

**Atf İçin:** Uzun, M. Z., Başaran, E. ve Çelik, Y. (2023). Xception Derin Öğrenme Modeli ve Gabor Filtreleri ile RFECV-SVM Algoritması Kullanılarak Mikro İfadelerin Tanınması. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(4), 2339-2352.

**To Cite:** Uzun, M. Z., Başaran, E. & Çelik, Y. (2023). Recognition of Microexpressions Using Xception Deep Learning Model and Gabor Filters with RFECV-SVM Algorithm. *Journal of the Institute of Science and Technology*, 13(4), 2339-2352.

## Xception Derin Öğrenme Modeli ve Gabor Filtreleri ile ÇDÖÖE-DVM Algoritması Kullanılarak Mikro İfadelerin Tanınması

Mehmet Zahit UZUN<sup>1\*</sup>, Erdal BAŞARAN<sup>2</sup>, Yüksel ÇELİK<sup>3</sup>

### Öne Çıkanlar:

- Çalışmada hem geleneksel hem de veriye dayalı yöntemler kullanılmıştır
- Modelde farneback ve TV-L1 optik akış teknikleri karşılaştırılmıştır
- Casme-II veri seti üzerinde 0.9184 doğruluk elde edilmiştir

### Anahtar Kelimeler:

- Mikro ifade
- Optik akış
- Xception
- Gabor
- ÇDÖÖE
- DVM

### ÖZET:

Mikro ifade (Mİ), insanların riskli bir ortamda bir olaya karşı istemsiz ve kontrolsüz duygusal tepkilerini gizlemeye çalıştıklarında ortaya çıkan sızıntıdır. Duyguyu yaşayan kişi risk altında bunu bastırmaya çalıştığı için yüze yansımaları düşük yoğunlukta, belirli bir bölgede ve çok kısa sürede gerçekleşir. İfade istemsizce ortaya çıktığı için sahte değil tamamen doğal olmaktadır. Bu doğal ifadelerin doğru tespiti sayesinde adli, klinik, eğitim gibi birçok alanda etkili bir şekilde kullanılması sağlanabilir. Bu çalışmada Mİ tanıma hedefi için oluşturulan model yapısında sırasıyla önışleme, öznelik çıkarma, öznelik seçme ve sınıflandırma görevleri kullanılmıştır. Önerilen model yapısında literatürde en çok kullanılan, kamuya açık Mİ veri setlerinden CASME-II kullanılmıştır. Ön işleme aşamasında Optik Akış algoritmalarında kullanılmak üzere her bir video klipin görüntü dizisinden başlangıç (onset) ve tepe (apex) kareleri seçilir. Bu iki kare kullanılarak Farneback, TV-L1 Dual ve TV-L1 e ait yatay ve dikey optik akış görüntüleri elde edilmiş, ardından bu optik akış görüntüleri evrişimsel sinir ağı (ESA) modeli olan Xception ve geleneksel model olan Gabor modelleri kullanılarak görüntülere ait öznelikler elde edilmiştir. Elde edilen bu özneliklere ait ayırt edici olanları filtrelemek için çapraz doğrulama ile özyinelemeli özellik eleme (ÇDÖÖE) öznelik seçim algoritması kullanılmıştır. Son olarak doğrusal destek vektör sınıflandırıcısı (DVS), filtrelenmiş Mİ özneliklerini pozitif, negatif ve sürpriz olmak üzere üç sınıfa ayırmıştır. Önerilen Mİ model yapısından elde edilen sonuçlar 0.9248 doğruluk oranı başarısı göstermiştir.

## Recognition of Microexpressions Using Xception Deep Learning Model and Gabor Filters with RFECV-SVM Algorithm

### Highlights:

- Both traditional and data-based methods were used in the study.
- Farneback and TV-L1 optical flow techniques are compared in the model.
- An accuracy of 0.9184 was obtained on the Casme-II dataset.

### Keywords:

- Micro-expression
- optical flow
- xception
- gabor
- RFECV
- SVM

### ABSTRACT:

Micro Expression (ME) is the leakage that occurs when people try to mask their involuntary and uncontrolled emotional response to an event in a risky environment. Because the person experiencing the emotion at risk tries to suppress it, its reflection on the face occurs in a low intensity, a specific region, and a very short time. Since the expression emerges involuntarily, it is not fake but completely natural. Thanks to the correct detection of these natural expressions, it can be used effectively in many fields such as forensics, clinical, and education. This study used preprocessing, feature extraction, feature selection, and classification tasks in the framework created for the ME recognition target. CASME-II, one of the literature's most widely used publicly available ME datasets, was used in the proposed framework. In the preprocessing stage, onset and apex Frames are taken from the image sequence of each video clip to be used in optical flow algorithms. These two frames obtained horizontal and vertical optical flow images of Farneback, TV-L1 Dual, and TV-L1. Then the features of these optical flow images were obtained using the convolutional neural network (CNN) model Xception and the traditional Gabor model. Recursive feature elimination with a cross-validation (RFECV) feature selection algorithm was used to filter the distinctive ones of these features. Finally, the SVC Linear classifier divided the filtered ME features into three classes: positive, negative, and surprise. The results obtained from the proposed ME framework showed an accuracy rate of 0.9248.

<sup>1</sup>Mehmet Zahit UZUN (Orcid ID: 0000-0002-6180-5860), Karamanoğlu Mehmetbey Üniversitesi, Ermenek Meslek Yüksekokulu, Bilgisayar Programcılığı, Karaman, Türkiye

<sup>2</sup>Erdal BAŞARAN (Orcid ID: 0000-0001-8569-2998), Ağrı Üniversitesi, Uzaktan Eğitim Merkezi, Bilgisayar Teknolojileri, Ağrı, Türkiye

<sup>3</sup>Yüksel ÇELİK (Orcid ID:0000-0002-7117-9736), Karabük Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Karabük, Türkiye.

\*Sorumlu Yazar/Corresponding Author: Mehmet Zahit UZUN, e-mail: mzuzun@kmu.edu.tr

## GİRİŞ

Duygular beyindeki ilgili sinir sistemini uyararak, yüzdeki duygusal gösterimleri geçici ve irade dışında otomatik olarak harekete geçirmektedir (Warren ve ark.,2009; Hurley ve ark.,2014). Mİ, kişilerin gizlemeye çalıştığı bir duyguyu istemsizce kısa süreli olarak sızdırdığı yüz hareketi olarak tanımlanmaktadır. İnsanlar yetiştiği ortamlardan dolayı, toplumsal, kültürel ya da bireysel etkenlerden dolayı duygularını gizleme eğiliminde olabilmektedirler. Bu mimikler istenmeyen durumlarda meydana geldiğinden, benzer şartların oluşmasının güç olmasından dolayı taklit edilmesi ve üretilmesi zor olmaktadır. Ayrıca istemsiz meydana geldiğinden kontrol edilemez ve gerçek duyguları yansıtmaktadırlar. Ulaştırma güvenliği, klinik, politik alanlarında kullanıldığında avantaj sağlayacak olan Mİ' yi diğer yüz ifadelerinden ayıran temel özelliklerden biri de imiklerin süreleri gösterilmiştir. Mİ sürelerinde bir fikir birliği olmasa da bugüne kadar öne sürülen süreler içerisinde maksimum, saniyenin yarısından daha az sürdüğü belirtilmiştir (Yan ve ark., 2013). Bazı kaynaklarda ise saniyenin 1/25–1/5'in aralığında gerçekleştiği literatüde arasında eleştirilmeden kabul edildiği belirtilmiştir (Yan ve ark., 2013; Fan ve ark., 2022) Araştırmalarda fark edilen bir diğer husus ise Mİ yüzün hem alt hem de üst kısmında aynı anda görülmedikleridir (Porter ve ark., 2012). Yani Mİ diğer yüz ifadeleri gibi tam olarak değil yüzün kısmi bölgelerinde parçalı bir şekilde oluşmaktadır. Mİ'lerin yüzdeki oluşumları literatürde belirtildiği gibi kısa süreli ve kısmi olduğundan dolayı insan gözüyle tespit edilmeleri zordur. Yetenekli ve eğitilmiş uzmanlar tarafından bile tespit edilme oranları %45 ila %59 aralığında değiştiğinden, bu da istenen hedefin oldukça altındadır (Hurley ve ark., 2014). Buna yaşlı yetişkinlerin genç yetişkinlere göre aldatıcı yüz ifadelerini çok daha zor tespit ettiği, yaşa bağlı farklılıkların da önem kazandığı (Stanley ve Webster, 2019), düşünülürse Mİ tanıma oldukça emek ve çaba isteyen bir görev haline gelmiştir.

Video klip görüntülerinde Mİ' lerin meydana gelme aralığı üç ortak kare ile tanımlanmaktadır. Mikro ifadenin başladığı an olarak belirtilen başlangıç karesi, ifadenin yüzde belirmesinin zirve yaptığı ve en yoğun görüldüğü tepe karesi ve ifadenin son bulduğu kare olarak belirtilen bitiş karesidir. Tüm Mİ video kare dizileri, ifadelerin süreçlerinin çok kısa olmasından dolayı, bu üç kare ile temsil edilebilmektedir (Ben ve ark., 2021; Gan ve ark., 2022; Zhou ve ark., 2022). Bu çalışmada da video klibe ait tüm kare dizileri yerine, belirtilen bu üç önemli kare kullanılarak önışleme ve öznitelik çıkarma süreçleri gerçekleştirilmiştir.

Kamuya açık doğal mikro ifade veri seti olarak en yaygın kullanılan veri setleri CASME II, SAMM ve SMIC veri setleridir (Uzun ve ark., 2022). Modellerine STSNET adı verdikleri çalışmalarında örnekleri üç etikete ayırdıkları CASME-II veri seti ile 0.8382 ağırlıksız F1, 0.8686 ağırlıksız ortalama duyarlılık değerleri elde etmişlerdir (Liong ve ark., 2019). Off-ApexNet isimli bir diğer çalışmada ise örnekleri üç etikete ayırdıkları SAMM, CASME-II ve SMIC veri setleri kendi içlerinde değerlendirildiğinde en yüksek performansı CASME-II veri seti 0.8828 doğruluk, 0.8697 F1 ölçümüyle elde etmiştir. Üç veri seti birleştirilerek elde ettikleri bileşik üç etiketli veri setinde ise 0.746 doğruluk, 0.7104 F1 ölçümü elde etmişlerdir (Gan ve ark., 2019).

Literatürde Mİ ile ilgili yapılan uygulamalarda kullanılan modellerin ortak işlemleri sırasıyla önışleme, öznitelik çıkarma, sınıflandırma olarak üç bölümden oluşmaktadır. Mİ paçalı olarak meydana geldiğinden, yüzün alt ya da üst kısmının küçük bir bölümünde meydana gelmektedir. Bundan dolayı baş hareketleri, aydınlatma ve gölgelendirmelerden kaynaklı tanıma doğruluğunu etkileyecek negatif faktörler bulunmaktadır (Liong ve ark., 2019). Önışleme aşamasında ilk olarak piksel değişiminden küçük hareket ve değişimleri yakalayabilen optik akış tekniği Mİ çalışmalarında öznitelik çıkarma aşamasından önce uygulanmaktadır. Yüz ifadelerinin tanınmasında optik akış yöntemleri

karşılaştırıldığında en iyi sonuçları yoğunluk tabanlı tekniklerden, Farneback ve TV-L1 elde etmiştir (Zhao ve Xu, 2020).

Öznitelik çıkarma aşamasında geleneksel ve veriye dayalı makine öğrenimi yöntemleri kullanılmaktadır. Geleneksel yöntemlerden en çok kullanılan yerel ikili desen (Local Binary Pattern-LBP) ve üç ortogonal düzlemde yerel ikili desen (Local Binary Pattern on Three Orthogonal Plane-LBP-TOP) (Sun ve ark., 2020; Adegun ve Vadapalli 2020) ve türevleri, yönlendirilmiş gradyan histogramı (Histogram of Oriented Gradient -HOG) (Ahadit ve Jatoth, 2022), Gabor (Lin ve ark., 2018) Mİ görüntülerine uygulanmıştır. Yerel ikili desen, 2B görüntülerde piksellerin yerel komşuluğundan görüntünün doku özelliğini çıkarırken, üç ortogonal düzlemde yerel ikili desen video görüntülerinin yerel komşuluklarını uzamsal ve zamansal olarak hesaplamaktadır. Yönlendirilmiş gradyan histogramı ise görüntülerin piksellere gradyanların büyüklük ve yön bilgisini iki boyutlu bir vektör şeklinde tanımlamaktadır. Bunu görüntüyü küçük pencerelere bölüp, sobel filtresi kullanarak yapmaktadır.


Makine öğrenmesinde, veriye dayalı modeller kullanılarak yapılan öznitelik çıkarma işleminde derin öğrenme yöntemleri uygulanmıştır. Bu modeller yapılarında evrişimsel ve havuzlama katmanları içermektedir. Evrişimsel katmanı öznitelik haritaları çıkarırken, havuzlama katmanı veri boyutlarını azaltmaktadır. Görüntüler için kullanılan 2B ESA modelleri önemli bilgileri içeren uzamsal öznitelik haritalarını çıkarıp sınıflandırmaktadır (Zhou ve ark., 2022; Tang ve ark., 2022). Video görüntüleri için kullanılan 3B ESA modelleri ise hem uzamsal boyutta hem de zamansal boyutta önemli bilgileri içeren öznitelik haritalarını çıkarıp sınıflandırmaktadır (Zhou ve ark., 2022; Cai ve ark., 2022). Bu modeller ayrıca binlerce örneğe sahip veri tabanları ile eğitilip bu öğrenme durumunu hiç karşılaşmadığı başka öğrenme ortamlarına aktarabilmektedirler. Öğrenmeyi aktarma yöntemi, Mİ gibi örnek sayısı az olan veri setlerinde uygulandığında da verimli sonuçlar elde edilmiştir (Zhou ve ark 2019; Xia ve ark., 2020).

Sınıflandırma aşamasında, makine öğrenmesinde kullanımı çok popüler olan Destek Vektör Makinesi (DVM) ve farklı çekirdekleri öznitelik haritalarının sınıflandırılmasında kullanılmıştır (Uzun ve ark., 2022). Ayrıca derin öğrenme modellerinin mimarisinde bulunan sınıflandırma katmanları da öznitelik haritalarını sınıflandırmada kullanılmıştır (Zhou ve ark., 2019; Xia ve ark., 2020). Başka bir çalışmada Üç ortogonal düzlemin yerel ikili deseninden elde ettikleri ve ESA'dan elde ettikleri Mİ özelliklerini birleştirerek softmax ve DVM sınıflandırıcılarında eğitmişlerdir. Çalışmalarında DVM'nin doğrusal, polinom, radyal ve sigmoid gibi dört farklı çekirdeğinin kullanılmıştır. DVM, CASME II, SMIC-NIR, CAS(ME)2 veri setleri için softmax sınıflandırma algoritmasından %4 ila %7 oranında üstün olduğunu gözlemlemişlerdir (Takalkar ve ark., 2020). Peng vd. CASME ve CASME II veri setlerini kullandıkları çalışmalarında veri setlerindeki video kliplerinin farklı kare hızlarına adapte olabilen biri 64fps diğeri 128 fps iki akışlı Çift Zamansal Ölçekli Konvolüsyonel Sinir Ağı (DTSCNN) adı verdikleri 3B ESA modeli kullanmaktadır. Modelin yapısında aşırı uydurmadan kaçınmak için sığ bir ağ yapısı tasarlanırken, sınıflandırma kısmında doğrusal bir DVM'den yararlanmışlardır (Peng ve ark., 2017).

Önerilen çalışmanın deneylerinde, kamuya açık en yaygın kullanılan CASME-II spontane Mİ veri seti kullanılmıştır. Ayrıca önerilen çalışmada, geleneksel yöntemler ve veriye dayalı yöntemler kullanılarak performans ölçümleri karşılaştırılmıştır. Veriye dayalı olarak derin öğrenme modellerinden Xception ESA modeli, geleneksel yöntem olarak gabor filtre bankaları uygulamalarda kullanılmıştır. Veri setindeki düşük örneklemeden dolayı veriye dayalı Xception modelinde veri artırma ve öğrenmeyi aktarma teknikleri uygulanmıştır. Gabor ve Xception modellerinden elde edilen öznitelik haritaları daha sonra makine öğrenmesinin fenomen sınıflandırıcısı olan doğrusal destek vektör sınıflandırıcısı (DVS) ile sınıflandırma işlemleri gerçekleştirilmiştir.

## MATERYAL VE METOT

Önerilen modelin yapısı önışleme, öznitelik çıkarma, öznitelik seçimi ve sınıflandırma aşamalarından oluşmaktadır. Modelin yapısı Şekil 1’de verilmiştir.



Şekil 1. Mİ sınıflandırma için önerilen mimari yapı

Modelin önışleme aşamasında başlangıç kare ve tepe kare görüntülerinden optik akış yöntemi uygulanarak hareket öznitelikleri çıkarılmıştır. Görüntüler, optik akış yönteminin Farneback ve TV-L1 teknikleri uygulandıktan sonra döndürme veri artırma yöntemi uygulanarak veri setindeki örnekler artırılmıştır. Artırılmış veri setine veriye dayalı model olan Xception ve geleneksel model olan Gabor uygulanarak öznitelik haritaları çıkartılmış ve iki model kendi aralarında karşılaştırılmıştır. Xception modelinde tam bağlı katmanlardan hemen önceki katmandan 100352 öznitelik haritası, Gabor yöntemi ile 50176 öznitelik haritası elde edilmiştir. Ardından kullanılan modelin, Mİ tanımda en az öznitelik haritası ile maksimum performansı vermesini sağlayacak olan ÇDÖÖE öznitelik seçim algoritması kullanılmıştır. Bu iki modelde de sınıflandırıcı olarak doğrusal DVM algoritması uygulanmıştır. Önerilen çalışmada kullanılan metotların detaylı açıklamaları aşağıdaki bölümlerde verilmiştir.

### Veri Seti

Günümüzde halka açık veri seti olarak oluşturulan CAME-II (Yan ve ark., 2014) veri setinde 26 katılımcıdan elde edilen 247 adet Mİ bulunmaktadır. Mİ örnekleri spontan ve dinamiktir. Video kayıtlar, uygun aydınlatma koşulları altında 200 fps kare hızına ve yaklaşık 280x340 yüz çözünürlüğüne sahiptir. İfadeleri etiketlemede (Facial Action Coding Sytem) FACS kullanılmıştır. Doğal Mİ üretmenin zorlukları ve laboratuvar koşulları, farklı kategorilerde eşit olmayan örnek dağılımına sebep olmuştur.

Yedi kategoriye ayrılmış Casme-II veri seti negatif, pozitif ve sürpriz olmak üzere üç etikete sahip veri seti oluşturulmuştur. Bu dönüştürmede iğrenme, korku, baskı ve üzüntü kategorileri negatif sınıf altında gruplandırılırken, mutluluk kategorisi pozitif sınıf altında, sürpriz kategorisi isim değiştirmeden aynı isimli sınıfta bulunmaktadır. Diğerleri kategorisine ait örnekler bu çalışmada kullanılmamıştır. Böylece negatif sınıfta 94 adet örnekleme, pozitif sınıfta 32 adet örnekleme ve sürpriz sınıfta 28 adet örnekleme sahip veri seti kullanılmıştır. Çizelge 1’de önerilen çalışmada kullanılan CASME-II veri setine ait özellikler gösterilmektedir.

Çizelge 1. Önerilen modelde kullanılan spontane Mİ veri tabanı CASME II’ nin özellikleri

Katılımcı	Örnek	Negatif	Pozitif	Sürpriz	Kare hızı (fps)	Çözünürlük	Yüz çözünürlüğü	Etnik
24	154	94	32	28	200	640*480	280*340	1

CASME-II veri setinde örnekler hem video klipi biçiminde hem de görüntü kareleri biçiminde sunulmaktadır. Ayrıca bu görüntü kareleri kullanıcılar için hem önışleme aşamasından geçirilmiş hem de başlangıç, tepe ve bitiş karelerinin indeksleri verilmiştir. Önışleme aşamasında yüz bölgesi ASM tekniği kullanılarak 68 nokta ile belirlenmiş, LWM tekniği ile hizalanıp kırılmıştır.

## Ön İşleme

İki kare arasındaki piksel başına değişiminden hareket ve farklılıkları vektörel olarak tahmin eden bir el yapımı yöntemidir (Liu ve ark., 2020). Mİ çalışmalarında sıkça kullanılan Farneback (Farneback, 2003) ve TV-L1 yoğunluk tabanlı optik akış teknikleridir. Farneback tekniği, hesaplama açısından daha hızlı, piramidal ayırıştırma kullanma, yüz hareketlerinin analizinde daha az hata üretme gibi avantajları bulunurken, TV-L1 ise görüntülerin süreksizliğini tahmin etme ve kenar özelliklerini koruma, L1 normunu kullanma gibi avantajlarından dolayı tercih edilmiştir (Benjamin ve ark., 2019; Liu ve ark., 2021).

Önerilen çalışmada başlangıç ve tepe kareleri kullanılarak, bu iki kare arasındaki değişikliklerden hareketi tahmin etmek için Farneback ve TV-L1 optik akış teknikleri uygulanmış ve karşılaştırılmıştır. Elde edilen optik akış görüntülerin buldukları kategoriler, veri setinden dolayı eşit değildir. DVM sınıflandırma, örnekleme fazla olan sınıfın lehine ölçüm sonuçları verdiği için (Li ve ark., 2020; Bozkurt 2023), optik akış görüntülerde veri arttırma tekniği uygulanarak, dengeli sınıfların oluşturulması hedeflenmektedir. Veri setinde 94 negatif, 32 pozitif ve 28 sürpriz örnekleme sayısı, veri arttırma tekniği sonrası her biri 94 örneklemeyle sahip üç sınıf haline getirilmiştir. Keras kütüphanesinin ImageDataGenerator sınıfı, pozitif ve sürpriz sınıflara uygulanarak 90°, 180°, 270° döndürme işlemi sonunda sınıflar eşitlenmiştir. Veri kaybına ve gürültüye sebep olmamak için diğer teknikler tercih edilmemiştir.

## Gabor Filtresi

Gabor filtreleri, görüntü işlemede ve bilgisayar görüşünde kullanılan kenar algılama, doku analizi, öznitelik vektörü çıkarma gibi görevleri yapabilen doğrusal bir hesaplama yöntemidir. Gabor filtrelerinin çalışma prensibi, memelilerin görsel sisteminde bulunan korteks hücrelerinin fizyolojik çalışmasına dayanmaktadır (Rose, 2006; Takalkar ve ark., 2018).

Gabor filtreleri bir görüntüdeki kenar ve doku yapısındaki değişim noktalarını algılamakta, ilgili filtreler bu uzamsal konumlarda ayırt edici özelliğe sahiptir. Gabor filtreleri nesne, yüz ve yüz ifadesi tanıma için kullanılmaktadır (Lee ve Chen, 2009; Ou ve ark., 2010). Ayrıca yüze ait öznitelik haritaları çıkarılırken yüzün tamamında ya da bir kısmında (Gao ve ark., 2017) kullanılabilir. Yüz hareketlerini sınıflandırmada iyi performans veren gabor, aydınlatma ve döndürmelere karşı dayanıklı farklı frekans ve yönlere sahip filtre bankaları kullanan piksel tabanlı popüler bir yöntemdir (Lee ve Chen, 2009; Takalkar ve ark., 2018). Belirli bir bant frekansın geçişine izin veren bir gabor filtresi bir sinüs dalgası ve bir Gauss zarf fonksiyonunun birleşiminden oluşmaktadır. Denklem 1-3 arasında Gabor filtresine ait eşitlik verilmektedir. (Jirik ve ark., 2011).

$$Gabor(x, y) = \exp\left(-\frac{x'^2}{2\sigma_x^2}\right) \exp\left(-\frac{y'^2}{2\sigma_y^2}\right) \cos\left(2\pi\frac{x'}{\lambda} + \psi\right), \quad (1)$$

$$x' = (x - m_x) \cos \gamma - (y - m_y) \sin \gamma, \quad (2)$$

$$y' = (x - m_x) \sin \gamma + (y - m_y) \cos \gamma, \quad (3)$$

Burada  $\psi$  parametresi bir faz kaymasını,  $\gamma$  parametresi yönü,  $\sigma_x^2$  ve  $\sigma_y^2$  parametreleri alıcı alanı,  $m_x$  ve  $m_y$  görüntü koordinatlarında gabor fonksiyonunun merkezini belirtir.

## Xception

Google tarafından 2017 tarihinde sunulan Extreme Inception (Chollet, 2017) anlamına gelen bu ağ, Inception modülü yerine modifiye edilmiş derinlemesine ayrışabilir evrişim katmanlarını temel alan bir evrişim mimari modelidir. Modelin temel fikri uzamsal ve derinlikli olarak öznitelik haritalarını

ayrıştırmak ve ek olarak artık (residual) bağlantılarla öznelik haritalarını güçlendirmektedir. Burada ayrılabilir evrişim ağlarında önce derinlemesine evrişim yapıp daha sonra noktasal evrişim yapılırken, Xception modelinin kullandığı değiştirilmiş derinlemesine ayrılabilir evrişim ağında ise tersi kullanılmaktadır.

### Çapraz Doğrulama ile Özyinelemeli Özellik Eleme (ÇDÖÖE)

Önerilen çalışmada özyinelemeli özellik eleme (ÖÖE) algoritmasının bir güncellenmiş versiyonu olan çapraz doğrulama ile özyinelemeli özellik eleme öznelik seçim algoritması kullanılmıştır. ÇDÖÖE, öznelik haritalarının sınıflandırmadaki önemlerine göre otomatik çapraz doğrulama kullanarak sıralamaktadır. Ardından algoritma sıralanmış öznelik haritaları içerisinde Mİ sınıflandırmasında en alakasız öznelikleri birer birer kaldırmaktadır. Bu algoritma adından da anlaşılacağı üzere öznelik haritalarının sıralarken özyinelemeli bir prosedür kullanıp sınıflandırmada en yüksek puanı verecek minimum sayıdaki öznelikleri belirleyip seçmektedir. Böylece sınıflandırmanın performansını artmasına yardımcı olmaktadır (Wang ve ark., 2019; Mustaqim ve ark., 2021).

### Destek Vektör Makinesi (DVM)

DVM başta ikili sınıflandırmada kullanılmak üzere Cortes ve Vapnik (Cortes ve Vapnik, 1995) tarafından 1995 yılında tasarlanmıştır. Zamanla uygulamalarda geliştirilerek ikiden fazla sınıflandırma kabiliyeti elde etmiştir. DVM, sınıflandırma problemlerinde veri setini en iyi ayıran fonksiyonu öğrenme, regresyon problemlerinde fonksiyon kestirimi yapabilen bir denetimli öğrenme algoritmasıdır (Ukil, 2007). Görüntü ve konuşma işleme, zaman serisi tahmini, veri madenciliği, güç sistemleri gibi uygulama alanlarda kullanılmaktadır.

DVM çekirdek hilesi ile verileri daha yüksek boyutlu bir uzaya taşıyarak doğrusal olmayan sınıflandırma becerisi kazanmaktadır. Böylelikle ilk olarak literatüre doğrusal sınıflandırıcı olarak giren DVM algoritması zamanla doğrusal olmayan sınıflandırma görevlerinde de kullanılmaktadır. Ayrıca destek vektör regresyonu (DVR), regresyon analizlerinde kullanılabilen DVM versiyonu olarak sunulmuştur (Ukil, 2007).

DVM algoritmasının kolay uygulanabilirliği, n boyut özellik uzayına sahip problemler için uygun yöntemlerden biri olmasından dolayı önerilen model için kullanılmıştır (Karcıoğlu ve Aydın, 2019).

### Performans Ölçümleri

Veri setinde bulunan sınıflara ait örnekleme sayılarının bazı sınıflarda dominant olduğu durumlarda modelin performansının ölçümünde sadece doğruluk değerine başvurmak değerlendirmede önyargıya sebep olacaktır. Modelin veri seti üzerindeki performansını daha etkili değerlendirebilmek için başka ölçümlere de başvurulmaktadır (Basaran ve ark., 2020; Tonkal ve ark., 2021). Doğruluk değeri sadece yapılan tahminlerin kaçının doğru olduğunu verdiğinden dolayı karmaşıklık matrisi modelin performansını analiz etmede doğruluk değerinden farklı değerli bilgilerde sunmaktadır. Tahmin olumlu olduğu durumlarda, değerlendirilen sonuç doğru olduğunda Doğru Pozitif (DP), yanlış olduğunda Yanlış Pozitif (YP) değerleri, tahmin olumsuz olduğu durumlarda, değerlendirilen sonuç doğru olduğunda Doğru Negatif (DN), yanlış olduğunda Yanlış Negatif (YN) değerleri karmaşıklık matrisinden elde edilecek olan parametrelerdir.

Doğruluk ölçümü haricinde duyarlılık pozitif sınıfın tahmin performansını verirken, özgüllük negatif sınıfın tahmin oranını veren bir ölçümdür. Kesinlik, örneklerin kaç tanesinin gerçekte pozitif olduğunu veren bir ölçümdür. Kesinlik ve duyarlılık arasında denge sağlayan F1 ölçümü, bu iki değer

harmonik ortalamasını veren ölçümdür. Denklem 4-8 arasında performans ölçümlerine ait eşitlikler verilmektedir. (Başaran ve Çelik, 2020).

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \quad (4)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (5)$$

$$\text{Özgüllük} = \frac{DN}{YP+DN} \quad (6)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (7)$$

$$F1 = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (8)$$

Bunun yanı sıra kullanılan yöntemler beş kat çapraz doğrulama yöntemi ile değerlendirilmiştir. Çapraz doğrulama yönteminde veri setindeki örnekler her biri eşit beş gruba ayrılmaktadır. Dört grupta bulunan örnekler eğitim setini, kalan bir gruptaki örnekler de test setini oluşturmaktadır. Her gruptaki örnekler bir kez test setini oluşturduktan sonra çapraz doğrulama işlemi sona ermektedir.

## BULGULAR VE TARTIŞMA

Kamuya açık CASME-II Mİ veri seti ön işleme aşaması gerçekleştirildikten sonra geleneksel yöntemlerden gabor modeli ve veriye dayalı yöntemlerden derin öğrenme modeli olan Xception ile öznitelik çıkarma, öznitelik seçme ve doğrusal DVM sınıflandırma algoritmaları kullanılarak deneysel test sonuçları elde edilmiştir. Derin öğrenme kullanılarak yapılan deneysel ölçümlerin hepsinde Xception modeline ait parametreler Çizelge 2’de verilmiştir.

**Çizelge 2.** Deneysel ölçümlerde kullanılan Xception modeline ait parametreler

Weights (ağırlıklar)	İnclude_top (tam bağlı katman kullanımı)	İnput_shape (giriş biçimi)	Batch_size (parti boyutu)	Özniteliklerin elde edildiği katman
ImageNet	False	224*224*3	12	block14_sepconv2_act

Gabor uygulamalarında, 64 farklı filtre kullanılmıştır. Gabor çekirdek boyutu (5,5) değeri, sigma bir ve üç değerleri, theta ve lamda  $0^0$ ,  $45^0$ ,  $90^0$ ,  $135^0$  açı değerleri ve gamma 0.05 ve 0.25 değerleri, faz kayması (psi) sıfır değeri yapılan uygulamalarda kullanılmıştır.

Hem Xception derin öğrenme modelinde hem de Gabor filtreleme modelinde kullanılan sınıflandırma algoritması olan SVC’de ‘kernel’ parametre değeri ‘linear’, ‘C’ parametre değeri ‘1.0’ olarak ayarlanırken, çapraz doğrulama olarak kullanılan RepeatedKfold algoritmasında ise ‘n\_splits’ değeri ‘5’, ‘n\_repeats’ değeri ‘5’, ‘random state’ değeri ‘42’ olarak belirlenmiştir.

CASME-II veri setinde önışlem aşamasında farklı öznitelik ler elde etmek için, her bir video klipinde bulunan başlangıç ve tepe kareleri kullanılarak Farneback, TV-L1, TV-L1 yatay ve TV-L1 dikey optik akış görüntüleri oluşturulmuştur. Bunun yanı sıra önışleme aşamasından geçmemiş doğal görüntülerin de tepe kareleri deneylerde kullanılmıştır.

İlk deneysel çalışmada, seçilen veri setinde 94 negatif, 32 pozitif, 28 sürpriz örneklemeden oluşan veri setinin, doğal görüntülerinin tepe kareleri ve iki farklı optik akış görüntüleri Xception ve Gabor modellerine girdi olarak verilmiştir. Buna göre 2 boyutlu görüntü verileri Xception’dan 100352 adet öznitelik ve Gabor’dan 50176 adet öznitelik çıkarılarak sınıflandırılmıştır. Bu iki modelden alınan öznitelik haritalarının doğrusal DVM sınıflandırma performanslarının sonuçları Çizelge 3 de verilmiştir.

**Çizelge 3.** Modellerin arttırılmamış CASME-II veri tabanına uygulanması ve doğrusal DVM ile sınıflandırma sonuçları

Model	Öznitelik Çıkarma	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1
Xception	Normal	0.6766	0.5818	0.7909	0.6138	0.5944
Gabor	Görüntü	0.6922	0.6016	0.8008	0.6166	0.6075
Xception	Farneback	0.6325	0.4878	0.7439	0.5869	0.5112
Gabor		0.6013	0.5056	0.7528	0.5188	0.5112
Xception	TVL1_Dual	0.6597	0.5543	0.7772	0.6319	0.5795
Gabor		0.5870	0.4922	0.7461	0.5101	0.4992
Xception	TVL1_u	0.6442	0.5363	0.7682	0.5576	0.5447
Gabor		0.7870	0.7403	0.8701	0.7318	0.7354
Xception	TVL1_v	0.7805	0.7246	0.8623	0.7670	0.7430
Gabor		<b>0.8260</b>	<b>0.7919</b>	<b>0.8960</b>	<b>0.8003</b>	<b>0.7952</b>

Çizelge 3' deki CASME-II veri setinde TV-L1 dikey görüntülerinden elde edilen özniteliklerin sınıflandırma ölçümleri iki model içinde en yüksek performansı göstermiştir. Buna göre Gabor modeli, doğruluk 0.8260, duyarlılık değeri 0.7919 özgüllük değeri 0.8960, kesinlik değeri 0.8003 ve f1 değeri 0,7952 ile en başarılı performansı göstermiştir.

İkinci deneysel çalışmada veri tabanı, veri arttırma tekniği ile her sınıf en büyük örnekleme sahip negatif sınıfa eşitlenerek, her sınıf 94 adet örnekleme sahip olmuştur. Böylece veri seti dengeli hale getirilip, sınıflandırıcının daha iyi sınıflandırması beklenmektedir (Liu ve ark., 2019). Arttırılmış veri tabanının, doğal biçimi ve farklı optik akış öznitelikleri Xception ve Gabor modellerine girdi olarak verilmiştir. ESA ve Gabor modellerinden alınan özniteliklerin doğrusal DVM sınıflandırma performanslarının sonuçları Çizelge 4' de verilmiştir.

**Çizelge 4.** Modellerin dengeli arttırılmış CASME-II veri setine uygulanması ve doğrusal DVM ile sınıflandırma sonuçları

Model	Öznitelik Çıkarma	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1
Xception	Normal	0.7504	0.7504	0.8752	0.7501	0.7492
Gabor	Görüntü	0.7447	0.7447	0.8723	0.7430	0.7428
Xception	Farneback	0.6723	0.6723	0.8362	0.6722	0.6722
Gabor		0.6191	0.6191	0.8096	0.6167	0.6173
Xception	TVL1_Dual	0.6979	0.6979	0.8489	0.6983	0.6980
Gabor		0.5837	0.5837	0.7918	0.5879	0.5822
Xception	TVL1_u	0.6709	0.6709	0.8355	0.6679	0.6667
Gabor		0.7099	0.7099	0.8550	0.7092	0.7061
Xception	TVL1_v	0.7702	0.7702	0.8851	0.7707	0.7700
Gabor		<b>0.8291</b>	<b>0.8291</b>	<b>0.9145</b>	<b>0.8293</b>	<b>0.8287</b>

Çizelge 4' deki arttırılmış dengeli veri setinde TV-L1 dikey görüntülerinden elde edilen özniteliklerin sınıflandırma ölçümleri iki model içinde en yüksek performansı göstermiştir. Buna göre Gabor modeli, doğruluk değeri 0.8291, duyarlılık değeri 0.8291 özgüllük değeri 0.9145, kesinlik değeri 0.8293 ve f1 değeri 0.8287 ile en başarılı performansı göstermiştir. Veri arttırma tekniği ve dengeli örneklemenin sonrasında bir önceki deneysel çalışmada elde edilen en başarılı performanslar karşılaştırıldığında duyarlılık ve F1 ölçümlerinde %3 den daha fazla bir performans artışına, bazı modellerde ise %16'den fazla F1 artışı, %18'den fazla duyarlılık artışı ölçülerek modelin performansına olumlu etkisi olduğu gözlemlenmiştir.

Üçüncü deneysel çalışmada, öznitelik seçim yöntemi kullanılarak Mİ tanımada en verimli öznitelikler filtrelenerek, modelin performansı arttırılması hedeflenmiştir. Öznitelik seçimi algoritmalarından olan ÇDÖÖE algoritması kullanılıp, algoritmada 'estimator' parametresi DVM



sınıflandırıcısı, ‘step’ parametresi ‘1000’, ‘scoring’ parametre değeri ‘accuracy’, ‘verbose’ parametresi ise ‘1’ olarak belirlenmiştir. Elde edilen bu öznelikler doğrusal DVM sınıflandırıcı ile sınıflandırılmıştır. Çizelge 5’de arttırılmış dengeli CAME-II veri setinde TV-L1\_dikey optik akış görüntüleri ile birlikte kullanılan Xception modelinin, geleneksel ESA modellerinin ve Gabor modelinin performansları karşılaştırmalı olarak sunulmaktadır.

**Çizelge 5.** Filtrelenmiş TVL1\_dikey öznelik haritalarının Xception ve Gabor modelleri ve Doğrusal DVM ile sınıflandırma sonuçları

Model	Öznelik Seçimi	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1
Xception		<b>0.9248</b>	<b>0.9248</b>	<b>0.9624</b>	<b>0.9251</b>	<b>0.9249</b>
Gabor		0.9170	0.9170	0.9585	0.9173	0.9168
VGG-16	ÇDÖÖE	0.8709	0.8709	0.9355	0.8704	0.8705
ResNet-50		0.9092	0.9092	0.9546	0.9093	0.9091
MobilNet		0.8936	0.8936	0.9468	0.8944	0.8936

İncelenen modeller arasında en performanslı ölçümleri veren Xception modelinden elde edilen en iyi performans ölçümleri doğruluk 0.9184, duyarlılık 0.9184, özgüllük 0.9592, kesinlik 0.9190 ve F1 0.9185 olarak ölçülmüştür. Başlangıçta yapılan deneysel çalışmada (Çizelge 3) en başarılı performansı veren Gabor modeli ile son deneysel çalışmada elde edilen en performanslı ölçümler (Çizelge 5) karşılaştırılması Çizelge 6’da verilmiştir.

**Çizelge 6.** En performanslı ilk ve son deneysel çalışmanın karşılaştırılması

Model	Öznelik Çıkarma	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1
Xception	TVL1_v	<b>0.9248</b>	<b>0.9248</b>	<b>0.9624</b>	<b>0.9251</b>	<b>0.9249</b>
Gabor		0.8260	0.7919	0.8960	0.8003	0.7952

Çizelge 3’deki en başarılı ölçüm ile karşılaştırıldığında modelin son ölçümlerinde %9.88 doğruluk, %13.29 duyarlılık, %6.64 özgüllük, %12.48 kesinlik, %12.97 F1 oranında bir performans artışı gözlemlenmektedir.

Mİ tanıma görevi kullanıldığında güvenlikten ticarete, sağlıktan eğitime birçok alanda fayda sağlayabilir. Yapılan ilk deneysel çalışmada CASME-II veri seti üzerinde kullanılan modellerin ölçümlerinde F1 ve duyarlılık sonuçları ile doğruluk sonuçları arasında büyük farklar olduğu görülmektedir. Bunun sebebi negatif sınıfa ait verilerin diğer iki sınıfa ait verilerin toplamından daha büyük olması ve sınıflar arasında veri dengesizliğidir. Baskın örneklemeli sınıfların bulunduğu veri setlerinde performans değerlendirilmesinde doğruluk ölçüsünün tek başına kullanılması önyargıya sebep olabilmektedir. Dolayısıyla F1 ve duyarlılık ölçümleri, dengesiz örneklemeli sınıfları bulunan veri setlerinin sınıflandırılmasında tüm sınıfların eşit derecede iyi tahmin edilip edilmediği hakkında dengeli bir yargı sunmaktadır (Yap ve ark., 2018; See ve ark., 2019). Her ne kadar doğruluk oranları kısmen iyi gibi görünse de F1 ve duyarlılık değerleri bazı ölçümlerde %50’nin altında bulunmaktadır. Diğer ölçümlerinde başarısını artırıp daha tutarlı ölçümler elde etmek için veri arttırma tekniği kullanılarak veri tabanı çoğaltılıp dengelenmiştir. Veri arttırma sonrası artan başarı oranlar incelendiğinde; farneback görüntüleri kullanılarak yapılan Xception modeli deneyinde %16 yı geçen F1 ve %18’i geçen duyarlılık ölçümleri görülmektedir. Buradan veri arttırma tekniğinin kullanılması ve dengeli örneklemeye sahip sınıflandırmanın Mİ tanıma performansını arttırdığı (Uzun ve ark., 2022), Xception ve Gabor modelinde olumlu etkiler yaptığı sonucuna ulaşılmaktadır.

Öznelik seçim algoritması kullanıldığında ise Mİ tanımada verimliliği daha fazla olan özneliklerin filtrelenerek seçilmesiyle yapılan sınıflandırmalarda, ölçüm sonuçlarının performansında önemli artışlar gözlemlenmiştir. ÇDÖÖE öznelik seçim algoritması kullanılarak yapılan ölçümlerde

başlangıçtaki en iyi ölçümlerle kıyaslandığında %9.24 doğruluk, %12.65 duyarlılık ve %12.33 F1 oranında performansa katkı sağladığı gözlemlenmiştir. Öznitelik seçimi yapılarak elde edilen verilerin, Mİ tanıma performansını arttırmada olumlu etkisi olduğu deneyler sonucu gözlemlenmiştir.

Xception teknolojisinin avantajlarından biriside Inception modelinde tasarlandığı gibi derinlemesine ayrıştırılabilir evrişim ve noktasal evrişim kullanarak parametre sayısını büyük oranda azaltıp hesaplama yükünü azaltmaktadır. Xception modelinde ise kendisinden önceki versiyonu olan Inception dan farkı, önce noktasal evrişim ardından derinlemesine ayrıştırılabilir evrişim uygulamaktadır. Böylece Inception modelinden hem daha az parametre kullanmakta hem de doğruluk ve hata oranı performansında daha başarılı olmaktadır (Chollet, 2017).

Çalışma (Allaert ve ark., 2022) 'de farklı optik akış yöntemleri karşılaştırıldığında farklı blok boyutlarında en sağlam iki yöntem olarak Farneback ve TV-L1 sonucuna varılmıştır. Bundan dolayı çalışmamızda bu iki yöntem haricinde TV-L1 yatay ve dikey görüntüleri de Mİ tanıma görevinde kullanılmıştır. Optik akış tekniğinin kullanılmasının başka bir avantajı da video kare dizisinin tamamının kullanılmasına yerine, hareketin başladığı ve zirve yaptığı kareler kullanılarak hesaplama yükü azaltılmaktadır. En başarılı sonuçların TV-L1 dikey bileşenlere sahip görüntülerden elde edildiği gözlemlenmiştir. Önerilen model yapısının dezavantajlarından birisi ise ÇDÖÖE algoritmasının özyinelemeli yapısından dolayı öznitelik haritaları arttıkça filtreleme süresi de doğru orantılı olarak artmaktadır. Farklı öznitelik seçim algoritmaları kullanılarak model maliyetinde ve başarısında daha verimli sonuçlar elde edilebilir. Mİ tanıma görevinde elde edilen diğer son teknoloji modeller ile önerdiğimiz modelin karşılaştırılması Çizelge 6'de sunulmuştur. Buna göre modelimizin rekabetçi ve sonuçların tatmin edici olduğu görülmektedir.

**Çizelge 7.** Önerilen çalışmanın en son modellerle karşılaştırılması

Metot	Doğruluk	F1	Veri Tabanı
OFF-ApexNet (Gan ve ark., 2019)	0.746	0.710	SMIC+CASME-II +SAMM
STSTNet+GA (Liu ve ark., 2021)	0.859	0.837	SMIC+CASME-II +SAMM
Deep3DCANN (Thuseethan ve ark., 2022)	0.86	0.84	CASME II
ESA+PSO+DVM (Uzun ve ark., 2022)	0.8784	0.8765	SMIC+CASME-II +SAMM
DFN (Sun ve ark., 2022)	0.9028	0.8923	CASME II
<b>Önerilen model</b>	<b>0.9248</b>	<b>0.9249</b>	CASME II

Bu makale yazıldığı sırada Mİ konusuna ait literatür incelendiğinde , Mİ'ye ait farklı optik akış görüntülerin ve bu görüntülere ait bileşenlerin incelendiği sınırlı sayıda çalışma olduğu gözlemlenmiştir. Mİ optik akış görüntülerinin farklı bileşenleri de Mİ tanımaya yönelik daha zengin özellikler içerebileceği literatüre katkı olarak düşünülebilir.

Bu makelede bulunan sınırlamalar Mİ sınıf etiketleri ve labaratuvar ortamından elde edilmiş Mİ örnekleridir. Modelin öğrendiği sınıf etiketleri deneylerde kullanılan mevcut etiketlerdir. Farklı bir Mİ duygusu içeren bir sınıf etiketi için çözüm üretmeyeceğidir. Bir diğer husus ise veri seti örnekleri labaratuvar ortamında katılımcılardan yüz ifadelerini bastırmaları ve kontrol etmeleri istendiğinden, gerçek hayattaki Mİ örnekleri koşullanma olmadan doğal olacağı için öğrenilen örneklerden farklı olabileceği göz önüne alınmalıdır.

## SONUÇ

Mİ tanıma görevi için önerilen bu çalışmada sırasıyla önışleme, öznitelik çıkarma, öznitelik seçimi ve sınıflandırma işlemleri gerçekleştirilen bir model yapısı sunulmuştur. Görüntülerden yüz bölgesi çıkarıldıktan sonra önışleme aşamasında optik akış yöntemleri öznitelik çıkarma aşamasında geleneksel ve derin öğrenme yöntemleri, öznitelik seçim aşamasında çapraz doğrulama ile özyinelemeli öznitelik eleme algoritmaları kullanılmıştır. Sınıflandırma aşamasında DVM sınıflandırma algoritması kullanılarak sonuçlar diğer çalışmalar ile karşılaştırılmıştır. Çalışmamızın özgünlüklerinden biri Mİ tanıma görevinde çapraz doğrulama ile özyinelemeli öznitelik eleme algoritmasının geleneksel ve derin öğrenme yöntemleri ile birlikte deneysel çalışmalarda kullanılıp karşılaştırılmasıdır. Bu çalışmada Mİ veri seti görüntülerinin yapay olarak artırılarak sınıfların dengelenmesi sonucunda performans ölçümlerinin başarısının artırılabilceği kanıtlanmıştır. Veri artırma yöntemine bağlı olarak modelin performansında F1 ve duyarlılık ölçüm değerlerinde %3'ten fazla bir artış görülmüştür. Veri seti farklılıklarına göre %16'den fazla F1 artışı, %18'den fazla duyarlılık ölçüm artışı gözlemlenmiştir. Sonuç olarak önerilen modelimiz ile başlangıçta elde edilen deneysel test sonuçlarına göre en başarılı ölçümler referans alındığında %9.88 doğruluk, %13.29 duyarlılık, %6.64 özgüllük, %12.48 kesinlik, %12.97 F1 oranında model performansını artırılmıştır. Modelimiz, CASME-II veri seti üzerinde 0.9248 doğruluk, 0.9249 F1 ve 0.9248 duyarlılık değerleri elde ederek en yüksek sınıflandırma doğruluğu sağlamıştır. Ek olarak özgüllük ölçüm değeri 0.9624'ye, kesinlik ölçüm değeri 0.9251'e ulaşmıştır.

## Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

## Yazar Katkısı

Yazarlar makaleye numaralandırma sırasında göre katkı sağlamış olduklarını beyan eder.

## KAYNAKLAR

- Adegun, I. P., & Vadapalli, H. B. (2020). Facial micro-expression recognition: A machine learning approach. *Scientific African*, 8, e00465. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.sciaf.2020.e00465>
- Ahadit, A. B., & Jatoth, R. K. (2022). A novel multi-feature fusion deep neural network using HOG and VGG-Face for facial expression classification. *Machine Vision and Applications*, 33(4), 55. Tarihinde adresinden erişildi <https://doi.org/10.1007/s00138-022-01304-y>
- Allaert, B, Ward, I. R., Bilasco, I. M., Djeraba, C., & Bennamoun, M. (2022). A comparative study on optical flow for facial expression analysis. *Neurocomputing*, 500, 434–448. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.neucom.2022.05.077>
- Allaert, Benjamin, Ward, I. R., Bilasco, I.-M., Djeraba, C., & Bennamoun, M. (2019). Optical flow techniques for facial expression analysis: Performance evaluation and improvements.
- Başaran, E., Cömert, Z., & Çelik, Y. (2020). Convolutional neural network approach for automatic tympanic membrane detection and classification. *Biomedical Signal Processing and Control*, 56, 101734.
- Basaran, E., Cömert, Z., Çelik, Y., Budak, Ü., & Sengür, A. (2020). Otitis media diagnosis model for tympanic membrane images processed in two-stage processing blocks. *IOP Sci*, 14, 1–27.
- Ben, X., Ren, Y., Zhang, J., Wang, S.-J., Kpalma, K., Meng, W., & Liu, Y.-J. (2021). Video-based Facial Micro-Expression Analysis: A Survey of Datasets, Features and Algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1. Tarihinde adresinden erişildi <https://doi.org/10.1109/TPAMI.2021.3067464>
- Bozkurt, F. Skin lesion classification on dermatoscopic images using effective data augmentation and pre-trained deep learning approach. *Multimed Tools Appl* 82, 18985–19003 (2023).

- Cai, L., Li, H., Dong, W., & Fang, H. (2022). Micro-expression recognition using 3D DenseNet fused Squeeze-and-Excitation Networks. *Applied Soft Computing*, 119, 108594. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.asoc.2022.108594>
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. İçinde *Proceedings of the IEEE conference on computer vision and pattern recognition* (ss. 1251–1258).
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. Tarihinde adresinden erişildi <https://doi.org/10.1007/BF00994018>
- Fan, L., He, J., Zheng, Y., Nie, Y., Chen, T., & Zhang, H., “Facial micro-expression recognition impairment and its relationship with social anxiety in internet gaming disorder”, *Curr. Psychol.*, 2022, doi: 10.1007/s12144-022-02958-7.
- Farneback, G. (2003). Two-frame motion estimation based on polynomial expansion. İçinde *Scandinavian conference on Image analysis* (ss. 363–370). Springer.
- Gan, Y S, See, J., Khor, H.-Q., Liu, K.-H., & Liong, S.-T. (2022). Needle in a Haystack: Spotting and recognising micro-expressions “in the wild”. *Neurocomputing*, 503, 283–298. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.neucom.2022.06.101>
- Gan, Yee Siang, Liong, S.-T., Yau, W.-C., Huang, Y.-C., & Tan, L.-K. (2019). OFF-ApexNet on micro-expression recognition system. *Signal Processing: Image Communication*, 74, 129–139.
- Gao, T., Zhao, X. M., Chen, T., Liu, Z. W., & Ni, C. (2017). Face description based on adaptive local weighted Gabor comprehensive histogram feature. *Multimedia Tools and Applications*, 76(10), 12893–12916. Tarihinde adresinden erişildi <https://doi.org/10.1007/s11042-016-3701-y>
- Hurley, C. M., Anker, A. E., Frank, M. G., Matsumoto, D., & Hwang, H. C. (2014). Background factors predicting accuracy and improvement in micro expression recognition. *Motivation and emotion*, 38(5), 700–714.
- Jirik, M., Ryba, T., & Zelezny, M. (2011). Texture based segmentation using graph cut and Gabor filters. *Pattern Recognition and Image Analysis*, 21, 258–261.
- Karcioglu, A. A., & Aydin, T. (2019, April). Sentiment analysis of Turkish and english twitter feeds using Word2Vec model. In 2019 27th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE
- Lee, Y.-C., & Chen, C.-H. (2009). Feature Extraction for Face Recognition Based on Gabor Filters and Two-Dimensional Locality Preserving Projections. İçinde *2009 Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing* (ss. 106–109). Tarihinde adresinden erişildi <https://doi.org/10.1109/IIH-MSP.2009.210>
- Li, Y., Huang, X., & Zhao, G. (2020). Joint Local and Global Information Learning With Single Apex Frame Detection for Micro-Expression Recognition. *IEEE Transactions on Image Processing*, 30, 249–263.
- Lin, C., Long, F., Huang, J., & Li, J. (2018). Micro-Expression Recognition Based on Spatiotemporal Gabor Filters. İçinde *2018 Eighth International Conference on Information Science and Technology (ICIST)* (ss. 487–491). Tarihinde adresinden erişildi <https://doi.org/10.1109/ICIST.2018.8426088>
- Liong, S.-T., Gan, Y. S., See, J., Khor, H.-Q., & Huang, Y.-C. (2019). Shallow triple stream three-dimensional cnn (ststnet) for micro-expression recognition. İçinde *2019 14th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2019)* (ss. 1–5). IEEE.
- Liu, K.-H., Jin, Q.-S., Xu, H.-C., Gan, Y.-S., & Liong, S.-T. (2021). Micro-expression recognition using advanced genetic algorithm. *Signal Processing: Image Communication*, 93, 116153. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.image.2021.116153>
- Liu, N., Liu, X., Zhang, Z., Xu, X., & Chen, T. (2020). Offset or Onset Frame: A Multi-Stream Convolutional Neural Network with CapsuleNet Module for Micro-expression Recognition. İçinde *2020 5th International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS)* (ss. 236–240). IEEE.
- Liu, Y., Du, H., Zheng, L., & Gedeon, T. (2019). A neural micro-expression recognizer. İçinde *2019 14th IEEE international conference on automatic face & gesture recognition (FG 2019)* (ss. 1–4). IEEE.

- Mustaqim, A. Z., Adi, S., Pristyanto, Y., & Astuti, Y. (2021). The Effect of Recursive Feature Elimination with Cross-Validation (RFECV) Feature Selection Algorithm toward Classifier Performance on Credit Card Fraud Detection. İçinde *2021 International Conference on Artificial Intelligence and Computer Science Technology (ICAICST)* (ss. 270–275). Tarihinde adresinden erişildi <https://doi.org/10.1109/ICAICST53116.2021.9497842>
- Ou, J., Bai, X.-B., Pei, Y., Ma, L., & Liu, W. (2010). Automatic Facial Expression Recognition Using Gabor Filter and Expression Analysis. İçinde *2010 Second International Conference on Computer Modeling and Simulation* (C. 2, ss. 215–218). Tarihinde adresinden erişildi <https://doi.org/10.1109/ICCMS.2010.45>
- Peng, M., Wang, C., Chen, T., Liu, G., ve Fu, X., “Dual temporal scale convolutional neural network for micro-expression recognition”, *Front. Psychol.*, c. 8, s. 1745, 2017.
- Porter, S., Ten Brinke, L., & Wallace, B. (2012). Secrets and lies: Involuntary leakage in deceptive facial expressions as a function of emotional intensity. *Journal of Nonverbal Behavior*, 36(1), 23–37.
- Rose, N. (2006). Facial Expression Classification using Gabor and Log-Gabor Filters. İçinde *7th International Conference on Automatic Face and Gesture Recognition (FG06)* (ss. 346–350). Tarihinde adresinden erişildi <https://doi.org/10.1109/FGR.2006.49>
- See, J., Yap, M. H., Li, J., Hong, X., & Wang, S. (2019). MEGC 2019 – The Second Facial Micro-Expressions Grand Challenge. İçinde *2019 14th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2019)* (ss. 1–5). Tarihinde adresinden erişildi <https://doi.org/10.1109/FG.2019.8756611>
- Stanley, J. T., & Webster, B. A. (2019). A comparison of the effectiveness of two types of deceit detection training methods in older adults. *Cognitive Research: Principles and Implications*, 4(1), 26. Tarihinde adresinden erişildi <https://doi.org/10.1186/s41235-019-0178-z>
- Sun, M.-X., Liong, S.-T., Liu, K.-H., & Wu, Q.-Q. (2022). The heterogeneous ensemble of deep forest and deep neural networks for micro-expressions recognition. *Applied Intelligence*, 52(14), 16621–16639. Tarihinde adresinden erişildi <https://doi.org/10.1007/s10489-022-03284-y>
- Sun, Z., Hu, Z., Zhao, M., & Li, S. (2020). Multi-scale active patches fusion based on spatiotemporal LBP-TOP for micro-expression recognition. *Journal of Visual Communication and Image Representation*, 71, 102862. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.jvcir.2020.102862>
- Takalkar, M., Xu, M., Wu, Q., & Chaczko, Z. (2018). A survey: facial micro-expression recognition. *Multimedia Tools and Applications*, 77(15), 19301–19325.
- Takalkar, M., Xu, M., ve Chaczko, Z. “Manifold feature integration for micro-expression recognition”, *Multimed. Syst.*, c. 26, sayı 5, ss. 535–551, 2020, doi: 10.1007/s00530-020-00663-8.
- Tang, J., Li, L., Tang, M., & Xie, J. (2022). A novel micro-expression recognition algorithm using dual-stream combining optical flow and dynamic image convolutional neural networks. *Signal, Image and Video Processing*. Tarihinde adresinden erişildi <https://doi.org/10.1007/s11760-022-02286-0>
- Thuseethan, S., Rajasegarar, S., & Yearwood, J. (2022). Deep3DCANN: A Deep 3DCNN-ANN Framework for Spontaneous Micro-expression Recognition. *Information Sciences*. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.ins.2022.11.113>
- Tonkal, Ö., Polat, H., Başaran, E., Cömert, Z., & Kocaoğlu, R. (2021). Machine Learning Approach Equipped with Neighbourhood Component Analysis for DDoS Attack Detection in Software-Defined Networking. *Electronics*, 10(11), 1227.
- Ukil, A. (2007). Support Vector Machine BT - Intelligent Systems and Signal Processing in Power Engineering. İçinde A. Ukil (Ed.) (ss. 161–226). Berlin, Heidelberg: Springer Berlin Heidelberg. Tarihinde adresinden erişildi [https://doi.org/10.1007/978-3-540-73170-2\\_4](https://doi.org/10.1007/978-3-540-73170-2_4)
- Uzun, M. Z., Celik, Y., & Basaran, E. (y.y.). Micro-Expression Recognition by Using CNN Features with PSO Algorithm and SVM Methods. *learning*, 2(3), 5–8, (2022).
- Wang, C., Xiao, Z., & Wu, J. (2019). Functional connectivity-based classification of autism and control using SVM-RFECV on rs-fMRI data. *Physica Medica*, 65, 99–105. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.ejmp.2019.08.010>

- Warren, G., Schertler, E., & Bull, P. (2009). Detecting deception from emotional and unemotional cues. *Journal of Nonverbal Behavior*, 33(1), 59–69.
- Xia, B., Wang, W., Wang, S., & Chen, E. (2020). Learning from Macro-expression: a Micro-expression Recognition Framework. İçinde *Proceedings of the 28th ACM International Conference on Multimedia* (ss. 2936–2944).
- Yan, W.-J., Li, X., Wang, S.-J., Zhao, G., Liu, Y.-J., Chen, Y.-H., & Fu, X. (2014). CASME II: An improved spontaneous micro-expression database and the baseline evaluation. *PloS one*, 9(1), e86041.
- Yan, W.-J., Wu, Q., Liang, J., Chen, Y.-H., & Fu, X. (2013). How Fast are the Leaked Facial Expressions: The Duration of Micro-Expressions. *Journal of Nonverbal Behavior*, 37(4), 217–230. Tarihinde adresinden erişildi <https://doi.org/10.1007/s10919-013-0159-8>
- Yap, M. H., See, J., Hong, X., & Wang, S.-J. (2018). Facial Micro-Expressions Grand Challenge 2018 Summary. İçinde *2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018)* (ss. 675–678). Tarihinde adresinden erişildi <https://doi.org/10.1109/FG.2018.00106>
- Zhao, Y., & Xu, J. (2020). Compound Micro-Expression Recognition System. İçinde *2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)* (ss. 728–733). Tarihinde adresinden erişildi <https://doi.org/10.1109/ICITBS49701.2020.00161>
- Zhou, L., Mao, Q., Huang, X., Zhang, F., & Zhang, Z. (2022). Feature refinement: An expression-specific feature learning and fusion method for micro-expression recognition. *Pattern Recognition*, 122, 108275. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.patcog.2021.108275>
- Zhou, L., Mao, Q., & Xue, L. (2019). Cross-database micro-expression recognition: a style aggregated and attention transfer approach. İçinde *2019 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)* (ss. 102–107). IEEE.
- Zhou, Y., Song, Y., Chen, L., Chen, Y., Ben, X., & Cao, Y. (2022). A novel micro-expression detection algorithm based on BERT and 3DCNN. *Image and Vision Computing*, 119, 104378. Tarihinde adresinden erişildi <https://doi.org/https://doi.org/10.1016/j.imavis.2022.104378>