



Araştırma Makalesi

## Yüz İfadelerini Sınıflandırmada CNN Modellerinde Kullanılan Optimizasyon Yöntemlerinin Karşılaştırılması

Berrin İŞLEK\*<sup>1</sup>, Hamza EROL<sup>2</sup><sup>1</sup>Sivas Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Sivas, Türkiye<sup>2</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

### ÖZ

İnsan yüz ifadeleri, kişiler için iletişimde ana bilgi kanallarından biridir. İnsanlar günlük hayatlarında psikolojik durumları ifade etmek için çok fazla yüz ifadesi oluşturmaktadır. Bu yüz ifadeleri temel ve karmaşık duygular olarak ayrılır. İnsanlar bu duygu ifadelerini tanımlamada hala zorlanırken makineler için de geliştirmekte olan bir konudur. Bu sebeple son zamanlarda çok fazla ilgi görmektedir. Bu çalışmada Ohio Eyalet Üniversitesine ait Compound Emotion (CE) veri setindeki temel 7 duygu olan doğal, mutlu, üzgün, öfkeli, şaşırılmış, korkulu ve iğrenme duyguları üzerinde durulmaktadır. Veri seti 1610 görüntüden oluşmaktadır. Başarımı arttırmak için veri çoğaltma işlemi uygulanarak 5478 görüntü elde edilmektedir. Eğitilmiş Evrişimli sinir ağı (CNN) modelleri ile sınıflandırma işleminde optimizasyon yöntemlerinin etkileri gösterilmektedir. VGG19 ve MobileNet modelleri ile Adadelta, Adagrad ve Stokastik gradyan inişi (SGD) optimizasyon yöntemlerinin duygu sınıfları üzerindeki sonuçları grafikler ve değerlendirme tabloları ile birlikte detaylı incelenmektedir.

### Anahtar Kelimeler:

Evrişimli Sinir Ağı  
Optimizasyon Yöntemleri  
Yüz İfadeleri  
Sınıflandırma  
Veri Arttırma

## Comparison of Optimization Methods Used in CNN Models for Classification of Facial Expressions

### ABSTRACT

Human facial expressions are one of the main channels of communication for people. People make too many facial expressions to express psychological states in their daily lives. These facial expressions are divided into basic and complex emotions. While humans still struggle to identify these expressions of emotion, it is an emerging topic for machines as well. For this reason, it has attracted a lot of attention lately. In this study, the 7 basic emotions in the Compound Emotion (CE) dataset of Ohio State University, which are natural, happy, sad, angry, surprised, fearful and disgusted, are emphasized. The dataset consists of 1610 images. To increase the performance, 5478 images are obtained by applying the data duplication process. The effects of optimization methods in the classification process are shown with trained convolutional neural network (CNN) models. The results of VGG19 and MobileNet models and Adadelta, Adagrad and Stochastic gradient descent (SGD) optimization methods on emotion classes are examined in detail with graphics and evaluation tables.

### Keywords:

Convolutional Neural Network  
Optimization Methods  
Face Expressions  
Classification  
Data Augmentation

\*Sorumlu Yazar

\*(berrinislek@sivas.edu.tr) ORCID ID 0000 - 0003 - 1984 - 357X  
(herol@mersin.edu.tr) ORCID ID 0000 - 0001 - 8983 - 4797

e-ISSN: 2717-8579

Geliş Tarihi: 18/11/2022; Kabul Tarihi: 24/02/2023

Bilgisayar Bilimleri ve Teknolojileri Dergisi

## 1. GİRİŞ

Yüz ifadelerinin oluşturduğu duygular, yüzyıllardır psikoloji ve bilişim alanında önemli araştırma konusudur. Bir kişinin yüz ifadelerinin analizi ile fiziksel ve duygusal durumu ile ilgili birçok çıkarım yapmak mümkündür. Günümüz teknolojik gelişmeleriyle beraber bireylerin yüz ifadelerinden duygu tespitinin yapılması medikal (Yolcu vd., 2017), robotik (Littlewort vd., 2003), trafik (Zhang ve Hua, 2015), pazarlama gibi farklı alanlarda kullanımı yaygınlaşmıştır.

Araştırmalarda duygular, temel ve karmaşık duygular olarak iki sınıfta incelenmektedir. Araştırmalar iki duygu sınıfı olduğunu gösterse de çalışmalar genellikle temel duyguların tespiti üzerine yoğunlaştığı görülmektedir. Temel duygular mutlu (happy), üzgün (sad), öfkeli (angry), şaşırılmış (surprised), iğrenmiş (disgusted), doğal (neutral) ve korkulu (fearful) yüz ifadeleridir. Yüz ifadelerinin belirlenmesinin temel hedef, belirli yüz görünümüne karşılık gelen insanların duygu durumunu tanımlamaktır. Bu nedenle insan bilgisayar etkileşimi olan birçok sosyal uygulamalarda sıkça kullanılmaktadır (Ko, 2018).

Önceki yıllarda, birçok geleneksel yöntemlerle ön işlem ve özellik çıkarım ile kullanılan makine öğrenmesi yöntemi önerilmiştir. Ancak birçok sebeple istenilen başarımlar elde edilmemektedir (Li vd., 2020). Çoklu hesaplama modellerine izin veren yapısı, büyük ve karmaşık verileri öğrenmesinde verimli sonuçlar vermesinden dolayı yüz ifadelerinden duygu analizi için derin öğrenme yöntemlerinin kullanımı artmaktadır ve yüksek başarımlar elde edilen birçok çalışma yapılmıştır (Voulodimos ve Doulamis, 2018).

2015 yılında Chen ve arkadaşları, görüntü verisinden duygu analizi için oluşturdukları Evrişimli Sinir Ağı (CNN) modeli geleneksel yöntemlerden daha iyi sonuçlar elde etmiştir (Chen vd., 2015). Karaman ve Özdemir, bir CNN modeli olan Alexnet ile video karelerinden yüz ifadeleri tanıma sistemi oluşturmuştur (Özdemir ve Karaman, 2017). Jung ve arkadaşları, görüntü dizilerinden zamansal görünüm özellikleri ve zamansal geometri özellikleri çıkartan iki farklı CNN modelini birleştirerek daha yüksek başarımlar elde etmeye çalışmışlardır (Jung vd., 2015).

Videla ve Kumar arkadaşları, 10 katmanlı CNN modeli ve Adam optimizasyon yöntemi tercih edilerek Cohn-Kanade (CK+) ve Japon Kadın Yüz İfadeleri (JAFFE) veri setleri üzerinde yüz ifadeleri tespiti üzerinde durulmuştur (Videla ve Kumar, 2020).

2022 yılında Kandhro ve arkadaşları, CK+ ve JAFFE veri setlerini kullanarak CNN modeli üzerinde hiperparametrelerin etkileri incelenmiştir. Adamax, Nadam ve Adam gibi optimizasyon yöntemleri test edilmiştir (Kandhro vd., 2022).

En önemli derin öğrenme algoritmalarından biri evrişimli sinir ağı (CNN) modelidir. Derin öğrenme modellerinin performans ve başarımları için

optimizasyon algoritması seçimi önemli bir parametredir. Yapılan çalışma kapsamında VGG19 ve MobileNet modelleri SGD optimizasyon algoritması, Adadelta optimizasyon algoritması ve Adagrad optimizasyon algoritmaları kullanılarak birbirleriyle detaylı olarak karşılaştırılmış ve başarımları incelenmiştir.

Makalenin bir sonraki kısmı olan ikinci kısımda çalışmada kullanılan veri seti, modeller ve optimizasyon yöntemlerinden bahsedilmektedir. Daha sonra üçüncü kısım ise kullanılan parametreler, elde edilen grafikler ve değerlendirme tabloları yer almaktadır. Son olarak dördüncü kısımda sonuçların değerlendirilmesi verilmektedir.

## 2. YÖNTEM

Bu çalışmada, Ohio Eyalet Üniversitesine ait Compound Emotion (CE) veri seti kullanılmaktadır. Yaşları 23 olan 130'u kadın 100'ü erkek 230 denek kişiden oluşmaktadır. Kişiler beş farklı kökenden oluşmaktadır. Yüz hatlarının belirginliği için sakal ile gözlük bulunmamaktadır. Ayrıca kaşlarının belirginliği belli olması için alınlarını açmaları istenmiştir. Bu veri seti temel ve karmaşık duyguları kapsamaktadır. İnsanlar günlük hayatlarında birçok duyguyu tanısalar da çalışmalar genellikle 7 temel duyguyu esas almıştır. Bu çalışmamızda veri setinde bulunan temel duygular olan mutlu, üzgün, öfkeli, şaşırılmış, doğal, iğrenmiş ve korkulu yüz ifadeleri kullanılmıştır. Toplam 1610 görüntü bulunmaktadır (Du vd., 2014). Veri seti %70 eğitim ve %30 test olarak ayrılmıştır. Veri setinden örnek görüntüler Şekil 1'de gösterilmektedir (Du vd., 2014).



**Şekil 1.** Yüz ifadelerinden (a) doğal, (b) mutlu, (c) üzgün, (d) öfkeli, (e) şaşırılmış, (f) iğrenmiş, (g) korkulu için veri setinden örnek görüntüler

Veri seti boyutu derin öğrenme modelleri için önemli bir parametredir. Probleme uygun veri toplamak zor bir işlemdir. Veri seti birleştirme ve veri çoğaltma işlemleri bu sorun için çözüm olabilmektedir. Veri seti birleştirme işleminde görüntülerde uyumsuzluk göstermesi sorun olabilmektedir. Bu sebeple modellerin başarımlarını arttırmak ve aşırı öğrenmenin önüne geçmek için eğitim veri setine veri arttırma işlemi uygulanmıştır (Alimovski ve Erdemir, 2021). Bu işlem sadece veri setinde eğitim için ayrılan kısma uygulanmaktadır. Mevcut verilerden yeni görüntüler üretilmektedir. Uygulanan veri arttırma yöntemi, Bir derin öğrenme

kütüphanesi olan Tensorflow'un açık kaynak olarak bulunan veri arttırma kodundan geliştirildi (Tensorflow Core, 2020). Görüntü üzerinde sağa ve sola belli açılarda döndürme, yakınlaştırma ve ölçekleme işlemleri yapıldı. Bu işlemler sonucunda toplam eğitim setindeki görüntü sayısı 5478 olmuştur. Test veri setinde bir değişiklik yapılmamıştır. Test veri setinde altı duygu için 69 ve üzgün sınıfında 70 veri ile 483 görüntü bulunmaktadır.

Bu çalışmada, önceden eğitilmiş Evrişimli Sinir Ağları (CNN) modelleri olan VGG19 ve MobileNet modelleri tercih edilmiştir. VGG19 modeli, çok katmanlı derin bir sinir ağıdır. VGG19 modelinde maksimum havuzlama katmanları bulunmaktadır. 4096 nörondan oluşan iki tam bağlantı katmanı içermektedir. 19 katman derinliğine sahiptir (Zheng vd., 2018). MobileNet modeli, mobil uygulamalarda kullanılmak için TensorFlow'un ilk mobil derin öğrenme modelidir. MobileNet katmanları derinlemesine ayrılabilir evrişimlerden oluşur. Parametre sayısını önemli derece azaltmaktadır (Pujara, 2020). Optimizasyon yöntemleri, makine öğrenmesi ve derin öğrenme yöntemlerinde hata oranını en aza indirmek için önemlidir. Bu çalışmada literatürden farklı olarak üç optimizasyon yöntemi seçilmiştir. Bunlar Stokastik gradyan inişi (SGD), Adadelta ve Adagrad yöntemleridir (Seyyarer vd., 2020; Defazio, 2020).

### 3. BULGULAR

Çalışma kapsamında temel 7 duygu olan mutlu (happy), üzgün (sad), öfkeli (angry), şaşırılmış (surprised), iğrenmiş (disgusted), doğal (neutral) ve korkulu (fearful) yüz ifadelerinin belirlenmesi için VGG19 ve MobileNet modelleri ile birlikte SGD, Adadelta ve Adagrad optimizasyon yöntemleri kullanılmaktadır. Modellere etki eden hiperparametreler test edilerek seçilmiştir. Bunlardan dönem sayısı(epoch) 10, parti boyutu (batch size) 32, öğrenme oranı (learning rate) 0.001 ve girdi boyutu (224,224,3) belirlenip her model için sabit değerlerdir. Optimizasyon algoritmalarının ve modellerin başarımlarının doğru kıyaslanması için başarımlar (accuracy) grafiği, hata (loss) grafiği, karmaşıklık (confusion) matrisi ve sınıfların performans metrikleri sunulmaktadır. Test verisi 484 görüntüden oluşmaktadır. Sonuçlar bu görüntüler üzerinden elde edilmektedir.


#### 3.1. VGG19 Modeli ile Elde Edilen Bulgular

VGG19 CNN modeli için üç farklı optimizasyon yöntemi ayrı ayrı incelenmekte ve birbirleri arasında kıyaslanmaktadır.

##### 3.1.1. SGD Optimizasyon Yöntemi


Stokastik Gradyan İnişi (SGD) optimizasyon yöntemi ile doğrulama ve eğitim verileri için başarımlar

(accuracy) ve hata (loss) grafikleri şekil 2'de sunulmaktadır.



**Şekil 2.** Vgg19 modeli ile kullanılan SGD optimizasyon algoritmasının a) başarımlar grafiği b) hata grafiği

Şekil 2'de grafikler paralel ilerlemiş olsa da değerler arasında farklar bulunmaktadır.



**Şekil 3.** Vgg19 modeli ile kullanılan SGD optimizasyon algoritmasının karmaşıklık matrisi

Şekil 3 ile test verileri için 7 duygu sınıfının doğru tahmin ettiği değerler görülmektedir. En çok doğru tahmini mutlu duygu sınıfında yapmıştır. En düşük tahmin ise üzgün duygu sınıfında olmuştur.

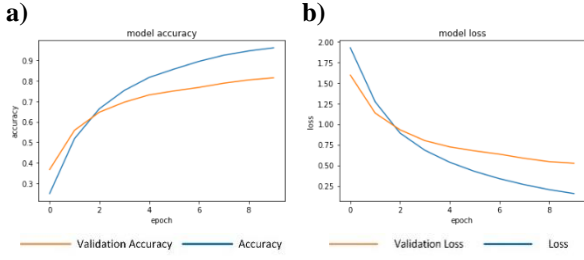
**Tablo 1.** Vgg19 model ile SGD optimizasyon algoritması için performans sonuçları

	PRECISION	RECALL	F1-SCORE	SUPPORT
ANGRY	0.63	0.83	0.72	69
DISGUSTED	0.90	0.67	0.77	69
FEARFUL	0.68	0.77	0.72	69
HAPPY	0.91	0.91	0.91	69
NEUTRAL	0.81	0.78	0.79	69
SAD	0.65	0.60	0.62	70
SURPRISED	0.89	0.83	0.86	69
ACCURACY			0.77	484
MACRO AVG	0.78	0.77	0.77	484
WEIGHTED	0.78	0.77	0.77	484
AVG				

Tablo 1'de test başarımlar (accuracy) değerinin %77 olduğu görülmektedir.


##### 3.1.2. Adadelta Optimizasyon Yöntemi

Adadelta optimizasyon algoritması için doğrulama ve eğitim verileri için başarımlar ve hata grafikleri şekil 4 ile sunulmaktadır.



**Şekil 4.** Vgg19 modeli ile kullanılan Adadelta optimizasyon algoritmasının a) başarım grafiği b) hata grafiği

Şekil 4'te başarım ve doğrulama değerleri benzer seyretmektedir.



**Şekil 5.** Vgg19 modeli ile kullanılan Adadelta optimizasyon algoritmasının karmaşıklık matrisi

Şekil 5'te test verileri için 7 duygu sınıfının doğru tahmin ettiği değerler görülmektedir. En çok doğru tahmini mutlu duygu sınıfında yapmıştır. En düşük tahmin ise doğal duygu sınıfında olmuştur.

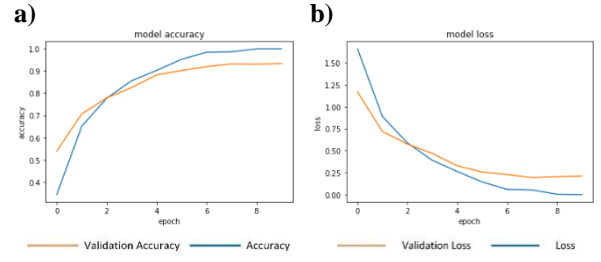
**Tablo 2.** Vgg19 model ile Adadelta optimizasyon algoritması için performans sonuçları

	PRECISION	RECALL	F1-SCORE	SUPPORT
ANGRY	0.67	0.72	0.69	69
DISGUSTED	0.71	0.78	0.74	69
FEARFUL	0.63	0.83	0.72	69
HAPPY	0.90	0.93	0.91	69
NEUTRAL	0.84	0.38	0.52	69
SAD	0.51	0.57	0.54	70
SURPRISED	0.92	0.84	0.88	69
ACCURACY			0.72	484
MACRO AVG	0.74	0.72	0.72	484
WEIGHTED	0.74	0.72	0.72	484
AVG				

Tablo 2'de test başarım (accuracy) değerinin %72 olduğu görülmektedir.


### 3.1.3. Adagrad Optimizasyon Yöntemi

Adagrad optimizasyon algoritması için doğrulama ve eğitim verileri için başarım ve hata grafikleri şekil 6 ile sunulmaktadır.



**Şekil 6.** Vgg19 modeli ile kullanılan Adagrad optimizasyon algoritmasının a) başarım grafiği b) hata grafiği

Şekil 6'da başarım ve doğrulama verileri uyumlu ve paralel seyretmektedir.



**Şekil 7.** Vgg19 modeli ile kullanılan Adagrad optimizasyon algoritmasının karmaşıklık matrisi

Şekil 7 ile test verileri için 7 duygu sınıfının doğru tahmin ettiği değerler görülmektedir. Genel olarak üzgün duygu sınıfı dışında iyi sonuçlar vermiştir.

**Tablo 3.** Vgg19 model ile Adagrad optimizasyon algoritması için performans sonuçları

	PRECISION	RECALL	F1-SCORE	SUPPORT
ANGRY	0.74	0.80	0.77	69
DISGUSTED	0.86	0.87	0.86	69
FEARFUL	0.83	0.97	0.89	69
HAPPY	0.97	0.96	0.96	69
NEUTRAL	1.00	0.80	0.89	69
SAD	0.73	0.73	0.73	70
SURPRISED	0.97	0.93	0.95	69
ACCURACY			0.86	484
MACRO AVG	0.87	0.86	0.86	484
WEIGHTED	0.87	0.86	0.86	484
AVG				


Tablo 3'te test başarım (accuracy) değerinin %86 olduğu görülmektedir.

## 3.2. MobileNet Modeli ile Elde Edilen Bulgular

MobileNet modeli için üç farklı optimizasyon yöntemi ayrı ayrı incelenmekte ve birbiri arasında kıyaslanmaktadır.

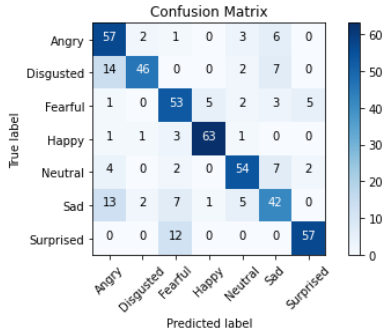
### 3.2.1. SGD Optimizasyon Yöntemi

SGD optimizasyon algoritması için doğrulama ve eğitim verileri için başarım ve hata grafikleri şekil 8 ile sunulmaktadır.



**Şekil 8.** MobileNet modeli ile kullanılan SGD optimizasyon algoritmasının a) başarıım grafiği b) hata grafiği

Şekil 8'te eğitim ve doğrulama verileri arasında başarıım farkları görülmektedir.



**Şekil 9.** MobileNet modeli ile kullanılan SGD optimizasyon algoritmasının karmaşıklık matrisi

Şekil 9'da test verileri için 7 duygu sınıfının doğru tahmin ettiği değerler görülmektedir. 69 test verisinden 63'ünü doğru tahmin ettiği en iyi sonuç mutlu yüz ifadesidir.


**Tablo 4.** MobileNet model ile SGD optimizasyon algoritması için performans sonuçları

	PRECISION	RECALL	F1-SCORE	SUPPORT
ANGRY	0.63	0.83	0.72	69
DISGUSTED	0.90	0.67	0.77	69
FEARFUL	0.68	0.77	0.72	69
HAPPY	0.91	0.91	0.91	69
NEUTRAL	0.81	0.78	0.79	69
SAD	0.65	0.60	0.62	70
SURPRISED	0.89	0.83	0.86	69
ACCURACY			0.77	484
MACRO AVG	0.78	0.77	0.77	484
WEIGHTED AVG	0.78	0.77	0.77	484

Tablo 4 ile test başarıım (accuracy) değerinin %77 olduğu görülmektedir.

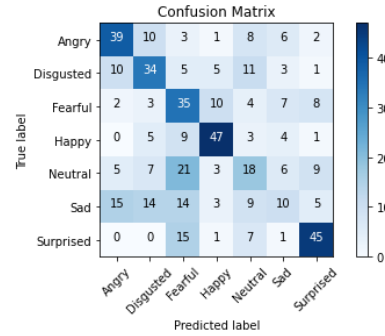
### 3.2.2. Adadelta Optimizasyon Yöntemi

Adadelta optimizasyon algoritması için doğrulama ve eğitim verileri için başarıım ve hata grafikleri şekil 10 ile sunulmaktadır.



**Şekil 10.** MobileNet modeli ile kullanılan Adadelta optimizasyon algoritmasının a) başarıım grafiği b) hata grafiği

Şekil 10'da başarıım ve doğrulama verileri paralel ilerlemiştir. Ancak başarıım düşük bulunmaktadır. Hata değeri ise yüksek bulunmaktadır.



**Şekil 11.** MobileNet modeli ile kullanılan Adadelta optimizasyon algoritmasının karmaşıklık matrisi

Şekil 11 ile gösterilen matrister test verileri için 7 duygu sınıfının doğru tahmin ettiği değerler görülmektedir. 69 test verisinden 47'sini doğru tahmin ettiği en iyi sonuç mutlu yüz ifadesidir. 45 doğru tahmin ile şaşırmiş duygu sınıfı gelmektedir.


**Tablo 5.** MobileNet model ile Adadelta optimizasyon algoritması için performans sonuçları

	PRECISION	RECALL	F1-SCORE	SUPPORT
ANGRY	0.55	0.57	0.56	69
DISGUSTED	0.47	0.49	0.48	69
FEARFUL	0.34	0.51	0.41	69
HAPPY	0.67	0.68	0.68	69
NEUTRAL	0.30	0.26	0.28	69
SAD	0.27	0.14	0.19	70
SURPRISED	0.63	0.65	0.64	69
ACCURACY			0.47	484
MACRO AVG	0.46	0.47	0.46	484
WEIGHTED AVG	0.46	0.47	0.46	484

Tablo 5 ile test başarıım (accuracy) değerinin %47 olduğu görülmektedir.


### 3.2.3. Adagrad Optimizasyon Yöntemi

Adagrad optimizasyon algoritması için doğrulama ve eğitim verileri için başarıım ve hata grafikleri Şekil 12 ile sunulmaktadır.



**Şekil 12.** MobileNet modeli ile kullanılan Adagrad optimizasyon algoritmasının a) başarımlar grafiği b) hata grafiği

Şekil 12’de eğitim ve doğrulama verilerinde başarımlar değerleri arasında fark görülmektedir.



**Şekil 13.** MobileNet modeli ile kullanılan Adagrad optimizasyon algoritmasının karmaşıklık matrisi

Şekil 13 ile gösterilen matriste test verileri için 7 duygu sınıfının doğru tahmin ettiği değerler görülmektedir. 69 test verisinden 65’ini doğru tahmin ettiği en iyi sonucu mutlu yüz ifadesidir.

**Tablo 6.** MobileNet model ile Adagrad optimizasyon algoritması için performans sonuçları

	PRECISION	RECALL	F1-SCORE	SUPPORT
ANGRY	0.64	0.78	0.70	69
DISGUSTED	0.74	0.71	0.73	69
FEARFUL	0.77	0.80	0.79	69
HAPPY	0.97	0.94	0.96	69
NEUTRAL	0.88	0.72	0.79	69
SAD	0.65	0.63	0.64	70
SURPRISED	0.87	0.88	0.88	69
ACCURACY			0.78	484
MACRO AVG	0.79	0.78	0.78	484
WEIGHTED AVG	0.79	0.78	0.78	484

Tablo 6 ile test başarımlar (accuracy) değerinin %78 olduğu görülmektedir.

#### 4. SONUÇLAR

Yapılan çalışmada, yüz ifadelerinden oluşan görüntü veri seti kullanarak VGG19 ve MobileNet modellerine uygulanan SGD, Adadelta ve Adagrad optimizasyon yöntemlerinin kıyaslanması yapılmıştır. Bulgular sonucunda VGG19 modelinin en iyi sonucu %86 oranla Adagrad optimizasyon algoritması ile elde edilmiştir. En düşük sonuçlar ise %72 oranla Adadelta optimizasyon algoritması tarafından elde edilmiştir. Tüm optimizasyon

algoritmaları için en iyi sonucu mutlu duygu sınıfında elde etmiştir. MobileNet modeli en iyi sonuçları %78 ile Adagrad ve %77 ile SGD optimizasyon algoritmalarında elde etmiştir. MobileNet ile kullanılan Adadelta optimizasyon yöntemi %47 oranla en düşük sonuç olmuştur.

Tüm sonuçlar değerlendirildiğinde iki model için Adagrad optimizasyon algoritması başarılı sonuç verirken en düşük değerler Adadelta optimizasyon algoritması ile elde edilmektedir. Tüm modellerde en iyi sonucu ve en çok doğru tahmini mutlu duygu sınıfı ile elde edilmektedir

#### KAYNAKÇA

- Alimovski, E. ve Erdemir, G. (2021). Veri artırma tekniklerinin derin öğrenmeye dayalı yüz tanıma sisteminde etkisi. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1), 76-80.
- Chen, M., Zhang, L., & Allebach, J.P. (2015). Learning deep features for image emotion classification. *2015 IEEE International Conference on Image Processing (ICIP)*, 4491-4495.
- Defazio, A. (2020). Optimizasyon yöntemleri 1. 25 Mayıs tarihinde <https://atcold.github.io/pytorch-Deep-Learning/tr/week05/05-1/> adresinden erişildi.
- Du, S., Tao, Y. & Martinez, A. M. (2014). Compound facial expressions of emotion. *Proceedings of the national academy of sciences*, 111(15), E1454-E1462.
- Jung, H., Lee, S., Yim, J., Park, S., & Kim, J. (2015) Joint Fine-Tuning in Deep Neural Networks for Facial Expression Recognition. *2015 IEEE International Conference on Computer Vision (ICCV)*, 2983-2991. doi: 10.1109/ICCV.2015.341.
- Kandhro, I. A., Uddin, M., Hussain, S., Chaudhery, T. J., Shorfuzzaman, M., Meshref, H., ... & Khalaf, O. I. (2022). Impact of Activation, Optimization, and Regularization Methods on the Facial Expression Model Using CNN. *Computational Intelligence and Neuroscience*, 2022.
- Ko, B. (2018). A Brief Review of Facial Emotion Recognition Based on Visual Information. *Sensors*, 18(2). doi: 10.3390/s18020401.
- Li, J., Jin, K., Zhou, D., Kubota, N., & Ju, Z. (2020). Attention mechanism-based CNN for facial expression recognition. *Neurocomputing*, 411,340-350. <https://doi.org/10.1016/j.neucom.2020.06.014>.
- Littlewort, G., Bartlett, M. S., Fasel, M. S., Chenu, J., Kanda, T., Ishiguro, H. & Movellan, J. R. (2003). Towards social robots: Automatic evaluation of human-robot interaction by face detection and expression classification, 2003.

- Özdemir, D., ve Karaman, S. (2017). Investigating interactions between students with mild mental retardation and humanoid robot in terms of feedback types. *Egitim ve Bilim*, 42(191),109-138.
- Pujara, A. (2020). Image classification with mobilenet. 27 Mayıs tarihinde <https://medium.com/analytics-vidhya/image-classification-with-mobilenet-cc6fbb2cd470> adresinden erişildi.
- Seyyarer, E., Ayata, F., Uçkan, T. & Karıcı, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Computer Science*, 5(2), 90-98.
- TensorFlow Core (Kasım, 2020) [https://www.tensorflow.org/api\\_docs/python/tf/keras/preprocessing/image/ImageDataGenerator](https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator).
- Videla, L. S., & Kumar, P. A. (2020, July). Facial expression classification using vanilla convolution neural network. In *2020 7th international conference on smart structures and systems (ICSSS)* (pp. 1-5). IEEE.
- Voulodimos, A. ve Doulamis, N. (2018). Anastasios Doulamis, Eftychios Protopapadakis. Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*. <https://doi.org/10.1155/2018/7068349>
- Yolcu, G., Oztel, I., Kazan, S., Oz, C., Palaniappan, K., Lever, T. E., & Bunyak, F. (2017). Deep learning-based facial expression recognition for monitoring neurological disorders. *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 1652-1657.
- Zhang Y. & Hua, C. (2015). Driver fatigue recognition based on facial expression analysis using local binary patterns. *Opt. - Int. J. Light Electron Opt.*, 126(23), 4501-4505.
- Zheng, Y., Yang, C., & Merkulov, A. (2018). Breast cancer screening using convolutional neural network and follow-up digital mammography. In *Computational Imaging III* (Vol. 10669, p. 1066905). SPIE.