



## Performance comparison of AlexNet and MobileNetV2 architectures in flower classification

Gözde Sena Karabay<sup>1\*</sup>, Mehmet Çavaş<sup>1</sup>, Engin Avcı<sup>2</sup>

<sup>1</sup>Department of Mechatronics Engineering, Faculty of Technology, Firat University, 23119, Elazığ, Türkiye

<sup>2</sup>Department of Software Engineering, Faculty of Technology, Firat University, 23119, Elazığ, Türkiye

### Highlights:

- Using the Oxford-17 dataset.
- Performing feature extraction and feature selection.
- Comparison of the results obtained from AlexNet-MobileNetV2 architectures.

### Keywords:

- Deep Learning
- Flower Classification
- AlexNet
- MobileNetV2

### Article Info:

Research Article

Received: 02.04.2024

Accepted: 26.07.2024

### DOI:

10.17341/gazimmfd.1463663

### Correspondence:

Author: Gözde Sena Karabay

e-mail:

senakarabay@hotmail.com

phone: +90 424 237 7602

### Graphical/Tabular Abstract

Classifying flower species plays a critical role in the protection and sustainability of the natural world. People working in this field need accurate identification of flowers. Because some flower types are very similar to each other and it becomes very difficult to distinguish them. Oxford-17 data set was used in our study. AlexNet and MobileNetV2 architectures were preferred for feature extraction. Neighborhood component analysis (NCA) algorithm was used for feature selection and support vector machine (SVM) was used for classification. The flow chart of the study is given in Figure A.

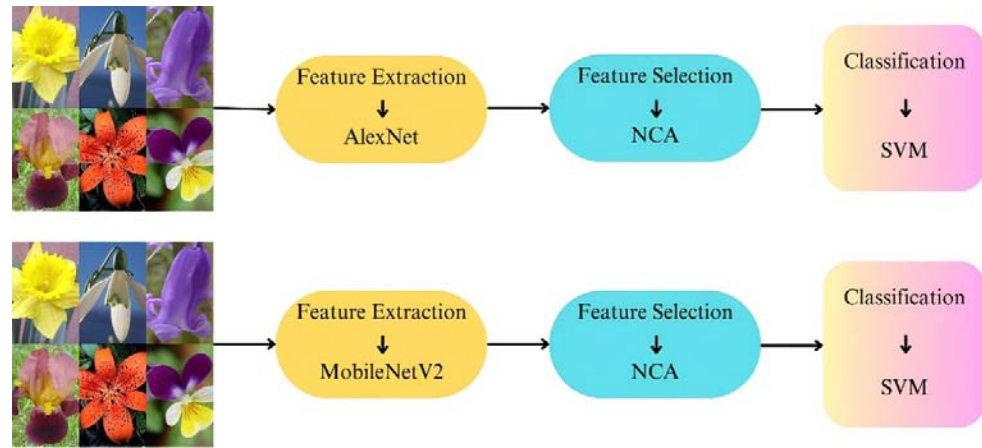


Figure A. Flow Chart of the Study

### Purpose:

The aim of this study is to evaluate the effectiveness of deep learning methods using artificial intelligence and image processing techniques for accurate identification and classification of flower species.

### Theory and Methods:

Oxford-17 data set was used in the study. This dataset contains 1360 images of 17 different flower species. Convolutional neural networks (CNN) were used for the analysis of the images. Feature extraction was performed using AlexNet and MobileNetV2 architectures and classification process was performed. Model performance was evaluated by 10-k cross validation method.

### Results:

The highest success rate in the results obtained with the AlexNet architecture was determined as 93.1%. In the classification made using the MobileNetV2 architecture, the highest success rate was found to be 93.9%. These results show that deep learning architectures are effective in recognizing and classifying flower species.

### Conclusion:

The results of the study show that deep learning methods are successful in recognizing and classifying flower species. It is anticipated that better results can be achieved by using more advanced deep learning architectures in future studies. It is emphasized that this study is an effective method in terms of cost and time for recognizing and classifying flower species.



## Çiçek sınıflandırmada AlexNet ve MobileNetV2 mimarilerinin performans karşılaştırması

Gözde Sena Karabay<sup>1\*</sup>, Mehmet Çavaş<sup>1</sup>, Engin Avcı<sup>2</sup>

<sup>1</sup>Firat Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, 23119, Elazığ, Türkiye

<sup>2</sup>Firat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, 23119, Elazığ, Türkiye

### Ö N E Ç İ K A N L A R

- Oxford-17 veri setinin kullanılması
- Özellik çıkarma ve özellik seçiminin gerçekleştirilmesi
- AlexNet-MobileNetV2 mimarilerinden elde edilen sonuçların karşılaştırılması

### Makale Bilgileri

Araştırma Makalesi

Geliş: 02.04.2024

Kabul: 26.07.2024

### DOI:

10.17341/gazimmfd.1463663

### Anahtar Kelimeler:

Derin öğrenme,  
çiçek sınıflandırma,  
AlexNet,  
MobileNetV2

### ÖZ

Çeşitliliğin fazla olması nedeniyle çiçek türlerini sınıflandırma problemi zorlu ve maliyetli bir süreçtir. Bu alana ilgili çalışmalar yapan araştırmacıların işlerini kolaylaştırmak için bilgisayarlı görü ve derin öğrenme uygulamaları büyük avantaj sağlamaktadır. Derin öğrenme yöntemleri yeni algoritmaların geliştirilmesiyle büyük miktarda veri üzerinde hızlı ve doğru analiz yapabilmeye yüksek başarıya ulaşabilmektedir. Birçok alanda kullanılan bu yöntemler, çiçek türlerini sınıflandırmada da başarılı sonuçlar vermektedir. Yapılan bu çalışmada Oxford-17 veri seti kullanılmıştır. Veri setinde 17 sınıfa ait 1360 adet çiçek görüntüsü yer almaktadır. Evrişimsel sinir ağları kullanılarak oluşturulan bu çalışmada derin öğrenme mimarilerinden AlexNet ve MobileNetV2 mimarileri kullanılmıştır. AlexNet mimarisi kullanılarak 4096 adet özellik çıkartılmıştır. Her bir görüntüden 4096 adet özellik çıkartılarak 1360x4096 boyutunda özellik matrisi elde edilmiştir. Komşuluk Bileşen Analizi (KBA) algoritması ile ilk 500 özellik seçilmiş olup, Destek Vektör Makinesi (DVM) yöntemiyle sınıflandırma işlemi gerçekleştirilmiştir. Ardından MobileNetV2 mimarisi kullanılarak 1000 adet özellik çıkartılmış olup 1360x1000 boyutunda özellik matrisi elde edilmiştir. Aynı işlemler tekrarlanarak KBA algoritması kullanılarak ilk 500 özellik seçilip DVM ile sınıflandırma işlemi gerçekleştirilmiştir. İki mimarinin performans karşılaştırmaları yapılarak AlexNet mimarisinden %93,1, MobileNetV2 mimarisinden %93,9 başarı oranı elde edilmiştir. MobileNetV2 mimarisinden elde edilen sonucun daha etkili olduğu görülmüştür.

## Performance comparison of AlexNet and MobileNetV2 architectures in flower classification

### H I G H L I G H T S

- Using the Oxford-17 dataset
- Performing feature extraction and feature selection
- Comparison of the results obtained from AlexNet-MobileNetV2 architectures

### Article Info

Research Article

Received: 02.04.2024

Accepted: 26.07.2024

### DOI:

10.17341/gazimmfd.1463663

### Keywords:

Deep learning,  
flower classification,  
AlexNet,  
MobileNetV2

### ABSTRACT

Due to the high diversity, the problem of classifying flower species is a difficult and costly process. Computer vision and deep learning applications provide great advantages to facilitate the work of researchers working in this field. With the development of new algorithms, deep learning methods can achieve high success in performing fast and accurate analysis on large amounts of data. These methods, which are used in many fields, also provide successful results in classifying flower species. Oxford-17 data set was used in this study. The data set includes 1360 flower images belonging to 17 classes. In this study, which was created using convolutional neural networks, AlexNet and MobileNetV2 architectures, which are deep learning architectures, were used. 4096 features were extracted using AlexNet architecture. By extracting 4096 features from each image, a feature matrix of 1360x4096 size was obtained. The first 500 features were selected with the Neighborhood Component Analysis (NCA) algorithm and the classification process was carried out with the Support Vector Machine (SVM) method. Then, 1000 features were extracted using the MobileNetV2 architecture and a feature matrix of 1360x1000 size was obtained. By repeating the same processes, the first 500 features were selected using the NCA algorithm and classification was performed with SVM. By comparing the performance of the two architectures, a success rate of 93.1% was obtained from the AlexNet architecture and 93.9% from the MobileNetV2 architecture. It has been observed that the result obtained from MobileNetV2 architecture is more effective.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*senakarabay@hotmail.com, mcavas@firat.edu.tr, enginavci@firat.edu.tr /  
Tel: +90 424 237 7602

## 1. Giriş (Introduction)

Günümüzde yapay zekâ ve görüntü işleme alanlarındaki gelişmeler, doğal yaşamın korunması ve biyoçeşitlilik alanında yapılan çalışmalar için yeni fırsatlar sunmaktadır. Çeşitli çiçek türlerinin bulunmasından dolayı çiçeklerin doğru bir şekilde tanımlanması ve sınıflandırılması maliyet ve zaman açısından zorlu bir süreçtir. Bilgisayarla görü ve derin öğrenme teknikleri bu anlamda araştırmacılara kolaylık sunmaktadır. Kısa sürede yüksek başarılar elde edilerek çiçek türlerinin doğru bir şekilde tanımlanması ve sınıflandırılması gerçekleştirilebilmektedir. Bu çalışmada derin öğrenme yöntemi kullanılarak 17 türe ait çiçek görüntüsü sınıflandırılmıştır.

Yapay zekâ günümüzde popüler hale gelerek birçok alanda kullanılmakta ve insan yaşamını kolaylaştırmaktadır. Makine öğrenmesi, yapay zekânın alt dalıdır. Derin öğrenme ise makine öğrenmesinin alt dalıdır. Makine öğrenmesinin aksine derin öğrenme, özellik çıkarımını dışarıdan yapmaya ihtiyaç duymadan kendisi yapabilmektedir [1]. Derin öğrenme, büyük miktarda veriyi işleme kapasitesine sahip olması ve öğrenme sürecindeki adaptif yeteneği sayesinde ses tanıma [2-4], görsel tanıma [5, 6] ve doğal dil işleme [7, 8] gibi pek çok alanı etkilemektedir ve bu alanlarda birçok çalışmalar yapılmıştır. Derin katmanlar kullanılarak bir problemin çözümü için yüksek başarılar elde edilebilmektedir.

Giriş'in yapmış olduğu çalışmada [9], Oxford-17 veri seti kullanılmış olup veri setinde 17 sınıf, her sınıfta 80 adet görüntü olmak üzere toplamda 1360 adet görüntü yer almaktadır. Çalışmada Inception V3 modeli kullanılarak özellik çıkarımı yapılmıştır ve %86,4 başarı tespit edilmiştir. Lin ve arkadaşının yapmış olduğu çalışmada [10], Oxford-17 ve Oxford-102 veri setleri kullanılmıştır. Oxford-17 veri setinde toplamda 1360 adet görüntü yer almaktadır. Oxford-102 veri setinde ise 102 sınıf bulunmakta ve toplamda 8189 adet görüntü yer almaktadır. Çalışmada VGG-16, VGG-19, LeNet-5 ve AlexNet mimarileri test edilmiştir. Oxford-17 veri setinde VGG-16 mimarisıyla %79,56, VGG-19 mimarisıyla %80,26, LeNet-5 mimarisıyla %72,45, AlexNet mimarisıyla %78,32 başarı değeri tespit edilmiştir. Oxford-102 veri setinde ise VGG-16 mimarisıyla %81,26, VGG-19 mimarisıyla %80,82, LeNet-5 mimarisıyla %73,46, AlexNet mimarisıyla %78,92 başarı değeri tespit edilmiştir. Pandey ve arkadaşlarının yapmış olduğu çalışmada [11], Oxford-17 veri seti kullanılmıştır. Çalışmada RegNetY 16GF modeli tercih edilmiş olup en yüksek başarı değeri %93,4 olarak tespit edilmiştir. Giriş ve arkadaşının yapmış olduğu çalışmada [12], Oxford-17 ve Caltech-101 veri seti kullanılmıştır. Çalışmada Oxford-17 veri setinde bulunan 1360 adet görüntünün tamamı kullanılmıştır. Caltech-101 veri setinde 101 sınıf bulunmakta ve yaklaşık 9000 görüntü yer almaktadır. Çalışmada Caltech-101 veri setinin 20 sınıfı kullanılmış olup her sınıfta 70 görüntü olmak üzere 1400 adet görüntü kullanılmıştır. Inception V3 modeliyle özellik çıkarımı yapılan çalışmada Oxford-17 veri setinde %92,27, Caltech-101 veri setinde ise %98 başarı değeri tespit edilmiştir. Tian ve arkadaşlarının yapmış olduğu çalışmada [13], Oxford-17 veri seti kullanılmıştır. Çalışmada değiştirilmiş Tiny DarkNet modeli oluşturulmuş olup %92 oranında başarı değeri tespit edilmiştir. Zhao ve arkadaşlarının yapmış olduğu çalışmada [14], Five Categories, Oxford-17 ve Self-dataset veri setleri kullanılmıştır. Five Categories veri setinde 5 adet tür bulunmakta ve toplamda 3670 adet çiçek görüntüsü yer almaktadır. Self-dataset veri setinde ise 6 adet tür bulunmakta ve toplamda 180 adet çiçek görüntüsü yer almaktadır. Çalışmada CCAN olarak kısaltılan bir renk sabitliği tabanlı yöntem kullanılmıştır. Five Categories veri setinden %86,12 başarı değeri elde edilmiştir. Oxford-17 veri setinden %90,44 başarı değeri elde edilirken, Self-dataset veri setinden %90,91 başarı değeri elde edilmiştir. Singprayoon ve arkadaşının yapmış olduğu çalışmada [15], Inception evrişimsel sinir ağlarında (ICNN) kullanılan 2-ICNN, 1F-

ICNN ve 1L-ICNN yardımcı ağlar model olarak tercih edilmiştir. Oxford-17 ve Oxford-102 veri setleri kullanılmıştır. 2-ICNN modelinde Oxford-17 veri setinden elde edilen başarı değeri %83,68 iken Oxford-102 veri setinden elde edilen başarı değeri %80,31'dir. 1F-ICNN modelinde Oxford-17 veri setinden elde edilen başarı değeri %84,63 iken Oxford-102 veri setinden elde edilen başarı değeri %80,12'dir. 1L-ICNN modelinde Oxford-17 veri setinden elde edilen başarı değeri %83,01 iken Oxford-102 veri setinden elde edilen başarı değeri %78,97'dir. Ran ve arkadaşlarının yapmış olduğu çalışmada [16], LeNet-5 mimarisi tercih edilmiş olup Oxford-17 ve Oxford-102 veri setleri kullanılmıştır. Oxford-17 veri setinden %93, Oxford-102 veri setinden ise %92,56 başarı değeri elde edilmiştir.

Birçok çiçek türü birbirine benzeyebilmektedir. Özellikle aynı aileden veya cinslerden olan çiçekler arasında ince farklılıklar bulunabilmektedir. Ayrıca çiçeklerin görünümü mevsimlere ve çevresel faktörlere bağlı olarak değişebilmektedir. Bunlar sınıflandırma yaparken karışıklığa sebep olmaktadır. Bu durumda bilgisayarlı görü ve yapay zekâ uygulamaları yardımcı olmaktadır. Özellik çıkarma ve özellik seçme işlemleri, anlamlı özelliklerin çıkartılarak daha doğru tahminlerde bulunulmasını ve daha hızlı sonuçlar elde edilebilmesini sağlamaktadır. AlexNet mimarisi [17], tarihsel bir dönüm noktası olup kullandığı katmanlar sayesinde modelin karmaşık özellikleri öğrenmesini sağlamaktadır. Aşırı uyuma (overfitting)'yı azaltmak için veri artırma yöntemini ve seyreltme (dropout) katmanını kullanmaktadır. Bu sayede modelin ezberleme yapmasının önüne geçilmekte ve daha sağlıklı, başarılı sonuçlar elde edilmektedir. MobileNetV2 mimarisi [18], mobil ve gömülü cihazlarda çalışmak üzere tasarlanmış bir mimaridir. Daha az parametre ile çalışarak hızlı ve verimli bir şekilde model eğitimi ve tahmini yapmaktadır. Böylece sınırlı kaynaklara sahip cihazlarda bile yüksek performans göstermesini sağlamaktadır. Kullandığı konvolüsyonlar sayesinde hesaplama maliyetini azaltmakta ve model boyutunu küçültmektedir. Bu, modeli daha hızlı ve hafif yapmaktadır. Her mimarinin kendine göre avantajları ve dezavantajları vardır. Literatürdeki diğer modellerle karşılaştırma yapılırken performans, hız, hesaplama maliyeti, model boyutu, bellek kullanımı gibi kriterler göz önünde bulundurulmuştur. MobileNetV2 mimarisi, özellikle mobil ve gömülü cihazlar için geliştirilmiş bir model olduğundan hızlı ve düşük maliyetli bir çözüm sunmaktadır. Bu da mimarinin uygulama alanlarını genişletmektedir. Ayrıca bu mimari, düşük parametre sayısına ve hafif bir yapıya sahiptir. Bu özellikler, modelin bellek kullanımını minimize etmekte ve daha düşük kaynaklarla çalışmasını sağlamaktadır. AlexNet mimarisi, derin öğrenmede önemli bir yere sahip olup görüntü tanıma ve sınıflandırma problemlerinde sıkça tercih edilmektedir. Bu mimari, büyük bir model olmasına rağmen seyreltme katmanı ile aşırı uymayı başarılı bir şekilde önlemektedir. Bu tür değerlendirmeler yapıldığında her mimarinin kendine has avantajı bulursa da AlexNet ve MobileNetV2 mimarileri ön plana çıkmaktadır. Bu nedenle bu iki mimari tercih edilmiştir. Yapay zekâ teknikleri, çok boyutlu ve karmaşık veri kümelerini işleyebilmektedir. Ayrıca ayrıntılı bir şekilde öğrenerek daha doğru tahminler yapmaktadır. Maliyet ve zaman açısından da bu alanda çalışmalarını yürüten araştırmacılara kolaylıklar sağlamaktadır. Bu çalışma, AlexNet ve MobileNetV2 mimarilerinin çiçek sınıflandırma problemine farklı yaklaşımlar sunarak her iki modelin faydalarını ortaya koymaktadır. Tüm bunlar göz önünde bulundurulduğunda çalışmanın, çiçek türlerini sınıflandırma problemine katkı sağlayacağı düşünülmektedir. Bu çalışmada evrişimsel sinir ağları (ESA) kullanılarak çiçek görüntüleri analiz edilmiştir. Çalışmada kullanılan veri seti ikinci bölümde, AlexNet, MobileNetV2 mimarileri ve sınıflandırma algoritmaları ile ilgili bilgiler ise üçüncü bölümde yer almaktadır. Çalışmaya ait bulgular ve tartışma dördüncü bölümde, sonuçlar ise beşinci bölümde yer almaktadır.

## 2. Veri Seti (Dataset)

Oxford-17 veri seti [19], 17 sınıftan oluşan ve her sınıfta 80 adet çiçek görüntüsü bulunan toplamda 1360 adet çiçek görüntüsüne sahip bir veri setidir. Veri setinde nergis, kardelen, müge çiçeği, mavi çan, çiğdem, iris, kaplan zambağı, lale, yılan başı, ayçiçeği, papatya, öksürük otu, karahindiba, çuha çiçeği, düğün çiçeği, rüzgâr çiçeği ve hercai menekşe türleri yer almaktadır. Şekil 1’de veri setinde bulunan çiçek görüntüleri verilmektedir.

## 3. Deneysel Metot (Experimental Method)

Çalışmada görüntüleri analiz edebilmek için evrimsel sinir ağları kullanılmıştır. Oxford-17 veri setinde yer alan her çiçek görüntüsünün boyutu aynı değildir. Görüntülerin sabit bir boyuta getirilmesi, modelin özellik çıkarımı yapmasını kolaylaştırmaktadır. Bu nedenle görüntülerin tümü 600x600 boyutuna eşitlenmiştir. Çok büyük boyutlu görüntüler, gereksiz yere yüksek hesaplama yükü ve bellek kullanımı gerektirirken, küçük boyutlu görüntüler ise yeterli detay içermeyebilir ve bu durum modelin performansını düşürebilmektedir. 600x600 boyutu, bu dengeyi sağlamak için ideal bir boyuttur. Çünkü yeterli detay ve bilgi içerirken, hesaplama yükünü de yönetilebilir seviyede tutmaktadır. Görüntüler üzerinden özellik çıkarımı yapabilmek için sırasıyla AlexNet ve MobileNetV2 mimarileri ayrı ayrı kullanılmıştır. Modelin başarımını ölçebilmek için 10-k çapraz doğrulama kullanılmıştır. Öncelikle AlexNet mimarisi ile 4096 adet özellik çıkartılarak modelin başarı oranı artırılmıştır. Böylelikle 1360x4096 boyutunda özellik matrisi elde edilmiştir. Bir özellik seçme algoritması olan KBA (Komşuluk Bileşen Analizi) ile ilk 500 özellik seçilmiş olup DVM (Destek Vektör Makinesi) ile sınıflandırma işlemi gerçekleştirilmiştir. Modellerin karşılaştırmasını yapabilmek için aynı işlemler MobileNetV2 mimarisi ile gerçekleştirilmiş olup 1000 adet özellik çıkartılarak 1360x1000 boyutunda özellik matrisi elde edilmiştir ve yine KBA ile ilk 500 özellik seçilmiş olup DVM ile sınıflandırma işlemi gerçekleştirilmiştir.

### 3.1. AlexNet Mimarisi (AlexNet Architecture)

AlexNet mimarisi derin öğrenmenin gelişmesine büyük katkılar sağlamıştır. Mimari sekiz katmandan oluşmaktadır. İlk beş katmanı

evrişim katmanıdır geriye kalan üç katman ise tam bağlantılı katmandır. Sınıflandırma için softmax sınıflandırıcısı kullanılmıştır. Ayrıca mimaride GPU kullanılmıştır ve aktivasyon fonksiyonu olarak ReLU tercih edilmiştir. Mimari 60 milyon parametreye sahiptir [17]. Şekil 2’de mimariye ait genel yapı verilmektedir.

### 3.2. MobileNetV2 Mimarisi (MobileNetV2 Architecture)


MobileNetV2 mimarisi mobil cihazlar için geliştirilen bir mimardır. Aynı zamanda bilgisayar ortamında da kullanılabilir. MobileNetV2 mimarisi MobileNet mimarisinin geliştirilmiş bir versiyonudur. Bu mimari darboğaz katmanlarının arasında kısayol bağlantılarının olduğu ters çevrilmiş artık blok yapısına dayanmaktadır [18]. Genel haliyle mimari, 32 filtrelili başlangıç tam evrişim katmanı ve ardından 19 darboğaz katmanından oluşmaktadır. Ayrıca mimaride taşınabilirlik için derinlemesine ayrılabilir evrişim yöntemi kullanılmaktadır [20]. Mimari, 1.7 milyon ile 6.9 milyon arasında parametre değerine sahiptir. Tablo 1’de modele ait katmanlar verilmektedir. Burada t genişletme faktörünü, c çıkış kanal sayısını, n tekrar etme sayısını, s ise adım kaydırma değerini temsil etmektedir. Bütün uzamsal evrişimler 3x3 boyutunda filtreler kullanılmaktadır [18]. Şekil 3’te MobileNetV2 mimarisine ait konvolüsyonel bloklar verilmektedir. İlk blok stride değeri 1 olan artık blok, ikinci blok ise küçültme işlemi için stride değeri 2 olan bloktur [21].

**Tablo 1.** MobileNetV2 mimarisinde kullanılan katmanlar (Layers used in MobileNetV2 architecture) [18]

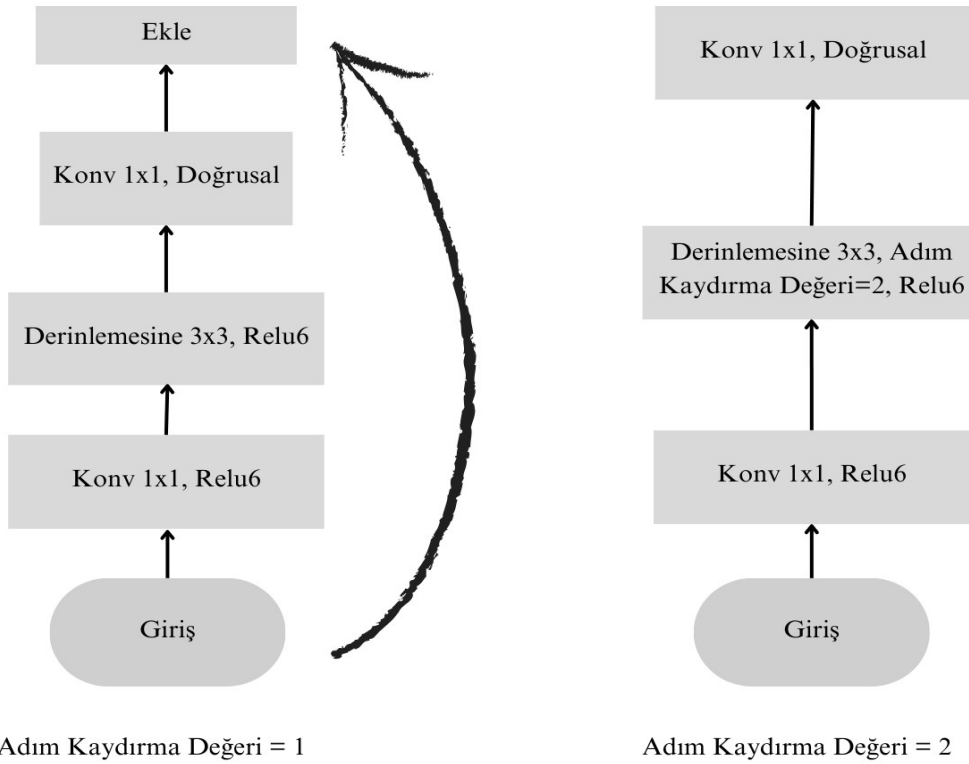
Giriş	Katman	t	c	n	s
224 <sup>2</sup> x 3	Konv2d	-	32	1	2
112 <sup>2</sup> x 32	Darboğaz	1	16	1	1
112 <sup>2</sup> x 16	Darboğaz	6	24	2	2
56 <sup>2</sup> x 24	Darboğaz	6	32	3	2
28 <sup>2</sup> x 32	Darboğaz	6	64	4	2
14 <sup>2</sup> x 64	Darboğaz	6	96	3	1
14 <sup>2</sup> x 96	Darboğaz	6	160	3	2
7 <sup>2</sup> x 160	Darboğaz	6	320	1	1
7 <sup>2</sup> x 320	Konv2d 1x1	-	1280	1	1
7 <sup>2</sup> x 1280	Ortalama Havuzlama 7x7	-	-	1	-
1 x 1 x 1280	Konv2d 1x1	-	k	-	-



**Şekil 1.** Oxford-17 veri seti (Oxford-17 dataset) [19]



Şekil 2. AlexNet Mimarisi (AlexNet architecture) [17] (AlexNet mimarisi (AlexNet architecture) [17])



Şekil 3. MobileNetV2 mimarisine ait konvolüsyonel bloklar (Convolutional blocks of MobileNetV2 architecture) [18]

### 3.3. Sınıflandırma Algoritmaları (Classification Algorithms)

Birden fazla sınıflandırma algoritması bulunmaktadır. Karar ağaçları, veri setindeki en iyi karar noktalarını ve ağaç yapılarını belirleyerek sınıflandırma yapmaktadır. Naif bayes, olasılık tabanlı bir yaklaşımla bir örneği maksimum a posteriori olasılığa göre sınıflandırmaktadır. DVM, veri setini ayıran en iyi marjinal hiper düzlemi bulmakta ve çekirdek fonksiyonları kullanarak performansını optimize etmektedir. K – en yakın komşuluk, veri noktalarını belirli bir k sayıda en yakın komşusuna göre sınıflandırmaktadır. Topluluk sınıflandırıcısı, birden

fazla sınıflandırıcının tahminlerine dayanarak daha doğru sonuçlar elde etmeyi amaçlamaktadır.

Bu yöntemler arasında bayes ortalaması, güçlendirme ve çantalama gibi teknikler bulunmaktadır [22]. Lineer diskriminant, tüm sınıfların doğrusal bir şekilde ayrılabilirliğini varsaymaktadır. Buna göre özellik uzayındaki birkaç tane hiper düzlemi temsil eden sınıfları ayırtmak için kullanılmaktadır [23]. Nöral ağlar, çoklu sınıflandırma için kullanılmaktadır. İyi bir tahmin doğruluğuna sahiptir. Tam bağlantılı katmanların boyutu ve sayısının artmasıyla model esnekliği de

artmaktadır. Çekirdek sınıflandırıcısı, verilerin doğrusal olmayan sınıflandırmasını gerçekleştirmek için kullanılmaktadır [24].

#### 4. Sonuçlar ve Tartışmalar (Results and Discussions)

Çalışmada, Intel(R) Core(TM) i5-4210U CPU @ 1.70GHz ~ 2.40 GHz işlemci, 8 GB Ram'e sahip Windows 10 işletim sistemi kullanılmış olup, sonuçlar MATLAB 2022a sürümünün classification learner toolbox'ı kullanılarak elde edilmiştir. Tablo 2'de AlexNet mimarisi kullanılarak elde edilen sonuçların sınıflandırıcılara göre tahmin değerleri ve başarı oranları, Tablo 3'te ise MobileNetV2 mimarisi kullanılarak elde edilen sonuçların sınıflandırıcılara göre tahmin değerleri ve başarı oranları verilmektedir.

**Tablo 2.** AlexNet mimarisi kullanılarak elde edilen sonuçların sınıflandırıcılara göre tahmin değerleri ve başarı oranları (Prediction values and success rates of the results obtained using AlexNet architecture according to classifiers)

Sınıflandırıcı	Doğru Tahmin	Yanlış Tahmin	Başarı Oranı (%)
Karar Ağaçları	888	472	65,3
Lineer Diskriminant	1198	162	88,1
Naif Bayes	1171	189	86,1
DVM	1266	94	93,1
K – En Yakın Komşuluk	1219	141	89,6
Topluluk	1242	118	91,3
Nöral Ağlar	1255	105	92,3
Çekirdek	1261	99	92,7

Tablo 2'ye göre AlexNet mimarisi kullanılarak elde edilen sonuçlarda en yüksek başarı değeri DVM (Destek Vektör Makinesi) sınıflandırıcısına aittir. Tablo 3'e göre MobileNetV2 mimarisi kullanılarak elde edilen sonuçlarda en yüksek başarı değerleri DVM ve Topluluk sınıflandırıcılara aittir.

**Tablo 3.** MobileNetV2 mimarisi kullanılarak elde edilen sonuçların sınıflandırıcılara göre tahmin değerleri ve başarı oranları (Prediction values and success rates of the results obtained using MobileNetV2 architecture according to classifiers)

Sınıflandırıcı	Doğru Tahmin	Yanlış Tahmin	Başarı Oranı (%)
Karar Ağaçları	756	604	55,6
Lineer Diskriminant	1246	114	91,6
Naif Bayes	1182	178	86,9
DVM	1277	83	93,9
K – En Yakın Komşuluk	1231	129	90,5
Topluluk	1277	83	93,9
Nöral Ağlar	1263	97	92,9
Çekirdek	1260	100	92,6

Karmaşıklık matrisinde yer alan DP, doğru pozitif değeri, DN ise doğru negatif değeri temsil etmektedir. YP, yanlış pozitif değeri, YN ise yanlış negatif değeri ifade etmektedir [25]. Bu değerler kullanılarak MCC, duyarlılık, özgüllük, kesinlik ve F1 skor metrikleri hesaplanmaktadır. Bu metriklere ait denklemler [26, 27] denklem Eş. 1-Eş. 5'te verilmektedir.

$$MCC = \frac{(DP+DN)-(YP+YN)}{\sqrt{(DP+YP)*(DP+YN)*(DN+YP)*(DN+YN)}} \quad (1)$$

$$Duyarlılık = \frac{DP}{DP+YP} \quad (2)$$

$$Özgüllük = \frac{DN}{DN+YP} \quad (3)$$

$$Kesinlik = \frac{DP}{DP+YP} \quad (4)$$

$$F1 \text{ skor} = \frac{2 * Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (5)$$

AlexNet ve MobileNetV2 mimarileriyle elde edilen sonuçlarda sınıflandırıcılara ait performans sonuçları ortalama değerleri alınarak Tablo 4 ve Tablo 5'te verilmektedir.

**Tablo 4.** AlexNet mimarisi kullanılarak elde edilen sonuçlarda sınıflandırıcılara ait ortalama performans sonuçları (Average performance results of classifiers in the results obtained using AlexNet architecture)

Sınıflandırıcı	MCC	Duyarlılık	Özgüllük	Kesinlik	F1-Skor
Karar Ağaçları	0,634	0,652	0,977	0,662	0,655
Lineer Diskriminant	0,911	0,915	0,936	0,919	0,916
Naif Bayes	0,862	0,868	0,991	0,874	0,869
DVM	0,927	0,930	0,995	0,933	0,931
K- En Yakın Komşuluk	0,893	0,896	0,993	0,908	0,897
Topluluk	0,911	0,913	0,994	0,923	0,915
Nöral Ağlar	0,917	0,922	0,994	0,922	0,921
Çekirdek	0,923	0,927	0,995	0,930	0,927

**Tablo 5.** MobileNetV2 mimarisi kullanılarak elde edilen sonuçlarda sınıflandırıcılara ait ortalama performans sonuçları (Average performance results of classifiers in the results obtained using MobileNetV2 architecture)

Sınıflandırıcı	MCC	Duyarlılık	Özgüllük	Kesinlik	F1-Skor
Karar Ağaçları	0,533	0,555	0,971	0,568	0,559
Lineer Diskriminant	0,911	0,915	0,994	0,919	0,916
Naif Bayes	0,862	0,868	0,991	0,874	0,869
DVM	0,935	0,938	0,995	0,941	0,939
K- En Yakın Komşuluk	0,899	0,904	0,993	0,908	0,904
Topluluk	0,935	0,938	0,995	0,941	0,939
Nöral Ağlar	0,924	0,928	0,995	0,929	0,928
Çekirdek	0,923	0,926	0,995	0,931	0,927

**Tablo 6.** Önerilen çalışmanın literatürdeki bazı çalışmalarla karşılaştırılması  
(Comparison of the proposed study with some studies in the literature)

Çalışma	Model	Veri Seti	Başarı Oranı (%)	
Giri [9]	Inception V3	Oxford-17	86,4	
Lin vd. [10]	VGG-16	Oxford-17	<u>Ox-17</u>	<u>Ox-102</u>
	VGG-19	Oxford-102	79,56	81,26
	LeNet-5		80,26	80,82
	AlexNet		72,45	73,46
			78,32	78,92
Pandey vd. [11]	RegNetY 16GF	Oxford-17	93,4	
Giri vd. [12]	Inception V3	Oxford-17	<u>Ox-17</u>	<u>Cal-101</u>
		Caltech-101	92,27	98
Tian vd. [13]	Tiny DarkNet	Oxford-17	92	
Zhao vd. [14]	CCAN	Five Categories	<u>Fi Ca</u>	<u>Ox-17</u> <u>Ox-102</u>
		Oxford-17	86,12	90,44
		Self-dataset		90,91
Singprayoon vd. [15]	2-ICNN	Oxford-17	<u>Ox-17</u>	<u>Ox-102</u>
	1F-ICNN	Oxford-102	83,68	80,31
	1L-ICNN		84,63	80,12
			83,01	78,97
Ran vd. [16]	LeNet-5	Oxford-17	<u>Ox-17</u>	<u>Ox-102</u>
		Oxford-102	93	92,56
Önerilen Çalışma	AlexNet	Oxford-17	93,1	
	MobileNetV2		93,9	

Tablo 4'e göre AlexNet mimarisi kullanılarak elde edilen performans sonuçlarında en yüksek değerler DVM sınıflandırıcısına aittir. Tablo 5'e göre MobileNetV2 mimarisi kullanılarak elde edilen performans sonuçlarında ise en yüksek değerler DVM ve Topluluk sınıflandırıcılarına aittir. Tablo 6'da önerilen çalışma ile literatürdeki bazı çalışmalar karşılaştırılmaktadır.

Tablo 6'da görüldüğü üzere Giri'nin yapmış olduğu çalışmada [9], Oxford-17 veri seti kullanılmış olup mimari olarak Inception V3 mimarisi tercih edilmiştir. %86,4 başarı değeri elde edilmiştir. Lin ve arkadaşının yapmış olduğu çalışmada [10], Oxford-17 ve Oxford-102 veri setleri kullanılmıştır. Sırasıyla VGG-16, VGG-19, LeNet-5 ve AlexNet mimarileri tercih edilmiştir. VGG-16 mimarisinden Oxford-17 veri setinde %79,56, Oxford-102 veri setinde ise %81,26 başarı değeri elde edilmiştir. VGG-19 mimarisinden Oxford-17 veri setinde %80,26, Oxford-102 veri setinde ise %80,82 başarı değeri elde edilmiştir. LeNet-5 mimarisinden Oxford-17 veri setinde %72,45, Oxford-102 veri setinde ise %73,46 başarı değeri elde edilmiştir. AlexNet mimarisinden Oxford-17 veri setinde %78,32, Oxford-102 veri setinde ise %78,92 başarı değeri elde edilmiştir. Pandey ve arkadaşlarının yapmış olduğu çalışmada [11], Oxford-17 veri seti kullanılmış olup RegNetY 16GF modeli tercih edilerek %93,4 başarı değeri elde edilmiştir. Giri ve arkadaşının yapmış olduğu çalışmada [12], Oxford-17 ve Caltech-101 veri setleri kullanılmıştır. Inception V3 modeli tercih edilerek Oxford-17 veri setinde %92,27, Caltech-101 veri setinde ise %98 başarı değeri elde edilmiştir. Tian ve arkadaşlarının yapmış olduğu çalışmada [13], Oxford-17 veri seti kullanılmıştır. Tiny DarkNet mimarisi tercih edilerek %92 başarı değeri elde edilmiştir. Zhao ve arkadaşlarının yapmış olduğu çalışmada [14], Five Categories, Oxford-17 ve Self-dataset veri setleri kullanılmış olup CCAN modeli tercih edilmiştir. Five Categories veri setinden %86,12, Oxford-17 veri setinden %90,44, Self-dataset veri

setinden %90,91 başarı değeri elde edilmiştir. Singprayoon ve arkadaşının yapmış olduğu çalışmada [15], 2-ICNN, 1F-ICNN ve 1L-ICNN modelleri tercih edilmiş olup Oxford-17 ve Oxford-102 veri setleri kullanılmıştır. 2-ICNN modelinde Oxford-17 veri setinden %83,68, Oxford-102 veri setinden ise %80,31 başarı değeri elde edilmiştir. 1F-ICNN modelinde Oxford-17 veri setinden %84,63, Oxford-102 veri setinden ise %80,12 başarı değeri elde edilmiştir. 1L-ICNN modelinde Oxford-17 veri setinden %83,01, Oxford-102 veri setinden %78,97 başarı değeri elde edilmiştir. Ran ve arkadaşlarının yapmış olduğu çalışmada [16], LeNet-5 mimarisi tercih edilmiş olup Oxford-17 ve Oxford-102 veri setleri kullanılmıştır. Oxford-17 veri setinden %93, Oxford-102 veri setinden ise %92,56 başarı değeri elde edilmiştir. Bu çalışmalara bakılarak önerilen çalışmanın başarılı sonuçlar verdiği görülmektedir. AlexNet ve MobileNetV2 mimarilerinde kullanılan katmanlar sayesinde daha başarılı sonuçlar elde edilmiştir. MobileNetV2 mimarisinde derinlemesine ayrılabilir evrişim katmanları kullanılarak verim artırılmıştır. AlexNet mimarisinde ise kullanılan seyreltme katmanı performansın doğru bir şekilde artmasını sağlamıştır. Önerilen çalışmada, MobileNetV2 mimarisinin AlexNet mimarisine göre daha yüksek performans gösterdiği belirlenmiştir. Bunun sebebi, MobileNetV2 mimarisinin AlexNet mimarisine göre daha yeni bir mimari olmasıdır. Ayrıca MobileNetV2 mimarisine göre AlexNet mimarisi daha büyük bir model olup, hesaplama yükü daha fazladır. Bu, modelin performansını olumsuz yönde etkileyebilmektedir.

## 5. Sonuçlar (Conclusions)

Günümüzde derin öğrenme, birçok alanda kullanılan ve hayatımızı büyük ölçüde kolaylaştıran bir çalışma alanıdır. Çiçek türlerini tanıma problemlerinde de etkili sonuçlar elde edilmektedir. Yapılan bu çalışmada Oxford-17 veri seti kullanılmış olup derin öğrenme

mimarilerinden AlexNet ve MobileNetV2 mimarilerinin performansları karşılaştırılmıştır. AlexNet mimarisinden elde edilen sonuçlarda en yüksek başarı değeri %93,1 olarak tespit edilmiştir. MobileNetV2 mimarisinden elde edilen sonuçlara göre ise en yüksek başarı değeri %93,9 olarak tespit edilmiştir.

Bu çalışmada çiçek sınıflandırma problemine yönelik AlexNet ve MobileNetV2 derin öğrenme mimarileri ve Oxford-17 veri seti kullanılmıştır. Oxford-17 veri seti, sınırlı sayıda çiçek türünü içermektedir. Ayrıca veri setindeki görüntü sayısının sınırlı olması modelin genelleme yeteneğini etkileyebilmektedir. Kullanılan derin öğrenme mimarileri, son dönemde çıkarılan yeni mimarilerle karşılaştırıldığında performans olarak geride kalabilir. Bu nedenle ileride yapılacak olan çalışmalarda daha yeni mimarilerin kullanılması hedeflenmektedir.

Derin öğrenmenin gün geçtikçe iyileştirilmesi göz önünde bulundurulduğunda gelecekte yapılacak çalışmalarda daha iyi sonuçlar veren ve daha anlamlı özellikler çıkarabilen derin öğrenme mimarileri geliştirilerek, çok sayıda çiçek türünü içeren büyük veri setleri kullanılmasıyla çiçek tanıma problemlerinde daha iyi sınıflandırma işlemi gerçekleştirilebileceği düşünülmektedir. Ayrıca optimizasyon algoritmaları kullanılarak başarı oranının artırılabilmesi düşünülmektedir.

#### Teşekkür (Acknowledgement)

Bu çalışma Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından ADEP.24.23 proje numarası ile desteklenmektedir.

#### Kaynaklar (References)

1. Karabay, G. S., Çavaş, M., Derin Öğrenme Yöntemiyle Alzheimer Hastalığının Tespiti, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 34 (2), 879–887, 2022.
2. Bae, H. S., Lee, H. J., Lee, S. G., Voice recognition based on adaptive MFCC and deep learning, 2016 IEEE 11th Conference on Industrial Electronics and Applications (ICIEA) June 05-07, 2016.
3. Khurana, L., Chauhan, A., Naved, M., Singh, P., Speech Recognition with Deep Learning, Journal of Physics: Conference Series April, 2021.
4. Zhang, X., Tao, Z., Zhao, H., Xu, T., Pathological voice recognition by deep neural network, 2017 4th International Conference on Systems and Informatics (ICSAI) November 11-13, 2017.
5. He, K., Zhang, X., Ren, S., Sun, J., Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 37 (9), 1904–1916, 2015.
6. Wu, Z., Shen, C., Van Den Hengel, A., Wider or Deeper: Revisiting the ResNet Model for Visual Recognition, Pattern Recognition, 90, 119–133, 2019.
7. Lopez, M. M., Kalita, J., Deep Learning applied to NLP, ArXiv Preprint ArXiv:1703.03091, 2017.
8. Guo, J., He, H., He, T., Lausen, L., Li, M., Lin, H., Shi, X., Wang, C., Xie, J., Zha, S., Zhang, A., Zhang, H., Zhang, Z., Zhang, Z., Zheng, S., Zhu, Y., GluonCV and gluon NLP: Deep learning in computer vision and natural language processing, The Journal of Machine Learning Research, 21 (1), 845–851, 2020.
9. Giri, S., Image based flower species classification using CNN, Journal of Innovation in Engineering Education, 2 (1), 182–186, 2019.
10. Lin, D. S., Cheng, C. F., Research on flower image recognition algorithm, International Conference on Big Data, Information and Computer Network (BDICN), IEEE January 20-22, 2022.
11. Pandey, S., Sindhuja, B., Nagamanjularani, C. S., Nagarajan, S., Exploring Transfer Learning Techniques for Flower Recognition Using CNN, Data Science and Security: Proceedings of IDSCS 2022, Springer Nature Singapore July 02, 2022.
12. Giri, S., Joshi, B., Transfer Learning Based Image Visualization Using CNN, International Journal of Artificial Intelligence and Applications (IJAAIA), 10 (4), 47–55, 2019.
13. Tian, M., Chen, H., Wang, Q., Flower identification based on Deep Learning, Journal of Physics: Conference Series, 1237 (2), 1-10, 2019.
14. Zhao, X., Feng, Y., Shi, X., Wang, Y., Zhang, G., A color constancy based flower classification method in the blockchain data lake, Multimedia Tools and Applications, 83 (10), 28657–28673, 2024.
15. Singprayoon, S., Supratid, S., Effects of Number and Position of Auxiliary Networks used in Inception Convolutional Neural Network on Object Recognition, 2021 International Electrical Engineering Congress, (IEECON 2021), Pattaya March, 2021.
16. Ran, J., Shi, Y., Yu, J., Li, D., A Multi-Feature Convolution Neural Network for Automatic Flower Recognition, Journal of Circuits, Systems and Computers, 30 (15), 2021.
17. Krizhevsky, A., Sutskever, I., Hinton, G. E., ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems, 25, 1-9, 2012.
18. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L. C., MobileNetV2: Inverted Residuals and Linear Bottlenecks, CVF Conference on Computer Vision and Pattern Recognition, IEEE, 4510-4520, 2018.
19. Nilsback, M. E., Zisserman, A., A visual vocabulary for flower classification, 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06) June 17-22, 2006.
20. Susanti, H., Yusuf, M., Sumardiono, A., Simulation and Experimentation of Fire Fighting with Early Detection Based on MobileNetV2, 2022 5th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), 548–553, 2022.
21. Van Hieu, N., Hien, N. L. H., Automatic plant image identification of Vietnamese species using deep learning models, International Journal of Engineering Trends and Technology (IJETT), 68 (4), 25–31, 2020.
22. Sunnetci, K. M., Ulukaya, S., Alkan, A., Periodontal bone loss detection based on hybrid deep learning and machine learning models with a user-friendly application, Biomedical Signal Processing and Control, 77, 2022.
23. BİLGIN, G., Investigation of The Risk of Diabetes in Early Period using Machine Learning Algorithms, Journal of Intelligent Systems: Theory and Applications, 4 (1), 55–64, 2021.
24. Choose Classifier Options - MATLAB & Simulink. <https://www.mathworks.com/help/stats/choose-a-classifier.html>. Erişim tarihi Haziran 5, 2024.
25. Sunnetci, K. M., Alkan, A., KNN and Decision Trees based SPPM demodulators applicable to synchronous modulation techniques, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (3), 1247–1261, 2022.
26. Chicco, D., Jurman, G., The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation, BMC Genomics, 21 (6), 2020.
27. Chicco, D., Tötsch, N., Jurman, G., The matthews correlation coefficient (MCC) is more reliable than balanced accuracy, bookmaker informedness, and markedness in two-class confusion matrix evaluation, BioData Mining, 14 (13), 2021.