420
5	97,925	360
6	101,550	465
TOPLAM	598,575	3,658

Proje önerisinde planlanmasına rağmen, projedeki gelişmelere bağlı olarak iki kameralı Langford deney ortamında baş ağrısı deneylerinin yapılmasından vazgeçilmesi kararı alınmıştır. Bunun sebebi: 1) Langford kutusu ile ilgili literatürde bu kutunun farenin hareketlerini sınırlamak suretiyle fare için stres yaratıcı olması eleştirisinin yer alması, 2) ODTÜ-HÜ deney ortamında elde edilen otomatik değerlendirme başarısının Langford deney ortamına göre daha yüksek olması 3) Langford kutusunda farenin huzursuzluğunun yanı sıra fare kuyruğunun görüntüde sıkça gözükmesi ve ayrıca kutunun küçük olmasından dolayı buharlanma ve diğer kirlenmeler nedeniyle görüntü kalitesinin bozulması, 4) Karın ve baş ağrısı deney sonuçlarının benzerlik göstermesidir. Tüm bunlar göz önüne alındığında, gereksiz yere farenin telef edilmesine sebep vermemek üzere etik kurallar çerçevesinde iki kameralı Langford deney ortamında baş ağrısı deneylerinin yapılmasından vazgeçilmiştir.

4.3.2 Fare Yüzü Ağrı Derecelendirmesi Deneysel Sonuçları

Evrimsel sinir ağına dayalı olarak geliştirdiğimiz Fare Mimik Net'in eğitimi için farklı videolardan alınan ve daha önce uznarca manuel olarak işaretlenmiş olan fare yüz kareleri kullanılmıştır. Herbir test için eğitim kümesinin eşit sayıda ağrısız, az ağrılı ve çok ağrılı fare yüz karesi içermesi sağlanmıştır. Bunun için yüz karesi sayısı en az olan ağrı sınıfı (örneğin az ağrılı) olduğu gibi kullanılıp diğer iki sınıftan aynı sayıda kare rasgele seçilmiştir. Test kümesi ise eğitimde kullanılmayan yeni bir videodan alınan karelerden oluşturulmuştur.

Eđitim iin “mini yıđın (batch)” yntemi kullanılmıřtır. Bu yntemde, her bir eđitim iterasyonunda eđitim kmesinden seilen grntlerden oluřan yıđın kullanılmıřtır. Her bir yıđının eřit sayıda ađrısız, az ađrılı ve ok ađrılı fare yz karesi iermesi sađlanmıřtır. Bu řekilde sistemin tercihinin rnek sayısı ok olan ađrı derecesine kayması engellenmiřtir.

4.3.2.1 Fare Yz Ađrı Derecelendirmesi iin n alıřmalar

Farelerde ađrının otomatik derecelendirilmesi iin evriřimsel sinir ađlarına dayalı bir yntem kullanılmıřtır. Projenin ilk dneminde yapılan n alıřmalarda, ve Evriřimsel Sinir Ađı (Convolutional Neural Network, CNN) ile elde edilen performanslar sınırlı bir veri set zerinden Destek Vektr Makinası, Temel Bileřen Analizi, K Yakın Komřu Sınıflayıcısı, ok Katmanlı Perceptron yntemleri ile karřılařtırılmıř ve bunlar arasında derin đrenme kullanılmasına karar verilmiřtir

Test kmesindeki benzer rneklerin, eđitim kmesinde temsiliyetinin sınıflama performansına etkisini anlamak zere tek bir videodan seilen fare yz grnts dizini Tablo 20'de verildiđi gibi farklı uzunlukta segmentlere ayrılmıř, her bir segmentin ilk %80 erevesi eđitim geri kalan %20'si ise test iin kullanılmıřtır. Geriye kalan artık segment ise kullanılmamıřtır. Her bir segment uzunluđuna gre bulunan segment sayısı, eđitim ve test setlerindeki rnek sayısı ve sınıflama bařarısı da aynı tabloda verilmiřtir.

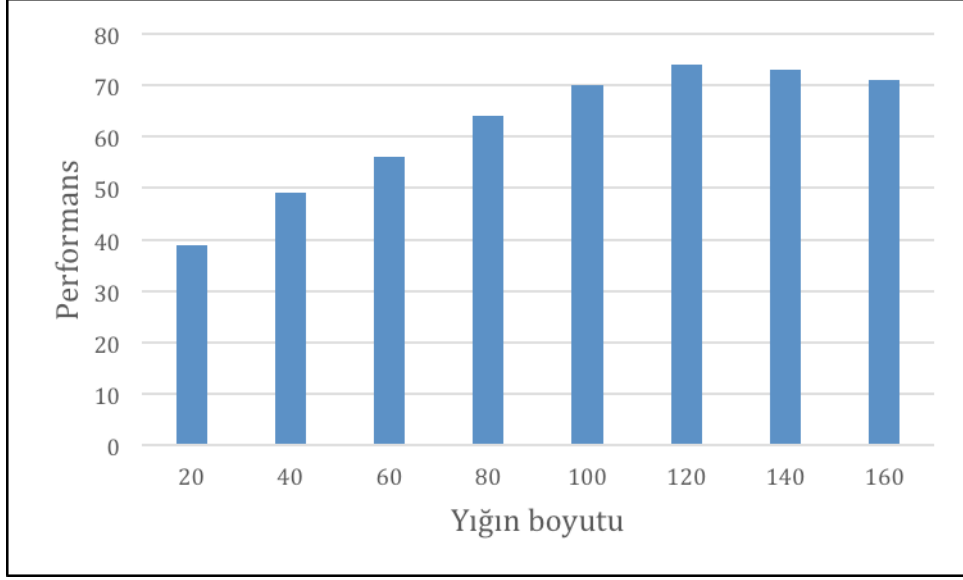
Tablo 20. Video Segment Uzunluđuna Gre Ađrı Derecelendirme Bařarısı

Segment uzunluđu	Eđitim Seti	Test Seti	Segment Sayısı	Eđitim Seti rnek sayısı	Test Seti rnek sayısı	Eđitim seti Ađrı Derecelendirme bařarısı	Test seti Ađrı Derecelendirme bařarısı
50	ilk 40	son 10	278	11120	2780	0.972	0.946
100	ilk 80	son 20	139	11120	2780	0.978	0.882
200	ilk 160	son 40	69	11040	2760	0.993	0.798
400	ilk 320	son 80	34	10880	2720	0.981	0.848
800	ilk 640	son 160	17	10880	2720	0.989	0.774

Tablo 20'de grldđi gibi segment uzunluđu kısayken bařarı ok yksektir, ancak segment uzunluđu arttıđı bařarı oranı dřmektedir. Bunun sebebi kısa segmentler kullanıldıđında, eđitim setindeki rneklerle test setindeki rneklerin benzerliđinin artması, segmentler uzadıđı benzerliđin azalmasıdır. Buradan ıkarılacak bir deđerlendirme, eđitim setindeki

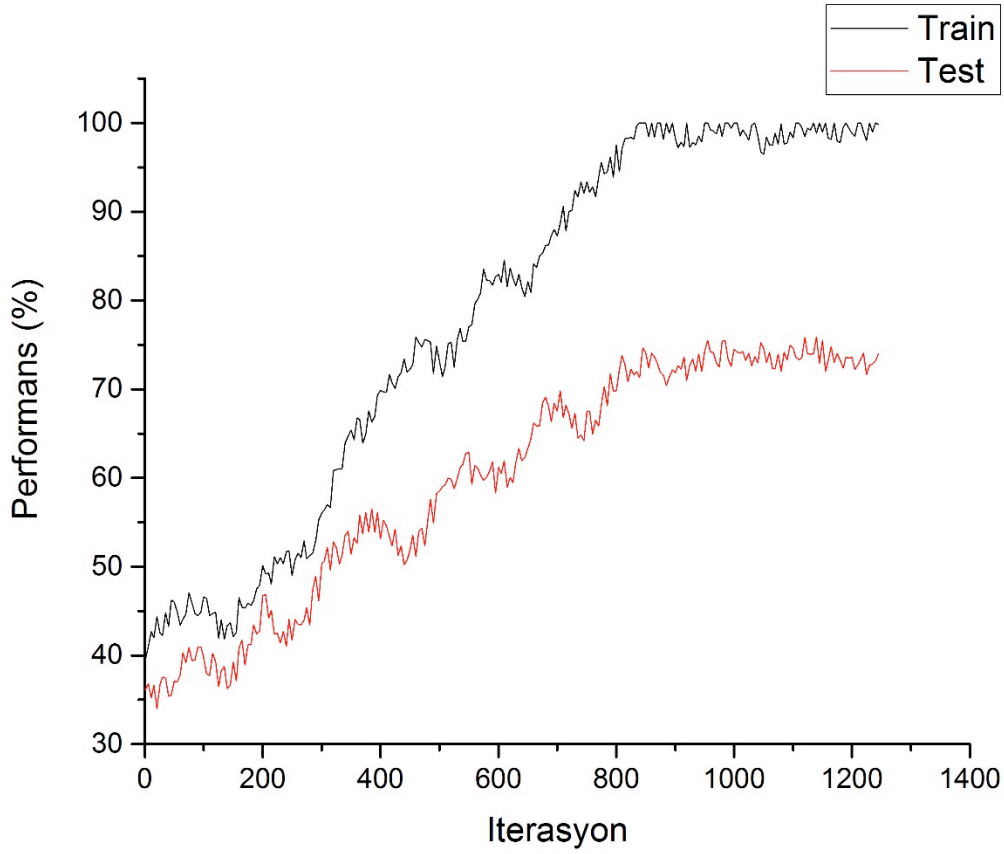
örnekler değişik bakış açılarında değişik ağırlık değerlerini yeterince kapsamaya başladığında, segment uzunluğu arttıkça başarıda görülen farklılığın azalacağı yönündedir.

Yığın boyutunun performans üzerindeki etkisi Şekil 34'de gösterilmiştir. Şekilde görüldüğü gibi en iyi yığın sayısı 120 olarak tespit edilip uygulamalarda kullanılmıştır.



Şekil 34. Yığın boyutunun performans üzerindeki etkisi

Ağırlık Derecelendirme eğitim ve test performansının eğitim iterasyonuna göre değişimi Şekil 35'de gösterilmiştir. Performans değerlerinin 1000 iterasyondan sonra pek değişmemesi gözlenmektedir. Uygulamalarda eğitim iterasyon sayısı 1000 olarak seçilmiştir.



Şekil 35. Ağrı Derecelendirme test ve train performansının eğitim iterasyonuna göre değişimi

Ağrı Derecelendirme için "Yöntem ve Gereçler" kısmında Ağrı Derecelendirme için anlatılan 3 değişik Fare-Mimik ağı, ön denemelerde karın ağrı verileri üzerinde çalıştırılarak Tablo 21'de verilen performanslar elde edilmiştir.

Tablo 21. Kullanılan ağların ortak bir test kümesi üzerindeki performansı

Ağ	Girdi Görüntü	Katman Sayısı	Performans (%)
Fare-Mimik-NET1	64x64	6	59.7
Fare-Mimik-NET2	64x64x3	9	68.8
Fare-Mimik-NET3	256x256x3	10	74.5

Tablo 21'de görüldüğü gibi, ağın katman sayısı artınca performans yükselmektedir. Ayrıca girdi görüntülerin renkli ve daha büyük boyutta seçilmesi sistemin performansını artırmaktadır ve en iyi performans Fare-Mimik-Net3 ile elde edilmiştir. Donlayısıyla bundan sonraki otomatik ağrı derecelendirme performans ölçümlerinde Fare-Mimik-Net3 ağı kullanılmıştır.

4.3.2.2. ODTÜ-HÜ Gözlem Kutusu (6 kamera) Karın Ağrısı Derecelendirme Sonuçları

Bu bölümde, yöntem ve gereçlere bölümünde anlatılan deney düzeneği kullanılarak farklı karın ağrısı deneylerinde Fare Mimik Net3 ile elde edilen ağrı derecelendirme performans sonuçları gösterilmiştir. Karın ağrısı deneylerin çekimi ve işaretlenmesi bu raporun 1.3.1. bölümünde anlatılmıştır. Bu aşamada her biri 6 videodan oluşan, 6 deney seti oluşturulmuştur. Ağrı derecelendirme için her deneyde bir video seti test ve geriye kalan 5 video seti eğitim için kullanılmıştır. Bu şekilde, test kümesi tamamen yeni bir videodan alınan karelerden oluşturulmuştur. Test setlerinde videoların sadece ağırlı kısımları gözönüne alınmıştır. Ancak eğitim setlerinde ağrısız yüz ifadesi sayısını dengeleyebilmek için bazal videolardan görüntüler, eğitim kümesine eklenmiştir. Sonuç olarak eğitim ve test videoları birbirlerinde tamamıyla ayrık videolardır.

ODTÜ-HÜ gözlem kutusu (6 kamera) Karın Ağrısı Derecelendirme amaçlı kaydedilen her bir deney için elde edilen doğruluk oranı Tablo 22'de gösterilmiştir. Ayrıca eğitim ve test için kullanılan kare sayıları da bu tabloda yer almaktadır. Eğitim kümesindeki örnekler seçerken eşit sayıda ağrısız, az ağırlı ve çok ağırlı fare yüz karesi içermesi sağlanmıştır. Ancak ağrısız yüz sayısı az olduğundan dolayı eğitim kümesi, test kümesine göre daha az görüntü içermiştir. Ağrısız yüz sayısını arttırmak için bazal videolardan 321 adet ağrısız yüz karesi seçilip eğitim kümesine eklenmiştir. Tablo 22'de eğitim için kullanılan toplam yüz sayısı gösterilmiştir.

Tablo 22. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test setindeki yüz sayısı (Ağrısız, Az ağırlı, Çok ağırlı)	Doğruluk oranı %
1	5568	37901(676,9151,28074)	54.6
2	5538	12568(685,3490,8393)	43.6
3	6600	13637(331,2423,10883)	54.4
4	7197	11197(132,1639,9426)	74.5
5	5550	13566(681,2496,10389)	51.8
6	7512	2346(27,369,1946)	42.1
Ortalama			53.5

Tablo 22'de görüldüğü gibi, deney 4 dışındaki diğer 5 deneyde doğruluk oranı düşük çıkmıştır. Veriler ikinci bir uzman tarafından tekrar incelendiğinde ağrı derecelendirmede her iki uzmanın görüşünün uyuşmadığı görüntüler ortaya çıkmıştır. Bu uyuşmazlık, fare

yüzündeki bazı yüz elemanlarının bazı bakış açılarındaki zorluktan kaynaklanmaktadır. Örneğin kulaklar yandan bakıldığında daha iyi, önden bakıldığında ise daha zor değerlendirilmektedir. Ayrıca bazı görüntülerde farenin hareketinden, otomatik odaklama sorunundan ya da camın buharlanması ya da kirlenmesi gibi sorunlardan, ya da farenin kuyruğunun yüzünü kapatması gibi sorunlardan dolayı görüntü kalitesinin iyi olmadığı tespit edilmiştir. Bu sorunu gidermek için, veriler tekrar kontrol edilip kötü kaliteli görüntüler ve ayrıca iki uzman görüşünün uyuşmadığı görüntüler elenmiştir. Bu şekilde çift uzman görüşüne göre temizlenmiş veriler, Fare-Mimik ağının eğitimi için kullanılmıştır. Ancak test setleri temizleme yapılmadan olduğu gibi kullanılmıştır. Bu şekilde eğitim setinin daha güvenilir veriler içerdiği sağlanıp test setine her her hangi bir müdahale yapılmamıştır. Bu analizlerin sonucu Tablo 23'de gösterilmiştir.

Tablo 23. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim kümesi üzerinde çift uzman, test kümesi üzerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağrısız, Az ağırlı, Çok ağırlı)	Doğruluk oranı %
1	1215	37901(676,9151,28074)	81.8
2	1629	12568(685,3490,8393)	77.3
3	2394	13637(331,2423,10883)	55.3
4	2415	11197(132,1639,9426)	85.5
5	2364	13566(681,2496,10389)	70.4
6	2502	2346(27,369,1946)	64.1
Ortalama			72.4

Tablo 23'de görüldüğü gibi, eğitim setinin çift uzman değerlendirmesi gözönüne alınarak temizlenmesinin ardından doğruluk oranı tüm deneylerde artmıştır. Böylece, 3 sınıflı otomatik ağrı derecelendirmesi ortalama doğruluk oranı %72.4 değerine yükselmiştir.

Derecelendirme sırasında ortaya çıkan hatalarının daha detaylı incelenmesi için, her deneye ait karışma (confusion) matrisi hesaplanmıştır. Bu matrisler, Tablo 24'de gösterilmiştir. Ayrıca ortalama karışma matrisi de bu tabloda gösterilmiştir. Tablolardaki değerler, her bir satırın kendi içindeki karışma yüzdesini göstermektedir.

Tablo 24'de, ortalama karışma matrisinde görüldüğü gibi en çok karışma Ağrısız-Az ağırlı ve Az ağırlı-Çok ağırlı sınıfların arasında yapılmıştır. Sistemin ağrısız kareleri çok ağırlı

olarak teşhis etme oranı %8.0 ve Çok ağırlı kareleri ağırsız olarak teşhis etme oran %7.5 dur. En düşük doğruluk oranı ise az ağırlı sınıfı için gözlemlenmiştir. Sistem ağırsız ve çok ağırlı kareleri daha başarılı olarak teşhis etmektedir.

Bir sonraki aşamada, test kümesi için de çift uzman değerlendirmesi ile temizlenen veriler kullanılmıştır. Bu uygulamanın sonuçları Tablo 25'de gösterilmiştir. Bu tabloda görüldüğü gibi doğruluk oranı tüm deneyler için oldukça artmıştır. Bu deneylerde ortalama doğruluk oranı %88.8 olarak belirlenmiştir.

Tablo 24. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için elde edilen karıştırma matrisi (Tablo 23 için, sayılar her bir satır içinde yüzde olarak verilmiştir)

Deney	Elle işaretleme	Otomatik Derecelendirme (%)		
		Ağırsız	Az Ağırlı	Çok Ağırlı
Deney 1	Ağırsız	56.4	32.8	10.8
	Az Ağırlı	6.4	75.8	17.9
	Çok Ağırlı	2.3	13.3	84.4
Deney 2	Ağırsız	92.6	2.8	4.7
	Az Ağırlı	25.1	48.7	26.2
	Çok Ağırlı	8.7	3.4	87.9
Deney 3	Ağırsız	37.2	35.9	26.9
	Az Ağırlı	10.7	44.4	44.9
	Çok Ağırlı	8.6	33.1	58.3
Deney 4	Ağırsız	78.8	20.5	0.8
	Az Ağırlı	13.6	68.2	18.2
	Çok Ağırlı	1.0	10.3	88.6
Deney 5	Ağırsız	97.5	1.1	1.3
	Az Ağırlı	23.1	35.8	41.1
	Çok Ağırlı	5.9	16.5	77.5
Deney 6	Ağırsız	85.2	11.1	3.7
	Az Ağırlı	83.2	13.3	3.5
	Çok Ağırlı	18.7	7.8	73.5
ORTALAMA	Ağırsız	74.6	17.4	8.0
	Az Ağırlı	27.0	47.7	25.3
	Çok Ağırlı	7.5	14.1	78.4

Tablo 25. ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde çift uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağrısız, Az ağırlı, Çok ağırlı)	Doğruluk oranı %
1	1215	1504(91,667,746)	90.8
2	1629	928(296,119,513)	88.7
3	2394	399(41,111,247)	83.0
4	2415	415(34,122,259)	91.8
5	2364	425(51,42,332)	88.2
6	2502	42(5,11,26)	90.2
Ortalama			88.8

4.3.2.3. Langford Kutusu (2 kamera) Deney Karın Ağrısı Derecelendirme Sonuçları

Bu bölümde, Langford kutusu kullanılarak farklı karın ağrısı deneylerinde elde edilen ağrı derecelendirme performans sonuçları gösterilmiştir. Langford deneylerin çekimi ve işaretlenmesi Bölüm 3.1'de anlatılmıştı. Bu aşamada her biri 2 videodan oluşan, 6 deney seti oluşturulmuştur. Otomatik ağrı derecelendirme deneyleri bir önceki bölümde açıklananlarla benzer şekilde yapılmıştır. Yine aynı şekilde, test kümeleri eğitim kümesinden ayrık olan tamamen başka bir videodan alınan karelerden oluşturulmuştur.

Ağrı Derecelendirme için Bölüm 3.1'de anlatılan Fare-Mimik-Net3 ağı kullanılmıştır. Her bir deney için elde edilen doğruluk oranı Tablo 26'da gösterilmiştir. Ayrıca eğitim ve test için kullanılan video karesi sayıları da Tablo 26'de yer almaktadır.

Ortalama doğruluk oranı bu deneyler için %50.4 olarak gözlemlenmiştir. Bir önceki deneye benzer şekilde veriler tekrar kontrol edilip ikinci bir uzman görüşüne uyumsuz işaretlenmiş video kareleri ve işaretli ve ayrıca kalitesi bozuk video kareleri elenmiştir. Eğitim için temizlenen görüntüler kullanılıp, test kümesi temizlenmeden kullanılınca Tablo 27'deki sonuçlar elde edilmiştir.

Eğitim ve test setleri ikinci uzman tarafından da değerlendirilerek temizlenmiş verilerden oluşturulduğunda Tablo 29'daki sonuçlar elde edilmiştir.

Tablo 26. Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağırsız, Az ağırlı, Çok ağırlı)	Doğruluk oranı %
1	810	405(20,65,320)	55.7
2	855	529(5,18,506)	60.8
3	408	978(154,505,319)	37.6
4	870	615(0,181,434)	53.6
5	792	351(26,236,89)	43.4
6	615	475(85,118,272)	51.5
Ortalama			50.4

Tablo 27. Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim kümesi üzerinde çift uzman, test kümesi üzerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağırsız, Az ağırlı, Çok ağırlı)	Doğruluk oranı %
1	732	405(20,65,320)	58.9
2	780	529(5,18,506)	65.3
3	330	978(154,505,319)	50.6
4	792	615(0,181,434)	55.9
5	726	351(26,236,89)	46.6
6	600	475(85,118,272)	56.3
Ortalama			55.6

Tablo 27’de görüldüğü gibi, eğitim kümesinin temizlenmiş görüntülerden seçilmesi ortalama başarıyı %5 civarında artarak %55.6 olmuştur.

Langford deneyleri için karıştırma matrisi, Tablo 28'de gösterilmiştir. Bu tabloda ortalama karıştırma matrisi de gösterilmiştir.

Tablo 28. Langford deney ortamında yapılan karın ağrısı deneyleri için elde edilen karıştırma matrisi (Tablo 27 için)

Deney	Elle işaretleme	Otomatik Tanıma%		
		Ağrısız	Az Ağrılı	Çok Ağrılı
Deney 1	Ağrısız	20,0	60,0	20,0
	Az Ağrılı	0,0	67,7	32,3
	Çok Ağrılı	0,9	39,5	59,6
Deney 2	Ağrısız	20,0	40,0	40,0
	Az Ağrılı	11,1	55,6	33,3
	Çok Ağrılı	4,4	29,5	66,1
Deney 3	Ağrısız	41,6	6,5	51,9
	Az Ağrılı	13,9	34,3	51,9
	Çok Ağrılı	9,1	10,1	80,8
Deney 4	Ağrısız	0,0	0,0	0,0
	Az Ağrılı	0,6	74,0	25,4
	Çok Ağrılı	1,8	49,9	48,3
Deney 5	Ağrısız	3,8	69,2	26,9
	Az Ağrılı	15,7	49,2	35,2
	Çok Ağrılı	5,7	42,0	52,3
Deney 6	Ağrısız	27,1	24,7	48,2
	Az Ağrılı	21,2	26,3	52,5
	Çok Ağrılı	2,2	19,2	78,6
ORTALAMA	Ağrısız	18,7	33,4	31,2
	Az Ağrılı	10,4	51,2	38,4
	Çok Ağrılı	4,0	31,7	64,3

Tablo 28'de görüldüğü gibi, sistem ağrısız kareleri çok düşük oranda bulabilmektedir. Bir önceki deneylere benzer şekilde, en çok hata Ağrısız-Az ağrılı ve Az ağrılı-Çok ağrılı sınıfların arasında yapılmıştır.


Test kümesi de temizlenmiş görüntülerden seçilince, elde edilen doğruluk değerleri Tablo 29'da gösterilmiştir. Bu durumda ortalama başarı oranı %11 artış göstererek, %61.8 olmuştur.

Tablo 29. Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde çift uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı


Deney	Eğitim için kullanılan yüz sayısı	Yüz sayısı (Ağrısız, Az ağırlı, Çok ağırlı)	Doğruluk oranı %
1	732	322(20,53,249)	69.8
2	780	429(4,9,416)	67.1
3	330	829(154,389,286)	55.9
4	792	493(0,148,345)	61.2
5	726	302(22,211,69)	53.5
6	600	397(64,85,248)	63.4
Ortalama			61.8

2 Kameralı Langford deney ortamında elde edilen performans değerleri ODTÜ-HÜ tarafından önerilen 6 kameralı deney ortamından elde edilenle karşılaştırıldığında, buna göre oldukça düşüktür. Bunun bir kaç nedeni vardır. Langford kutusu küçük olduğundan dolayı, çoğu zaman farenin kuyruğu yüzünün önüne gelmektedir. Ayrıca hayvana çok yakın olan kutu camlarının kirlenmesi ve buharlanması görüntülerin kalitesini düşürmektedir. Bunlara ek olarak, fare dar bir alanda bulunduğundan dolayı daha az kıpırdamaktadır ve hareketsizliğin strese yol açtığı bilinmektedir. Bunun sonucunda çok az sayıda “az ağırlı” yüz kareleri elde edilmiştir. Bu nedenlerden dolayı, eğitim için kullanılacak diğer ağırlı seviyesindeki görüntülerin sayısı da oldukça azdır. Sonuç olarak 6 deney sonucunda kaydedilen videolardan elde edilen verilerin miktarı Fare Mimik ağrının bu örneklerden iyi bir şekilde öğrenebilmesi için yetersiz kalmıştır.

Şekil 36’da Langford deneyinden örnek kareler gösterilmiştir. Yukarıda açıklanan biçimde ortaya çıkan problemlerli görüntü örnekleri bu şekilde yer almaktadır. 6 kameralı ODTÜ-HÜ deney ortamındaki düzenekten alınan örnek görüntüler karşılaştırma amacıyla Şekil 37’de gösterilmiştir.



Şekil 36. Langford deneyinden örnek kareler



Şekil 37. 6 kameralı düzeneden alınan örnek kareler

4.3.2.4 ODTÜ-HÜ Kutusu (6 kamera) Baş Ağrısı (TBI) Derecelendirme Sonuçları

Baş ağrısı için kullanılan TBI ağrı modeli Bölüm 3.1.2'de anlatılmıştır. TBI ağrısı derecelendirme deneyleri, Karın ağrısı deneylerine benzer şekilde yapılmıştır. Öncelikle, karın ağrısı ve TBI modeli arasındaki benzerlik araştırılmıştır. Bunun için Fare-Mimik-Net3 ağrı karın ağrısı videolarla eğitilip TBI videoları ile test edilmiştir. Her bir TBI deneyi için elde edilen doğruluk oranı Tablo 30'da gösterilmiştir.

Tablo 30. ODTÜ-HÜ ortamında karın ağrısı üzerinde çift uzman değerlendirmesi yapılan eğitim kümesi ile eğitilen ağrı tek uzman değerlendirmeli TBI baş ağrısı test kümeleri üzerinde doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağrısız, Az ağrılı, Çok ağrılı)	Doğruluk oranı %
1	2610	884(11,246,617)	69.0
2	2610	896(142,346,408)	64.3
3	2610	441(64,161,216)	65.7
4	2610	403(23,60,320)	78.5
5	2610	354(34,94,226)	68.6
6	2610	445(20,97,328)	70.3
Ortalama			69.4

Tablo 30'da görüldüğü gibi karın ağrısı ile eğitilen sistem, TBI modeli için test edildiğinde başarılı bir sınıflandırma sağlamaktadır. Ortalama doğruluk oranı %69.4 olarak belirlenmiştir. Bu değer karın ağrısı için elde edilen ve daha önce Tablo 23'de gösterilen ortalama %72.4 değeri ile çok yakın olması, fare baş ve karın ağrıları görüntülerinin benzerliğini göstermektedir. Bu nedenle karın ağrısı verileri TBI baş ağrısı modelinin sınıflandırılması için kullanılabilir.

Tablo 31'de verilen sonuçlar, her bir TBI baş ağrısı deneyi için deneyi için karın ağrısı verileri ve 5 diğer TBI deneyinin verileri kullanılarak elde edilmiştir. Eğitimde kullanılan verilerin hepsi önce çift uzman değerlendirmesine göre temizlenmiş, ancak test verileri olduğu gibi kullanılmıştır.

Tablo 31. ODTÜ-HÜ deney ortamında kaydedilerek çift uzman değerlendirmesi yapılmış karın ağrısı ve TBI baş ağrısı eğitim verileri ile eğitilen ağın tek uzman degerlendirmesi yapılmış TBI baş ağrısı test kümesi üzerinde elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağrısız, Az ağırlı,Çok ağırlı)	Doğruluk oranı %
1	3645	884(11,246,617)	74.5
2	3519	896(142,346,408)	67.4
3	3555	441(64,161,216)	71.1
4	3630	403(23,60,320)	82.6
5	3594	354(34,94,226)	73.1
6	3633	445(20,97,328)	76.4
Ortalama			74.2

Tablo 31'de görüldüğü gibi, ortalama doğruluk oranı bu deneyler için %74.2 olarak gözlemlenmiştir. En düşük ve en yüksek sınıflandırma başarısı değerleri %67.4 ve %82.6 olarak belirlenmiştir. Sistemin hatalarının araştırılması için, her deneye ait karıştırma hesaplanmış ve Tablo 32'de gösterilmiştir. Ayrıca ortalama karıştırma matrisi de bu tabloda gösterilmiştir.

Tablo 32'de görüldüğü gibi en çok hata Ağrısız-Az ağırlı ve Az ağırlı-Çok ağırlı sınıfların arasında yapılmıştır. Sistemin ağrısız kareleri çok ağırlı olarak teşhis etme oranı %10.8 ve Çok ağırlı kareleri ağrısız olarak teşhis etme oran %6.0 dır. En düşük doğruluk oranı ise çok ağırlı sınıfı için gözlemlenmiştir. Sistem ağrısız ve çok ağırlı kareleri başarılı olarak teşhis etmektedir.

Tablo 32. ODTÜ HÜ ortamının TBI baş ağrısı deneyleri için karıştırma matrisi (Tablo 31 için)

Deney	Elle işaretleme	Otomatik Derecelendirme (%)		
		Ağrısız	Az Ağrılı	Çok Ağrılı
Deney 1	Ağrısız	72,7	18,2	9,1
	Az Ağrılı	23,8	60,9	15,2
	Çok Ağrılı	7,5	12,3	80,2
Deney 2	Ağrısız	68,3	13,4	18,3
	Az Ağrılı	27,2	51,4	21,4
	Çok Ağrılı	10,3	9,1	80,6
Deney 3	Ağrısız	73,4	18,8	7,8
	Az Ağrılı	18,0	61,5	20,5
	Çok Ağrılı	2,8	19,5	77,7
Deney 4	Ağrısız	65,2	21,7	13,0
	Az Ağrılı	13,3	58,3	28,3
	Çok Ağrılı	6,3	5,3	88,4
Deney 5	Ağrısız	61,8	26,5	11,8
	Az Ağrılı	23,4	48,9	27,7
	Çok Ağrılı	4,9	10,2	84,9
Deney 6	Ağrısız	75,0	20,0	5,0
	Az Ağrılı	20,6	56,7	22,7
	Çok Ağrılı	4,3	13,5	82,3
ORTALAMA	Ağrısız	69,4	19,8	10,8
	Az Ağrılı	21,1	56,3	22,6
	Çok Ağrılı	6,0	11,7	82,3

Bir sonraki aşamada, test kümesi için de elle temizlenmiş veriler kullanılmıştır. Bu uygulamanın sonuçları Tablo 32'de gösterilmiştir. Bu tabloda görüldüğü gibi doğruluk oranı tüm deneyler için artmıştır. Bu deneylerde ortalama doğruluk oranı %82.9 olarak belirlenmiştir

Tablo 32. ODTÜ HÜ deney ortamında kaydedilerek çift uzman değerlendirmesi yapılmış karın ağrısı ve TBI baş ağrısı eğitim verileri ile eğitilen ağın çift uzman değerlendirmesi yapılmış TBI test verisi üzerinde elde edilen doğruluk oranı

Deney	Eğitim için kullanılan yüz sayısı	Test kümesindeki yüz sayısı (Ağrısız, Az ağırlı,Çok ağırlı)	Başarı oranı %
1	912	780(6,205,569)	80.9
2	786	746(48,297,401)	78.0
3	822	359(36,136,187)	76.8
4	897	330(11,49,270)	91.5
5	861	277(23,65,189)	87.7
6	900	363(10,83,270)	82.6
Ortalama			82.9

5.TARTIŞMA/SONUÇ

FARE-MİMİK projesinde, fareler üzerindeki ağrı deneyleri sırasında kaydedilen videoların her bir karesi için ağrı derecesini otomatik olarak değerlendiren bir sistemin geliştirilmesi amaçlanmıştır. Projede geliştirilen sistem kullanılarak, fare ağrı deneylerinde kaydedilen fare videolarında, fare yüzü tespiti birimi tarafından bulunan fare yüzleri, takipçi tarafından takip edilmekte ve bu takipçi tarafından kırılan yüzler, ağrı değerlendirme bileşeni tarafından girdi olarak kullanılarak derecelendirilmektedir. Fare yüzü tespiti, fare yüzü takibi ve MGS'ye göre ağrı derecesinin otomatik değerlendirilmesi olmak üzere bu üç bileşenin her biri için özel veri setleri üretilmiş ve her birine özel evrışimsel sinir ağları bu veri setleri kullanılarak eğitilmiştir.

Literatürde manuel ağrı derecelendirme için Langford vd (2010) tarafından önerilmiş olan sistemde, farenin yüz ifadeleri 9x5x5 cm ebatlarında prizma biçimindeki gözlem kutusunun her iki ucuna yerleştirilmiş toplam 2 kamera ile saptanmaktadır. Farenin yüzünün kameralardan birinde görünür olması için geliştirilmiş bu sistemin, sonradan eleştirilen önemli kısıtlılığı farelerin hareketlerini sınırlamasıdır. Hareketsizliğin farelerde strese neden olduğu ve bunun da yüz ifadelerini etkilediği literatürde bilinmektedir. Dolayısı ile Langford yönteminin en çok eleştirilen yanı, değerlendirilen yüz ifadelerinin ağırlıya mı yoksa hareketsiz kalmaktan dolayı oluşan stresle mi ilişkili olduğunun ayırt edilememesidir.

Langford kutusunda eleştiriye neden olan bu sorunun üstesinden gelmek üzere FARE-MİMİK projesinde farenin serbestçe hareket edebildiği 18 cm çapında silindir biçiminde cam bir gözlem kutusu ve bunun etrafına eşit uzaklıklarda yerleştirilmiş 6 kamera kullanılması önerilmiştir. ODTÜ-HÜ deney ortamı dediğimiz bu düzeneğe projede geliştirilerek kullanmıştır. Aydınlatma farklılıklarının neden olduğu sorunlardan kurtulmak üzere, yapay aydınlatma ile ışıklandırması optimize edilmiş olan altıgen prizma biçiminde bir dış kutu geliştirilmiş, hem Langford hem de ODTÜ-HÜ düzeneği ile yapılan video çekimlerinde gözlem kutuları ve kameralar bu dış kutunun içine yerleştirildikten sonra video kayıtları alınmıştır.

Fare yüzünün tespiti için Viloa Jones yöntemi denenmiş, ayrıca Yüz Onaylama ağı adını verdiğimiz evrışimsel sinir ağı kullanılan bir yöntem geliştirilmiştir. Evrışimsel sinir ağı kullanılan yaklaşımda, fare yüzü tespit zamanını hızlandırmak üzere önce farenin bulunduğu bölge, projede önerdiğimiz odak alanı belirleme yöntemiyle bulunmuş, daha sonra o bölge yüz onaylama ağı kullanılarak taranıp, fare yüzünün görüntü üzerindeki yeri tespit edilmiştir.

Yüz tespiti için geliştirdiğimiz birimde yer alan fare yüzü onaylama evrışimsel sinir ağı 256x256 büyüklüğündeki 1000 tane fare yüzü örneğinin (pozitif örnekler) tamamı doğru bulunmuştur. Fare yüzüne karşılık gelmeyen 1000 negatif örnekten ise sadece iki örneğe

yanlılıkla yüz olarak karar verilmiştir. Bu başarı konvensiyonel bir yöntem olan Viola Jones'a göre çok daha yüksektir. Odak alan ve evrişimsel sinir ağı birlikte kullanıldığında bir video karesi içinde ortalama yüz tespit süresi PC'de 40 saniye ve TITAN X grafik kartına sahip iş istasyonunda 3.8 saniyedir. Bu süre odak alanı büyüklüğü ve fare yüzü büyüklüğüne göre değişmektedir.

Her bir video karesinde fare yüzünü tespit etmek yerine, fare yüzü bir kez tespit edildikten sonra fare yüzü takipçisi yüzün bulunması işini devralmakta ve fare yüzü kaybolana kadar bu işlemi çok daha hızlı bir şekilde gerçekleştirmektedir. Fare yüzünü takip etmek amacıyla MFTN adı verilen özel bir evrişimsel sinir ağı mimarisi önerilmiştir. Tüm MFTN sürümleri MFT veri kümesi ile eğitilmiştir. Önerilen MFTN yapısında, FEN tarafından çıkarılan düşük ve yüksek seviyeli özellikler FAN aracılığıyla kaynaştırılmış ve daha sonra hedefin pozisyonu RN tarafından üretilmiştir. Deney sonuçları, tarafımızdan önerilen bir yapı olan FAN kullanıldığında performansın önemli ölçüde iyileştiğini göstermektedir. FAN kullanan MFTN/c, 0,8 sağlamlık ve 0,67 gürbüzlük değerleri ve GPU içeren bir iş istasyonunda 213 fps'lik verimle en iyi performans gösteren takipçi olarak bulunmuştur. Yine FAN kullanan MFTN/cp takipçisinin de sağlamlık ve gürbüzlük performansları buna çok yakındır, ancak bu yapıda iki tane FEN ağı kullanıldığından hızı daha düşüktür. Buna rağmen 113 fps veriminde çalışabilmektedir, bu da yine video çekimlerindeki 25 fps'nin çok üstünde olduğundan başarılı bir biçimde kullanılabilir bir hızdır.

Bu çalışmada, tek bir nesne tipi ve bu tipten de tek bir nesne, yani fare yüzü, bulunmaktadır. Bu nedenle, belirli bir türdeki tek bir nesneyi takip etmek için MFTN/c yapısının kullanılmasını önermekteyiz. Bununla birlikte, çoklu nesne takibi veya genel nesneler için MFTN/c ve MFTN/cp'nin performansı daha fazla araştırılmalıdır. Bu durumlarda MFTN/cp MFTN/c'den daha iyi bir alternatif olabilir.

Farklı açılardan çekim yapan kameralardan alınan görüntülerden yararlanmak için, tespit ve takip işlemlerini 6 kamera üzerinden birleştiren 6 kameralı yüz bulma algoritması geliştirilmiştir. Bu algoritma kullanılarak, farenin yüzü hemen hemen tüm video çerçevelerinde (frame), 6 kameradan birinde bulunabilmektedir. Bu algoritma 2 kameralı Langford deney ortamı için de kullanılabilir.

6 kameralı ODTÜ-HÜ düzeneğinde ve 2 kameralı Langford düzeneğinde, periton içine asetik asit çözeltisi enjekte edilerek karın ağrısı yaratılması paradigmasına dayalı 6 tane karın ağrısı deneyi yapılmıştır. Her bir gözlem kutusunda yapılan karın ağrısı deneyleri için ağrı derecelendirme performansını ölçmek üzere, her deneyde bir videodan elde edilen video kareleri test için ve geriye kalan 5 videodan elde edilen video kareleri eğitim için kullanılmıştır. Bu şekilde, test kümesi tamamen yeni bir videodan alınan karelerden oluşturulmuştur. Test kümelerinde videoların sadece ağırlı kısımları gözönüne alınmıştır.

Ancak eğitim setlerinde ağrısız yüz ifadesi sayısını dengeleyebilmek için bazal videolardan görüntüler, eğitim kümesine eklenmiştir. Sonuç olarak eğitim ve test videoları birbirlerinde tamamıyla ayrı videolardır.

Projede karşılaştığımız en büyük sorunlardan biri veri etiketleme işinin çok emek yoğun olması, çok dikkat gerektirmesi ve yavaş olmasıdır. Birbirine çok yakın zamanlarda yer alan video karelerinde, fare yüzündeki ifade yüksek korelasyona sahip olduğundan, fare yüzünün hareket etmediği video kareleri elenerek, etiketleme işi hızlandırılmaya çalışılmıştır.

Veri etiketlemesi yapılırken projenin çeşitli zamanlarında farklı uzmanlar işaretleme yapmıştır. Bazı video kareleri için fare yüzünün bakış açısına göre ağrı derecelendirmede karar vermede zorluk bulunan görüntüler ortaya çıkabilmektedir. Bu görüntüler üzerinde karar verirken uzmana bağlı olarak, hatta aynı uzman tarafından farklı zamanlarda farklılık ortaya çıkabildiği gözlemlenmiştir. Bu sorun biyolojik sistemlerde öznel değerlendirmelerde sıkça ortaya çıkan bir durumdur, biyolojik çalışmalarda değerlendirmelerin ara verilmeden kısa sürede tamamlanmasıyla sorunun büyük ölçüde üstesinden gelinebilmektedir, ancak bu projede değerlendirilmesi gerekli video çerçeve sayısının çok olması ve video çekimlerinin zamana yayılması nedeniyle öznel değerlendirmelerden kaynaklanan varyasyon artmıştır. Bu sorunu aşmak üzere, daha önce etiketlenmiş olan her bir video çerçevesi, ilk etiketlemede bulunmayan diğer bir uzman tarafından ikinci kez gözden geçirilmiş ve kalitesi bozuk olan görüntülerin yanı sıra, ilk etiketlemenin bu yeni uzman görüşüyle uyuşmadığı video kareleri elendiği zaman ortaya çıkan başarı da ayrıca değerlendirilmiştir.

ODTÜ-HÜ deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı %53.5'dir. Bu deneyler için eğitim kümesi üzerinde çift uzman, test kümesi üzerinde tek uzman değerlendirmesi kullanıldığında elde edilen doğruluk oranı 72.4 olmuştur. Eğitim ve test kümelerinde çift uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı ise 88.8 olmuştur. Bu durum, eğitim kümesindeki tutarlılığın, test kümesinde bir değişiklik yapılmasa bile önemli ölçüde başarıya katkısının olduğunu göstermektedir. Test kümesinde de çift uzman görüşü dikkate alındığında başarı ayrıca artmaktadır. Sistemin normal ağrı derecelendirme için kullanımı sırasında ayrıca bir etiketleme yapmaya ihtiyaç yoktur, ancak iyi bir başarı için sistem tutarlı veriler üzerinden eğitilmiş olmalıdır.

Benzer şekilde Langford deney ortamında yapılan karın ağrısı deneyleri için eğitim ve test kümelerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı 50.4, eğitim kümesi üzerinde çift uzman, test kümesi üzerinde tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı 55.6, eğitim ve test kümelerinde çift uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı 61.8 olarak bulunmuştur.

2 Kameralı Langford deney ortamında elde edilen performans değerleri ODTÜ-HÜ tarafından önerilen 6 kameralı deney ortamından elde edilenle karşılaştırıldığında, buna göre oldukça düşüktür. Bunun bir kaç nedeni vardır. Langford kutusu küçük olduğundan dolayı, çoğu zaman farenin kuyruğu yüzünün önüne gelmektedir. Ayrıca hayvana çok yakın olan kutu camlarının kirlenmesi ve buharlanması görüntülerin kalitesini düşürmektedir. Bunlara ek olarak, fare dar bir alanda bulunduğundan dolayı daha az kıpırdamaktadır, ve hareketin olmadığı ve yüz ifadesinin de değişmediği kareler yeni bilgi getirmediğinden dolayı veri kümesinden elenmektedir. Bu nedenlerden dolayı, eğitim için kullanılabilecek görüntülerin sayısı oldukça azdır. Sonuç olarak 6 deney sonucunda kaydedilen videolardan elde edilen verilerin miktarı Fare Mimik ağının bu örneklerden iyi bir şekilde öğrenebilmesi için yetersiz kalmıştır.

Serbest dolaşan farelerde otomatik ağrı derecelendirmek üzere, bu projede önerilerek geliştirilen 6 kameralı ODTÜ-HÜ gözlem kutusu, farenin hareketlerinin kısıtlandığı 2 kameralı Langford kutusuna göre daha kullanışlı ve başarılı olmuştur. Bu projede geliştirilmiş olan 6-kameralı ODTÜ-HÜ gözlem kutusu, Langford vd'nin yöntemiyle ilgili en önemli kısıtlılığı ortadan kaldırmış, ölçeğin güvenilirliğini artırmıştır. Langford kutusunun aksine bu yeni sistemde farelerin hareketleri sınırlandırılmamaktadır, dolayısıyla hareketsizliğin yolaçabileceği stresin karıştırıcı bir değişken olarak sonuçlar üzerindeki etkisi önlenmektedir. İleride yapılacak çalışmalarda bu düzeneğin ağrı deneylerinde Langford kutusu yerine kullanılması önermekteyiz.

Orta derecede kafa travması ile oluşturulan baş ağrısı modeli kullanılarak, 6 kameralı ODTÜ-HÜ düzeneğinde 6 tane baş ağrısı deneyinin video kaydı alınmıştır. Proje önerisinde planlanmasına rağmen, projedeki gelişmelere bağlı olarak iki kameralı Langford deney ortamında baş ağrısı deneylerinin yapılmasından vazgeçilmesi kararı alınmıştır. Bu karar, Langford'a göre farenin hareketini sınırlamaması nedeniyle avantajlı olan ODTÜ-HÜ gözlem kutusunun başarısının Langford kutusuna göre daha yüksek olması üzerine, deneylerde en az sayıda hayvan kullanılması gerekliliği etik kuralı çerçevesinde alınmıştır.

Ayrıca, kaydedilen fare deneylerinde, ağrılı uyaran vermeden önce bazal ortamda yapılan deney kayıtlarının, ağrı yaratmayan kontrol deneyleri ile aynı sonucu vereceği göz önüne alınarak, yine aynı etik kurallar çerçevesinde kontrol deneyleri olarak bazal videolar kullanılmış, kontrol için ayrıca farklı farelerle çekim yapılmasına gerek kalmamıştır.

ODTÜ-HÜ deney ortamında, baş ağrısı deneyleri ile ilgili eğitim kümesi kullanılmadan, sadece karın ağrısı ile ilgili eğitim kümeleri kullanılarak eğitilen ağrı tek uzman değerlendirmeli baş ağrısı test kümeleri üzerinde doğruluk oranı 69.4 bulunmuştur. Bu değer aynı ortamda karın ağrısı eğitim kümesi üzerinde çift uzman, karın ağrısı test kümesi üzerinde ise tek uzman değerlendirmesi kullanılarak elde edilen doğruluk oranı olan

72.4 ile oldukça yakındır. Bu sonuç, farklı deney paradigmaları kullanıldığında, eğer paradigma fare yüz ifadesinde ameliyat gibi nedenlerle bir farklılık yaratmıyorsa, eğitimde kullanılan fare türleri ile testte kullanılan fare türleri aynıysa ve eğitim kümesinde yeterince örnek bulunuyorsa, yeni paradigmalar için yeniden etiketleme ve eğitime gerek olmaksızın önceki paradigmalarda eğitilen ağın doğrudan kullanılabilirliğini göstermektedir. Burada az miktardaki bir performans artışı, baş ağrısı deneylerinden gelen örneklerin, henüz tam doyuma ulaşmamış olan ağın eğitimine ufak da olsa bir katkı getirmesinden dolayıdır.

Çift uzman değerlendirmesi yapılmış karın ağrısı ve TBI baş ağrısı eğitim verileri birlikte kullanılarak eğitilen ağın tek uzman değerlendirmesi yapılmış TBI baş ağrısı test kümesi üzerinde elde edilen doğruluk oranı 74.2 olmuştur. Çift uzman değerlendirmesi yapılmış karın ağrısı ve TBI baş ağrısı eğitim verileri ile eğitilen ağın çift uzman değerlendirmesi yapılmış TBI test verisi üzerinde elde edilen doğruluk oranı ise 82.9 değerine ulaşmıştır.

Elde ettiğimiz sonuçlar, geliştirilen fare mimik ağının eğitimi bir kez tamamlandıktan sonra normal ağrı derecelendirme için kullanımı sırasında ayrıca bir etiketleme yapmaya ihtiyaç olmadığını, ancak iyi bir başarı için ağın tutarlı olarak etiketlenmiş veriler üzerinden eğitilmiş olması gerektiğini göstermektedir.

Bu projede yapılan çalışmalarda, farenin ağrı derecelendirmesi o anda seçilmiş olan kameradaki tek görüntüye göre yapılmaktadır. Oysa o anda, bir kısmına farenin arkası dönük olsa bile diğer kameralar fare yüzünü farklı açılardan görebilmektedir. Dolayısı ile her hangi bir an için, ağrı derecelendirmede tek bir kamera görüntüsü kullanmak yerine birden fazla kameradaki görüntünün birlikte kullanılmasının veriye olan güveni ve sonuçtaki başarıyı artıracakları öngörülmektedir. Bu durum gelecekteki çalışmalarımızda göz önüne alınacaktır.

Bu projede ağrı derecelendirme için kullanılan derin ağ, sınıflama için eğitilmiştir. Ağrı derecelendirme işini 0,1 ve 2 sınıflarından birine karar veren bir sınıflandırma problemi olarak ele almak yerine 0 ile 2 arasında herhangi bir değer üretebilen bir regresyon problemi olarak da ele almak mümkündür. Gelecekteki çalışmalarda bunun başarıya etkisinin incelenmesi faydalı olacaktır.

Tuttle vd'nin (2018) benzer çalışmasında ağrı var-yok olarak ikili sınıflandırıldığında %94 doğruluk oranı bildirilmiştir. Bizim çalışmamızda ise ağrı yok-hafif-ağır olarak derecelendirilmiştir. Her ne kadar 2 sınıf yerine 3 sınıf göz önüne alındığında doğruluk oranları azalsa da, translasyonel farmakolojik çalışmalarda ağrı kesici olarak sınanacak ajanların etkilerinin bu skalada değerlendirilmesi ağrıdaki değişikliğin daha sağlıklı değerlendirilebilmesini sağlayacaktır. Dolayısıyla kullanılan yöntem ağrı kesici özelliği olan ilaçları bulmada daha duyarlıdır, bu da klinik bakımdan ağrının eşlik ettiği tüm hastalıklar için önem taşımaktadır. Ayrıca Tuttle vd. deneyinde kullanılan veri kümesi ile bu çalışmada

üretilen veri kümesi bir birinden tümüyle farklı olduğundan bir performans karşılaştırması yapılması da doğru değildir.

Bu projedeki ağrı derecelendirme işi, her bir video karesindeki yüz ifadesi, önceki ve sonrakinden bağımsız olarak ele alınarak yapılmıştır. Oysa otomatik ağrı değerlendirme için tek tek video karelerindeki yüzler üzerinden yüz ifadesi tanıma yoluyla karar vermek yerine farenin tüm vücudunu göz önüne alan ve video dizinleri üzerinden çalışan davranış anlama (behaviour understanding) yöntemleriyle karar veren çalışmalarının literatüre önemli katkıları olacağını ve bu tür bir ağrı derecelendirmenin sisteminin başarısını önemli ölçüde artıracığını öngörmekteyiz.

Langford vd (2010) ağrı derecelendirmesi manüeline göre farenin kendini tımarladığı, uyuduğu görüntüler değerlendirmeye alınmaz. Bu projede kullanılan otomatik derecelendirmelerde tımarlama ve uyku fotoğrafları da değerlendirilmiştir. Davranış anlama üzerinden çalışan bir yaklaşımın bu tür sorunların da üstesinden geleceğini öngörmekteyiz.

FARE-MIMIK projesinde, fare deneylerinin video kayıtları alındıktan sonra, çoklu kamera görüntülerinin fare yüzünün görüldüğü kamera temel alınarak birleştirilmesi, ve birleştirilmiş bu videolarda fare yüzünün tespiti, takibi ve derecelendirilmesi işlemlerinin hepsi otomatik yapılmaktadır. FARE MIMIK projesinde hedeflendiği gibi otomatik ağrı değerlendirme araçları geliştirildikçe, manuel ağrı değerlendirmesinin içsel sınırlamalarının üstesinden gelmek mümkün olacaktır. Bu tür araçlar ağrı deneylerinde kullanıldığında, araştırmacıların hızlı ve kolay bir şekilde laboratuvar hayvanlarında ağrı derecelendirilmesi mümkün olacaktır, bu da ağrı çalışmalarında analjezik moleküllerin taranmasını kolaylaştıracak ve uzun vadede bulguların klinik çalışmalara dönüştürülmesini sağlayacaktır.

Kaynaklar

1. Aifanti, N., Papachristou, C. and Delopoulos, A., 2010, April. The MUG facial expression database. In *Image analysis for multimedia interactive services (WIAMIS)*, IEEE, 2010 11th international workshop on, 1-4.
2. Ashraf, A.B., Lucey, S., Cohn, J.F., Chen, T., Ambadar, Z., Prkachin, K.M. and Solomon, P.E., 2009. "The painful face—pain expression recognition using active appearance models". *Image and vision computing*, 27(12), 1788-1796.
3. Bartlett, M.S., Javier, R., Littlewort, M. and Fasel, I. 2014. "Fully automatic coding of basic expressions from video. Machine Perception Laboratory", Institute for Neural Computation University of California, San Diego, CA 92093,
4. Bartlett, M.S., Littlewort, G., Fasel, I., and Movellan, J.R. June 2003. "Real time face detection and facial expression recognition: Development and applications to human computer interaction". In *Computer Vision and Pattern Recognition Workshop*, 5, 53–53.
5. Cehovin, L., Kristan, M., and Leonardis, A. 2014. "Is my new tracker really better than yours?", In *IEEE Winter Conference on Applications of Computer Vision*, 540–547.
6. Chatfield, K., Simonyan, K., Vedaldi, A., Zisserman, A. 2014. "Return of the Devil in the Details: Delving Deep into Convolutional Nets", *British Machine Vision Conference*.
7. Cootes, T.F., Edwards, G.j., Taylor, C.J. 1998. "Active Appearance Models", *Computer Vision, ECCV'98*. Lecture Notes in Computer Science, 1407, 484.
8. Cottrell, G. and Padgett, C. 1996. "Representing face images for emotion classification". Department of Computer Science University of California, San Diego La Jolla.
9. Craig, K.D., Prkachin, K.M., Grunau, R.V.E. 2001. "The facial expression of pain", *Handbook of pain assessment*, Editors: Turk D.C. and R. Melzack, New York: Guilford.
10. Danelljan, M., Hager, G., Shahbaz Khan, F. and Felsberg, M. 2016. "Adaptive decontamination of the training set: A unified formulation for discriminative visual tracking". In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1430-1438.
11. Danelljan, M., Hager, G., Shahbaz Khan, F. and Felsberg, M., 2015. "Learning spatially regularized correlation filters for visual tracking". In *Proceedings of the IEEE International Conference on Computer Vision*, 4310-4318.
12. Danelljan, M., Robinson, A., Sahbaz Khan, F.S. and Felsberg, M. 2016. "Beyond

correlation filters: Learning continuous convolution operators for visual tracking". In European Conference on Computer Vision, Springer, Cham, 472-488.

13. Darwin, C. 1872. *The Expression of the Emotions in Man and Animals*. London: Albemarle.
14. Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986. "Learning representations by back-propagating errors". *nature*, 323(6088), 533.
15. Defensor, E.B., Corley, M.J., Blanchard, R.J., Blanchard, D.C. 2012. "Facial expressions of mice in aggressive and fearful contexts", *Physiology and Behavior*, 107, 680–685.
16. Ekman, P., Friesen, W.V. 1978. "Manual for the Facial Action Coding System". Palo Alto CA: Consulting Psychologists Press.
17. Girshick, R., Donahue, J., Darrell, T. and Malik, J. 2014. "Rich feature hierarchies for accurate object detection and semantic segmentation". In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 580-587.
18. Hai, T.S., Thai, L.H. and Thuy, N.T., 2015. "Facial expression classification using artificial neural network and k-nearest neighbor". *International Journal of Information Technology and Computer Science (IJITCS)*, 7(3), 27.
19. Hammal, Z. and Cohn, J.F. 2012. "Automatic detection of pain intensity". In *Proceedings of the 14th ACM international conference on Multimodal interaction*, 47-52.
20. Hammal, Z., Kunz, M. 2012. "Pain Monitoring: A Dynamic and Context-sensitive System", *Pattern Recognition*, 45(4), 1265-1280.
21. Hammal, Z. 2009. "Context based recognition of pain expression intensities". In *The 5th Workshop on Emotion in Human-Computer Interaction-Real World Challenges-held at the 23rd BCS HCI Group conference*. Cambridge University, Cambridge, UK.
22. Held, D., Thrun, S. and Savarese, S., 2016. "Learning to track at 100 fps with deep regression networks". In *European Conference on Computer Vision*, 749-765. Springer, Cham.
23. Hong, S., You, T., Kwak, S. and Han, B. 2015. "Online tracking by learning discriminative saliency map with convolutional neural network". In *International Conference on Machine Learning*, 597-606.
24. Houben, T., Loonen, I.C.M., Baca, S.M., Schenke, M., Meijer, J.H., Ferrari, M.D., Terwindt, G.M., Voskuyl, R.A., Charles, A., Maagdenberg, A.M.J.M., Tolner, E.A. 2016.

"Optogenetic induction of cortical spreading depression in anesthetized and freely behaving mice", *Journal of Cerebral Blood Flow and Metabolism*.

25. Ioffe, S. and Szegedy, C., 2015. "Batch normalization: Accelerating deep network training by reducing internal covariate shift". arXiv preprint arXiv:1502.03167.
26. Jiang, H. and Learned-Miller, E., 2017. "Face detection with the faster R-CNN". In *Automatic Face & Gesture Recognition (FG 2017)*, 2017 12th IEEE International Conference on, 650-657.
27. Karatas, H., Erdener, S.E., Gursoy-Ozdemir, Y., Lule, S., Eren-Koçak, E., Sen, Z.D. and Dalkara, T., 2013. "Spreading depression triggers headache by activating neuronal Panx1 channels". *Science*, 339(6123), 1092-1095.
28. Khanam, A., Shafiq, M.Z. and Akram, M.U., 2008. "Fuzzy based facial expression recognition". IEEE, In *Image and Signal Processing, 2008. CISP'08. Congress on*, 1, 598-602.
29. Lee, Y.H., Han, W., Kim, Y. and Kim, C.G., 2014. "Robust emotion recognition algorithm for ambiguous facial expression using optimized AAM and k-NN". *International Journal of Security and Its Applications*, 8(5), 203-212.
30. Kotsia, I. and I. Pitas. 2005. "Real time facial expression recognition from image sequences using support vector machines". In *Image Processing, ICIP 2005. IEEE International Conference on*, 2, 11-966-9.
31. Kotsia, I., Nikolaidis, N. and Pitas, I. 2007. "Facial expression recognition in videos using a novel multi-class support vector machines variant". In *Acoustics, Speech and Signal Processing, ICASSP 2007. IEEE International Conference on*, 2, 11-585.
32. Krizhevsky, A., Sutskever, I. and Hinton, G.E. 2012. "Imagenet classification with deep convolutional neural networks". In *Advances in neural information processing systems* 1097-1105.
33. Kumar, V., Nambodiri, A. and Jawahar, C.V. 2015. "Visual phrases for exemplar face detection. In *Proceedings of the IEEE International Conference on Computer Vision*, 1994-2002.
34. Langford, D.J., Bailey, A.L., Chanda, M.L., Clarke, S.E., Drummond, T.E., Echols, S., Glick, S., Ingrao, J., Klassen-Ross, T., LaCroix-Fralish, M.L. and Matsumiya, L. 2010. "Coding of facial expressions of pain in the laboratory mouse". *Nature methods*, 7(6), 447-449.

35. Leach, M.C., Klaus, K., Miller, A.L., Di Perrotolo, M.S., Sotocinal, S.G. and Flecknell, P.A., 2012. "The assessment of post-vasectomy pain in mice using behaviour and the Mouse Grimace Scale". *PloS one*, 7(4), e35656.
36. Cun, Y.L., Boser, B., Denker, J.S., Howard, R.E., Hubbard, W., Jackel, L.D. and Henderson, D., 1990. "Handwritten digit recognition with a back-propagation network". In *Advances in neural information processing systems*, Morgan Kaufmann Publishers Inc, 2 396-404.
37. LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998. "Gradient-based learning applied to document recognition". *Proceedings of the IEEE*, 86(11), 2278-2324.
38. Lei, G., Li, X.H., Zhou, J.L. and Gong, X.G., 2009. "Geometric feature based facial expression recognition using multiclass support vector machines". In *Granular Computing, 2009, GRC'09. IEEE International Conference on*, 318-321.
39. Li, H., Li, Y. and Porikli, F. 2016. "Deeptrack: Learning discriminative feature representations online for robust visual tracking". *IEEE Transactions on Image Processing*, 25(4), 1834-1848.
40. Li, W., Li, M., Su, Z. and Zhu, Z. 2015. "A deep-learning approach to facial expression recognition with candid images". In *Machine Vision Applications (MVA), 2015 14th IAPR International Conference on*, 279-282.
41. Li, Y. and Zhu, J. 2014. "A scale adaptive kernel correlation filter tracker with feature integration". In *European Conference on Computer Vision*, Springer, Cham, 254-265.
42. Li, Y., Zhu, J. and Hoi, S.C., 2015. "Reliable patch trackers: Robust visual tracking by exploiting reliable patches". In *Computer Vision and Pattern Recognition (CVPR), 2015 IEEE Conference on*, 353-361.
43. Liao, S., Jain, A.K. and Li, S.Z. 2016." A fast and accurate unconstrained face detector". *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 211-223.
44. Gwen, C., Bartlett, M.S., Littlewort, G.C. and Kang, L. 2007. "Faces of Pain: Automated Measurement of Spontaneous Facial Expressions of Genuine and Posed Pain". In *Proceedings of ICMI*, 7, 12-15.
45. Ma, C., Huang, J.B., Yang, X. and Yang, M.H. 2015. "Hierarchical convolutional features for visual tracking". In *Proceedings of the IEEE International Conference on Computer Vision*, 3074-3082.
46. Makowska, J., Weary, D.M. 2013. "Assessing the emotions of laboratory rats", *Applied*

Animal Behaviour Science, 148, 1-12.

47. Martins, P., 2008. "Active appearance models for facial expression recognition and monocular head pose estimation". Portugal: Department of Electrical and Computer Engineering, Faculty of Sciences and Technology, University of Coimbra.
48. Mogil, J.S., Crager, S.E. 2004. "What should we be measuring in behavioral studies of chronic pain in animals?" *Pain*, 112,12-15.
49. Mogil, J.S., Davis, K.D., Derbyshire, S.W. 2010. "The necessity of animal models in pain research", *Pain*, 151, 12-17.
50. Mogil, J.S. 2009. "Animal models of pain: progress and challenges", *Nat Rev Neurosci*, 10, 283-294.
51. Monwar, M.M. and Rezaei, S. 2006. "Pain recognition using artificial neural network". In *Signal Processing and Information Technology, 2006 IEEE International Symposium on* pp. 28-33.
52. Mufti, M. and Khanam, A. 2006. "Fuzzy rule based facial expression recognition". In *Computational Intelligence for Modelling, Control and Automation, 2006 and International Conference on Intelligent Agents, Web Technologies and Internet Commerce, International Conference on*, 57-57.
53. Nam, H. and Han, B. 2016. "Learning multi-domain convolutional neural networks for visual tracking". In *Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on*, 4293-4302.
54. Nam, H. and Han, B. 2015. "Learning multi-domain convolutional neural networks for visual tracking," *arXiv preprint arXiv:1510.07945*.
55. Pantic, M. and Rothkrantz, L.J.M. 2000. "Automatic analysis of facial expressions: The state of the art". *IEEE Transactions on pattern analysis and machine intelligence*, 22(12), 1424-1445.
56. Pantic, M. and Rothkrantz, L.J. 2004. "Facial action recognition for facial expression analysis from static face images". *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 34(3), 1449-1461.
57. Patil, R.A. and Sahula, V. 2012. "Features classification using support vector machine for a facial expression recognition system". *Journal of Electronic Imaging*, 21(4), 043003.
58. Prkachin, K.M., Solomon, P.E., Ross, A.J. 2007. "The underestimation of pain among health-care providers" *Can J Nurs Res.*, 39, 88-106.

59. Prkachin, K.M. 1992. "The consistency of facial expressions of pain: a comparison across modalities", *Pain*, 51, 297-306.
60. Ranjan, R., Patel, V.M., Chellappa, R. 2015. "A Deep Pyramid Deformable Part Model for Face Detection". *IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS)*.
61. Ranjan, R., Patel, V.M. and Chellappa, R. 2017." Hyperface: A deep multi-task learning framework for face detection, landmark localization, pose estimation, and gender recognition". *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
62. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M. and Berg, A.C. 2015. "Imagenet large scale visual recognition challenge". *International Journal of Computer Vision*, 115(3), 211-252.
63. Simonyan, K. and Zisserman, A. 2014. "Very deep convolutional networks for large-scale image recognition".
<https://arxiv.org/abs/1409.1556>
son erişim tarihi, 29 Haziran 2018.
64. Silva, C., Sobral, A. and Vieira, R.T., 2014. "An automatic facial expression recognition system evaluated by different classifiers". In *X Workshop de Visao Computacional (WVC 2014)*, Uberlandia, Minas Gerais, Brazil.
65. Sohail, A.S.M. and Bhattacharya, P. 2007. "Classification of facial expressions using k-nearest neighbor classifier". In *International Conference on Computer Vision/Computer Graphics Collaboration Techniques and Applications*, Springer, Berlin, Heidelberg, 555-566.
66. Sotocinal, S.G., Sorge, R.E., Zaloum, A., Tuttle, A.H., Martin, L.J., Wieskopf, J.S., Mapplebeck, J.C., Wei, P., Zhan, S., Zhang, S. and McDougall, J.J. 2011. "The Rat Grimace Scale: a partially automated method for quantifying pain in the laboratory rat via facial expressions". *Molecular pain*, 7(1), p.55.
67. Stanley, K.L., Paice, J.A. 1997. "Animal Models in Pain Research Seminars in Oncology Nursing" , 113(1), 3-9.
68. Suja, P., Tripathi, S. and Deepthy, J., 2014. Emotion recognition from facial expressions using frequency domain techniques. In *Advances in signal processing and intelligent recognition systems*, Springer, Cham, 299-310.
69. Tuttle, A.H., Molinaro, M.J., Jethwa, J.F., Sotocinal, S.G., Prieto, J.C., Styner, M.A.,

- Mogil, J.S. and Zylka, M.J. 2018. "A deep neural network to assess spontaneous pain from mouse facial expressions". *Molecular pain*, 14, 1744806918763658.
70. Uijlings, J.R., Van De Sande, K.E., Gevers, T. and Smeulders, A.W. 2013. "Selective search for object recognition". *International journal of computer vision*, 104(2), 154-171.
71. Viola, P. and Jones, M. 2001. "Rapid object detection using a boosted cascade of simple features". In *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*, 1, I-I.
72. Wan, S., Chen, Z., Zhang, T., Zhang, B. and Wong, K.K., 2016. "Bootstrapping face detection with hard negative examples". *arXiv preprint arXiv:1608.02236*.
73. Wang, L., Liu, T., Wang, G., Chan, K.L. and Yang, Q. 2015. "Video tracking using learned hierarchical features". *IEEE Transactions on Image Processing*, 24(4), 1424-1435.
74. Wang, L., Ouyang, W., Wang, X. and Lu, H. 2015. "Visual tracking with fully convolutional networks". In *Proceedings of the IEEE International Conference on Computer Vision*, 3119-3127.
75. Wang, N. and Yeung, D.Y. 2013. "Learning a deep compact image representation for visual tracking". In *Advances in neural information processing systems*, 809-817.
76. Wang, N., Li, S., Gupta, A. and Yeung, D.Y., 2015. "Transferring rich feature hierarchies for robust visual tracking".
<https://arxiv.org/abs/1501.04587>.
son erişim tarihi, 29 Haziran 2018.
77. Wang, N., Li, S., Gupta, A. and Yeung, D.Y. 2015. "Transferring rich feature hierarchies for robust visual tracking".
<https://arxiv.org/abs/1501.04587>
son erişim tarihi, 29 Haziran 2018.
78. Wen, C.J. and Zhan Y. Z. 2008. "Hmm+knn classifier for facial expression recognition". In *2008 3rd IEEE Conference on Industrial Electronics and Applications*, 260–263.
79. Whittaker, A.L. and Howarth, G.S. 2014. "Use of spontaneous behaviour measures to assess pain in laboratory rats and mice: How are we progressing?". *Applied Animal Behaviour Science*, 151, 1-12.
80. Williams, A.C.D.C. 2002. "Facial expression of pain: an evolutionary account". *Behavioral and brain sciences*, 25(4), 439-455.

81. Yang, B., Yan, J., Lei, Z. and Li, S.Z. 2015. "Convolutional channel features". In Computer Vision (ICCV), 2015 IEEE International Conference on, 82-90.
82. Yang, S., Luo, P., Loy, C.C. and Tang, X., 2015. "From facial parts responses to face detection: A deep learning approach". In Proceedings of the IEEE International Conference on Computer Vision, 3676-3684.
83. Ye, X., Chen, X., Chen, H., Gu, Y. and Lv, Q., 2015. "Deep learning network for face detection". In Communication Technology (ICCT), 2015 IEEE 16th International Conference on, 504-509.
84. Yu, J., Jiang, Y., Wang, Z., Cao, Z. and Huang, T., 2016. "Unitbox: An advanced object detection network". In Proceedings of the 2016 ACM on Multimedia Conference, 516-520.
85. Li, Y., Sun, B., Wu, T. and Wang, Y., 2016. "Face detection with end-to-end integration of a convnet and a 3d model". In European Conference on Computer Vision, Springer, Cham, 420-436).
86. Zhang, K., Zhang, Z., Li, Z. and Qiao, Y. 2016. "Joint face detection and alignment using multitask cascaded convolutional networks. IEEE Signal Processing Letters, 23(10), 1499-1503.

Yayınlar

Sıra	Çıktı türü	Yazarlar	Başlık	Yayın yeri	Durumu*
1	Y. Lisans Tezi	Batuhan Akkaya Tez Danışmanı: Uğur HALICI	Mouse Face Tracking Using Convolutional Neural Networks	ODTÜ, Eylül 2016	Yayınlandı
2	Y. Lisans Tezi	Mustafa Eral Tez Danışmanı: Uğur HALICI	Deep Learning Approach For Laboratory Mice Grimace Scaling	ODTÜ, Eylül 2016	Yayınlandı
3	Yurt İçi Konferans Bildirisi	Mustafa Eral, Canan Çakır Aktaş, Emine Eren Koçak, Turgay Dalkara, Uğur Halıcı	Fare Yüzü Görüntülerinde Ağrı Derecelendirilmesi	BIYOMUT, 2016, XX. Biyomdikal Mühendisliği Ulusal toplantısı, Seferihisar, 3-5 Kasım	Yayınlandı
4	Yurt İçi Konferans Bildirisi	Batuhan Akkaya, Yousef Rezaei Tabar, Fourough Gharbalchi, İlkay Ulusoy, Uğur Halıcı	Fare Yüzünün Videoda Takip Edilmesi	BIYOMUT, 2016, XX. Biyomdikal Mühendisliği Ulusal toplantısı, Seferihisar, 3-5 Kasım	Yayınlandı
5	Yurtdışı Dergi Makalesi	Batuhan Akkaya, Uğur Halıcı	Mouse face tracking using convolutional neural networks	IET Computer Vision(2018), 12 (2):153 http://dx.doi.org/10.1049/iet-cvi.2017.0084	Yayınlandı

TÜBİTAK
PROJE ÖZET BİLGİ FORMU

Proje Yürütücüsü:	Prof. Dr. UĞUR HALICI
Proje No:	115E248
Proje Başlığı:	Farelerde Ağrıya Bağlı Yüz İfadesinin Otomatik Değerlendirilmesi (Fare-Mimik)
Proje Türü:	1001 - Araştırma
Proje Süresi:	30
Araştırmacılar:	EMİNE EREN KOÇAK, TURGAY DALKARA, İLKAY ULUSOY
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	ORTA DOĞU TEKNİK Ü. FEN BİLİMLERİ ENSTİTÜSÜ NÖROBİLİM VE NÖROTEKNOLOJİ ABD
Projenin Başlangıç ve Bitiş Tarihleri:	01/11/2015 - 01/05/2018
Onaylanan Bütçe:	501740.0
Harcanan Bütçe:	383026.04
Öz:	<p>Moleküler ağrı mekanizmalarının temellerinin anlaşılmasındaki önemli ilerlemelere ve endüstrideki büyük yatırımlara karşın, ağrı kesici ilaç geliştirme için yapılan temel araştırma ile klinik uygulama arasındaki translasyonel çalışmalarda başarılar oldukça sınırlı kalmıştır. Bu arayışın önündeki önemli engellerden biri mevcut hayvan modellerindeki sezinlenebilirlik (specifity) başarısının düşük olması, dolayısı ile geliştirilecek ilaçlar için hızlı ve güvenilir bir deneysel tarama testinin bulunmamasıdır.</p> <p>Bu ihtiyacı karşılamaya yönelik olarak bu projede, fare deneylerinde ağrı paradigmaları uygulanarak farelerin yüzlerinde oluşan ağrı mimiklerinin video kayıtlarından otomatik olarak derecelendirilmesini sağlayacak hesaplamalı yöntemlerin geliştirilmesi hedeflenmiştir. Literatürde Langford ve ekibi (2010) tarafından geliştirilen Fare Yüzburuşturması Derecelendirmesi (Mouse Grimace Scaling, MGS) isimli manuel bir yöntem mevcuttur. Farelerde ağrı mimiklerinin otomatik derecelendirilmesi, hız ve daha tarafsız bir etiketleme başarısının sağlanması yanında etiketlemeyi manuel olarak yapabilecek uzmanların yetiştirilmesi zorunluluğunu ortadan kaldırmasından dolayı da önem taşımaktadır.</p> <p>Proje, ortak doktora programı bulunan Hacettepe Üniversitesi (HÜ) ile Orta Doğu Teknik Üniversitesi'nin (ODTÜ) nörolojik bilimler ve teknoloji alanlarındaki deneyimleri bir araya getirilerek yürütülmüştür. Projede HÜ Nörolojik Bilimler ve Psikiyatri Enstitüsü (NBPE) tarafında yapılan çalışmalarda, iki değişik ağrı paradigması kullanılarak farelerde başağrısı ve karın ağrısı yaratılmış, farelerde oluşan ağrıya bağlı yüz ifadeleriyle ilgili video kayıtları toplanmış, ağrı miktarı uzmanlar tarafından manuel derecelendirilerek veri etiketlemesi yapılmıştır. ODTÜ Nörobilim ve Nöroteknoloji (NSNT) - Elektrik ve Elektronik Mühendisliği (EEMB) tarafındaki çalışmalarda ise toplanan video verilerinde fare yüzünün tespit ve takip edilmesini ve yüz ifadelerinden ağrının otomatik derecelendirilmesini sağlamak üzere bilgisayarla görme ve derin öğrenme adı verilen makine öğrenmesine dayalı hesaplamalı yöntemlerin geliştirilmesi yoluna gidilmiştir.</p> <p>Serbest dolaşan farelerde otomatik ağrı derecelendirmek üzere, bu projede önerilerek geliştirilen 6 kameralı ODTÜ-HÜ gözlem kutusu, farenin hareketlerinin kısıtlandığı 2 kameralı Langford kutusuna göre daha kullanışlı ve başarılı olmuştur. Bu projeye geliştirilen yöntem, farklı ağrıların fare yüz ifadelerinden otomatik tespitinde ve potansiyel ağrı kesicilerin hızlı taranması için translasyonel tıp alanında nesnel, kolay uygulanır ve güvenilir bir yaklaşım getirmesi açısından önem taşımaktadır.</p>
Anahtar Kelimeler:	Ağrı, farede ağrı için otomatik yüz ifadesi tanıma, bilgisayarla görme, yapay öğrenme, derin öğrenme
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır

Projeden Yapılan Yayınlar:	<p>1- Mouse face tracking using convolutional neural networks (Makale - Diğer Hakemli Makale),</p> <p>2- Eral M, Çakır-Aktaş C, Eren-Koçak E, Dalkara T, Halıcı U, Assessment of pain in mouse facial images / Fare Yüzü Görüntülerinde Ağrı DerecelendirilmesiDOI: 10.1109/BIYOMUT.2016.7849416 (Bildiri - Ulusal Bildiri - Poster Sunum),</p> <p>3- Akkaya B, Tabar YR, Gharbalchi F, Ulusoy I, Halıcı U, Tracking Mice Face in Video /Fare Yüzünün Videoda Takip EdilmesiDOI: 10.1109/BIYOMUT.2016.7849406 (Bildiri - Ulusal Bildiri - Poster Sunum),</p> <p>4- Eral M, Çakır-Aktaş C, Eren-Koçak E, Dalkara T, Halıcı U, Assessment of pain in mouse facial images / Fare Yüzü Görüntülerinde Ağrı DerecelendirilmesiDOI: 10.1109/BIYOMUT.2016.7849416 (Bildiri - Ulusal Bildiri - Poster Sunum),</p> <p>5- Akkaya B, Tabar YR, Gharbalchi F, Ulusoy I, Halıcı U, Tracking Mice Face in Video /Fare Yüzünün Videoda Takip EdilmesiDOI: 10.1109/BIYOMUT.2016.7849406 (Bildiri - Ulusal Bildiri - Poster Sunum),</p> <p>6- MOUSE FACE TRACKING USING CONVOLUTIONAL NEURAL NETWORKS (Tez (Araştırmacı Yetiştirilmesi) - Yüksek Lisans Tezi),</p> <p>7- DEEP LEARNING APPROACH FOR LABORATORY MICE GRIMACE SCALING (Tez (Araştırmacı Yetiştirilmesi) - Yüksek Lisans Tezi),</p>
----------------------------	---

TÜBİTAK