



**Makale / Research Paper**

**Yağ Gülü (*Rosa damascena* Mill.) Bitkisinin Hasat Durumunun Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile Tespiti**

**Burhan DUMAN<sup>1a\*</sup>, Kıyas KAYAALP<sup>2b</sup>**

<sup>1</sup>Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta/TÜRKİYE

<sup>2</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta/TÜRKİYE  
[burhanduman@isparta.edu.tr](mailto:burhanduman@isparta.edu.tr)

**Received/Geliş:** 24.06.2022

**Accepted/Kabul:** 07.09.2022

**Öz:** Bitkiler uzun yıllardır çoğu sektörde insan hayatında önemli bir yer tutmaktadır. Pembe Yağ Gülü olarak adlandırılan *Rosa damascena* Mill. bitkisi, gül çeşitleri arasında kendine özgü keskin ve yoğun kokusu ile kozmetik, parfüm, ilaç ve gıda endüstrisi gibi sektörler için ekonomik değeri olan bir türdür. Türkiye’de Mayıs aylarında hasadına başlanan yağ gülü, tomurcuklarının çiçek açması durumunda hasadı yapılmaktadır. Tomurcuk halindeki güller ise açması durumuna kadar hasat edilmeden bırakılmaktadır. Bu çalışmada makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak her bir yağ gülünün “hasat edilebilir/hasat edilemez” durumuna göre ikili sınıflandırılması gerçekleştirilmiştir. Gül bahçelerinden elde edilen görüntüler ile oluşturulan veri seti, yapay zekâ modellerinin eğitim ve testinde kullanılmıştır. Makine öğrenmesi modeli olarak DVM sınıflandırıcısı, derin öğrenme modelleri olarak da VGG16, VGG19 ve InceptionV3 kullanılmıştır. Sınıflandırma başarımları; DVM modelinde %71.06, VGG16 modelinde %96.44, VGG19 modelinde %97.96 ve InceptionV3 modelinde %72.08 olarak elde edilmiştir.

**Anahtar Kelimeler:** *Rosa damascena* Mill, DVM, InceptionV3, VGG16, VGG19.

**Detection of Harvest Status of Oil Rose (*Rosa damascena* Mill.) with Machine Learning and Deep Learning Methods**

**Abstract:** Plants have an important place in human life in many sectors for many years. *Rosa damascena* Mill plant, which is called Pink Oil Rose, is a species that has economic value for sectors such as cosmetics, perfume, medicine and food industry with its distinctive sharp and intense scent among rose varieties. Oil rose is harvested in May in Turkey when its buds bloom. Roses in bud form are left unharvested until they bloom. In this study, binary classification of each oil rose according to "harvestable/non-harvestable" status was carried out using machine learning and deep learning methods. The data set created with the images obtained from the rose gardens was used in the training and testing of artificial intelligence models. DVM classifier was used as machine learning model, and VGG16, VGG19 and InceptionV3 were used as deep learning models. Classification performance is 71.06% in the DVM model, 96.44% in the VGG16 model, 97.96% in the VGG19 model and 72.08% in the InceptionV3 model.

**Keywords:** *Rosa damascena* Mill., DVM, InceptionV3, VGG16, VGG19.

**1. Giriş**

Yağ Gülü dünyada 200’den fazla türü ve yaklaşık 18.000 çeşidi bulunan Rosaceae familyasından olan, yağ gülü olarak adlandırılan, kendine özgü keskin bir kokuya sahip yıllarca ürün verebilen

*Bu makaleye atf yapmak için*

Duman, B., Kayaalp, K., “Yağ Gülü (*Rosa damascena* Mill.) Bitkisinin Hasat Durumunun Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile Tespiti” El-Cezerî Fen ve Mühendislik Dergisi 2022, 9(4); 1328-1341.

*How to cite this article*

Duman, B., Kayaalp, K., “Detection of Harvest Status of Oil Rose (*Rosa damascena* Mill.) with Machine Learning and Deep Learning Methods” El-Cezerî Journal of Science and Engineering, 2022, 9(4); 1328-1341.

ORCID ID: \*0000-0001-5614-1556; \*0000-0002-6483-1124

tıbbi ve aromatik bir bitki türüdür. Yağ Gülü sadece kozmetik sektöründe değil, aynı zamanda ilaç ve gıda gibi birçok farklı alanda kullanımı mevcuttur. Çok fazla kullanım alanı bulunan Yağ Gülü üretiminin %50'si ülkemizde, %40'ı Bulgaristan'da geri kalan miktarı ise İran, Afganistan, Fas, Hindistan ve Çin'de gerçekleştirilmektedir [1]. Şekil 1'de görüntüsü verilen Yağ Gülü ülkemizde ise en çok Isparta ilinde özellikle Merkez, Gönen, Keçiborlu, Eğirdir, Uluborlu, Atabey ilçelerinde olmak üzere, az bir kısmı ise Burdur, Afyon, Konya ve Denizli illerinin Isparta'ya yakın olan bölgelerinde yetiştirilmektedir [2], [3]. Kozmetik ve parfümeri sanayisinde kullanılan yağ gülünden; başta yağ, su, konkret ve absolüt gibi ürünler elde edilmektedir. Ayrıca gıda sanayisinde, kişisel bakım ve temizlik ürünlerinin yanı sıra, tıpta birçok hastalığın önlenmesinde ve tedavisinde kullanılmaktadır [4]–[6]. Tıpta özellikle; stres, depresyon, jinekolojik hastalıklar, yaraların iyileştirilmesinde, sindirim sistemi, kalp ve solunum hastalıklarının tedavisinde kullanılmaktadır [7]–[9]. İlk olarak Bulgaristan'ın Kazanlık bölgesinde yetiştirilen yağ gülü, coğrafik konumu, iklimi ve toprak yapısı ile 19. yüzyılın sonlarında Isparta'da yetiştirilmeye başlanmış ve yağ gülünün üretim merkezi haline gelmiştir. 2021 yılında, Isparta'da 15 bin, Burdur'da 2 bin, Afyon'da 700 ton ve diğer illerle birlikte toplamda yaklaşık olarak 20 bin ton gül çiçeği üretimi yapılmıştır [10].



**Şekil 1.** Yağ Gülü

Literatürde yağ gülü ile ilgili yapılan çalışmaların büyük bir çoğunluğu kullanım alanlarının ve ürün kalitesinin artırılmasına yöneliktir. Az sayıda da olsa yapay zekâ yöntemlerinin kullanıldığı ve gül yağının sınıflandırılması ile ilgili çalışmalar bulunmaktadır [11], [12]. Bu çalışmada ise, Yapay Zekâ yöntemlerinden Makine Öğrenmesi ve Derin Öğrenmenin yağ gülü hasadında kullanılabilirliği araştırılmıştır. Gül bahçelerinden elde edilen görüntülerden oluşturulan veri seti ile DVM, VGG16, VGG19 ve InceptionV3 modelleri eğitilerek başarımları bulunmuştur.

## 2. Literatür Özeti

Teknolojinin gelişmesine paralel olarak birçok farklı alanda yapay zekâ uygulamaları geliştirilmekte ve kullanılmaktadır. Geliştirilen uygulamalardan bir bölümü görüntüler üzerinde yapılan sınıflandırma çalışmalarıdır [13]. Bu çalışmalar kullanılan veri setindeki görüntülerin oluşturduğu sınıf sayısına bağlı olarak farklılıklar gösterebilmektedir. Çalışmada yağ gülünün hasat edilebilir ve hasat edilemez olduğunun tespiti üzerine ikili sınıflandırma işlemi gerçekleştirilmiştir. Literatürde farklı sektörlerde yapılan ikili sınıflandırma çalışmalarından bazıları sunulmuştur.

Rodrigues vd.[14] 2020 yılında yaptıkları çalışmalarında, Melanom cilt kanserinin tespiti için IoT sisteminde Derin Öğrenmenin kullanılabilirliğini araştırmışlardır. İki veri setinde bulunan 1100 adet dermatoskopik görüntüler, veri artırma teknikleri ile 6600 adete çıkarılmıştır. VGG16, VGG19,

ResNet, InceptionV3, MobileNet, DenseNet, NASNet modellerinin kullanıldığı çalışmada, görüntülerin sağlıklı veya Melanom kanseri olduğunun sınıflandırılmasında en iyi doğruluk oranını InceptionV3 modeliyle %78.75 oranına ulaşılmıştır. 2021 yılında ise Patra vd.[15], şehir içinde bulunan yollardaki çukurlarının tespitinin yapay zekâ yöntemleri ile tespitini değerlendirmişlerdir. Çalışmada, Kalküta şehrinin Jadavpur ve Garia bölgelerindeki yollardan kendi imkânları ile elde ettikleri 3424 adet görüntü kullanılmıştır. Yollarda bulunan çukurların tespitinde önceden eğitilmiş VGG16, VGG19 ve InceptionV3 modelleri uygulanmıştır. Yol kazalarını ve araçların hasar görmesini önlemek, seyahat konforunu artırmak gibi çukurların belirlenmesi için yapılan çalışmada InceptionV3 ile %92.50 doğruluk oranı elde edilmiştir.

2021 yılında Pancholi vd.[16] yaptıkları çalışmada, Dünya nüfusunun yaklaşık %10'nun etkilendiği yüz, alın, sırt ve göğüste çıkan aknelere yönelik bir çalışma gerçekleştirmişlerdir. 100 tanesi normal ve 100 tanesinde akne bulunan veri setinden yararlanılmıştır. Farklı ciltlerdeki aknelere tanımlanması için önceden eğitilmiş VGG16, VGG19 ve InceptionV3 modelleri kullanılmış ve %99.5 doğruluk oranı InceptionV3 modeli ile elde edilmiştir. Ünal vd. [17] 2022 yılında, kamuya sunulmuş olan hasarlı araba setini kullanarak, ikili sınıflandırma çalışması yapmışlardır. Veri setinde var olan 80 sağlam ve 80 hasarlı araç sayısını veri artırma yöntemleri ile 5 kat artırarak çalışmalarında 800 araç görüntüsünü kullanmışlardır. En iyi sınıflandırma oranının NasnetLarge algoritması ile elde edildiği çalışmada, VGG16, VGG19, InceptionV3 ve DenseNet algoritmaları da kullanılmıştır. Vivek vd.[18] 2022 yılında, insanların sağlığını olumsuz yönde etkileyen Guatr hastalığının CNN modelleri ve Makine Öğrenmesi sınıflandırıcıları ile tespiti üzerine bir çalışma gerçekleştirmişlerdir. Veri seti olarak 103 tanesi guatr hastası ve 116 tanesi sağlıklı insana ait boyun resmini kullanmışlardır. İnsan boyun resimindeki şişkinliğin önceden eğitilmiş VGG16, InceptionV3 ve VGG19 algoritmaları ile özellik çıkarımı gerçekleştirildikten sonra, lojistik regresyon, rastgele orman, destek vektör makinesi, KNN, yapay sinir ağı, saf bayes ve adaBoost sınıflandırıcıları ile sınıflandırma işlemlerini gerçekleştirmişlerdir.

Malik vd. [19] 2018 yılında, Makine öğrenimi kullanılarak gül bitkisi sınıflandırmasının performans değerlendirilmesi isimli çalışmalarında 4 farklı gül türünü yaprak görüntülerinden faydalanarak sınıflandırmaya çalışmışlardır. Veri setini dört farklı (turuncu, kırmızı, pembe ve beyaz) gül yaprağına ait toplam 100 fotoğraftan oluşturmuşlardır. k En Yakın Komşu (k-NN) tabanlı bir makine öğrenmesi yaklaşımı ile maksimum %65 doğruluk oranına ulaşmışlardır. Literatürde Yağ Gülü ile ilgili yapılan çalışmaların büyük bir çoğunluğu gül yağının farmakolojik etkileri, doku kültürü, uçucu yağ bileşimi üzerine olmakla birlikte, yapay zekâ yöntemlerinin kullanıldığı çalışmalara rastlanamamıştır. Çalışma literatürdeki Yağ Gülü ile ilgili yapay zekâ yöntemlerinin kullanılabilirliğine yönelik katkı sağlaması açısından önem arz etmektedir.

### 3. Materyal ve Metot

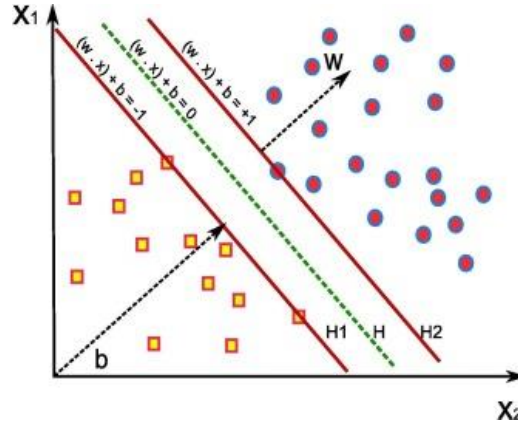
#### 3.1. Destek Vektör Makineleri (Support Vector Machines)

Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon analizinde kullanılan, istatistiksel öğrenme alanında geliştirilmiş denetimli bir yapay zekâ öğrenme yöntemidir [20], [21]. DVM, temeli 1960'lı yıllara dayansa da, bugünkü şekline Vapnik vd. tarafından 1992 yılında yapılan çalışma ile literatüre kazandırılmıştır [22], [23]. DVM sağlam teorik temelleri ve iyi genelleme kapasitesi nedeniyle son yıllarda veri madenciliği, örüntü tanıma ve makine öğrenmesi uygulamalarında en çok kullanılan sınıflandırma yöntemlerinden biri haline gelmiştir [24], [25].

Örüntü sınıflandırmada temel amaç, eğitim verileri kullanılarak, en iyi sınıflandırma performansını veren bir model elde etmektir. Bunun için DVM'ler eğitim setindeki sınıfları, birbirinden ayırabilen optimum hiper düzlemi bulmaya çalışırlar. DVM'ler çözdükleri problemlere göre, doğrusal ve

doğrusal olmayan olmak üzere iki farklı türe ayrılabilir.

**Doğrusal DVM :** Doğrusal olarak ayrılan problemlerde, amaç sınıfların özellikleri arasından geçen hiper düzlemi bulmaktır (Şekil 2). Bu hiper düzlem sınıflara ait özelliklerin birbirine en uzak olduğu iki doğrudan oluşmaktadır. Bu doğrular Şekil 2’de gösterilen  $(w \cdot x) + b = +1$  ve  $(w \cdot x) + b = -1$  ile temsil edilen hiper düzlemlerdir. Hiper düzlemler üzerindeki kare ve daire şeklindeki sınıflara ait özellikler ise destek vektörlerini temsil ederler. Doğrusal DVM problemlerinin karmaşıklığı, kullanılan özelliklerin sayısına bağlı olarak değişiklik göstermektedir.



Şekil 2. Doğrusal DVM [26]


**Doğrusal Olmayan DVM :** Eğer eğitim verileri doğrusal olarak ayrılabilir değilse, sınıflar arasındaki boşluğu maksimize etmek için hiper düzlemler optimal olarak belirlenmiş olsa bile, elde edilen sınıflandırıcı yüksek bir genelleme yeteneğine sahip olmayabilir. Böyle durumlarda, eğitim verilerinin birbirinden ayrılabilmesi için çok boyutlu uzaya dönüştürmek gerekmektedir (Şekil 3). İki boyutlu uzaydan çok boyutlu uzaya dönüşüm aşamasında çekirdek fonksiyon ismi verilen özel fonksiyonlar kullanılmaktadır. Bu amaç için literatürde kullanılan çekirdek fonksiyonlardan Doğrusal Çekirdek Eşitlik 1, Gauss Çekirdek Eşitlik 2, Anova Çekirdek Eşitlik 3 ve Polinom Çekirdek Eşitlik 4 ile gösterilmiştir.

Doğrusal Çekirdek 
$$K(x_i, x_j) = x_i^T x_j \quad (1)$$

Gauss Çekirdek 
$$K(x_i, x_j) = (e)^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (2)$$

Anova Çekirdek 
$$K(x_i, x_j) = \sum_{i=1}^n \exp(-\sigma(x_i^i - x_j^i)^2)^d \quad (3)$$

Polinom Çekirdek 
$$K(x_i, x_j) = (1 + x_i^T x_j)^d \quad (4)$$



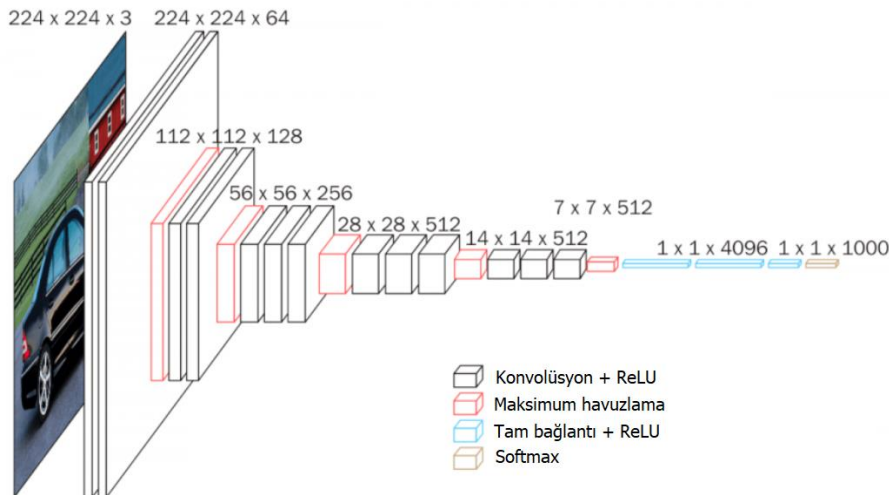
Şekil 3. Boyut artırma işlemi [27]

Literatürde boyut artırımı için kullanılan çekirdek fonksiyonlarının kullanıldığı uygulamalara bakıldığında; Polinom'un doğal dil işlemede [28], Gauss'un iflas tahmininde [29], Doğrusal'ın ise kötü amaçlı yazılım tespiti [30] gibi farklı uygulamalarda kullanıldığı görülmektedir.

### 3.2. VGG16

VGG16, Oxford Üniversitesi'nden Karen Simonyan ve Andrew Zisserman tarafından önerilen bir Evrişimsel Sinir Ağı (CNN) modelidir. 2014 yılında, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veritabanında, %92,7 sınıflandırma başarımlarını sağlamıştır. AlexNet-2012 ve ZFNet-2013 modellerinden farklı olarak bu modelde, tüm ağ boyunca 1 piksellik adımlarla çok küçük 3×3 filtreler kullanılmıştır [31]. Böylece, ağa daha hızlı yakınsama yeteneği kazandırılmıştır.

VGG-16 mimarisinin genel yapısı Şekil 4'de verilmiştir. Ağa girdi verisi olarak 224×224 boyutunda RGB (Red Green Blue – Kırmızı Yeşil Mavi) formatında görüntüler aktarılır. İlk olarak RGB değerlerinin normalleştirilmesi yapılır. Görüntüler, iki defa 3×3'lük evrişim katmanı ve ReLU aktivasyonundan sonra, 3 defa 3×3'lük evrişim katmanı ve ReLU aktivasyonundan geçirilir. Her evrişim ve ReLU uygulamasından sonra 2×2'lik maksimum havuzlama işlemi yapılır. Daha sonra ilk ikisi 4096 ve üçüncüsü 1000 nörona sahip tam bağlantı katmanından geçirilir. Son olarak da, Softmax aktivasyon katmanı ile sınıflandırma işlemi tamamlanır.




Şekil 4. VGG-16 mimarisi [32]

VGG-16 mimarisi bitkilerde hastalık [33], [34], tıpta beyin tümörü [35] ve zatürre [36] gibi hastalık, görsel konuşma [37], balık türlerinin tespiti [38] ve otomatik yüz tanıma [39] olmak üzere birçok farklı disiplinde kullanılmaktadır.

### 3.3. VGG19

VGG16 ile hemen hemen benzer mimariye sahip olan VGG19’da (Şekil 5), 16 evrişimsel, 5 havuzlama ve 3 adet tam bağlantı katmanı bulunmaktadır. VGG19’un amacı, evrişimsel katmanda bulunan filtreler ile parametre sayısının azaltılarak derinlemesine bir ağa sahip olunmak istenmesidir. Bu mimari yaklaşık olarak 144 milyon parametre içermektedir [40]. Şekil 5’de VGG16 ile VGG19 mimarilerine şematik olarak bakıldığında, VGG19’da sadece 3 adet konvolüsyonel katmanın fazlalığı göze çarpmaktadır.



Şekil 5. VGG16 (a) ile VGG19 (b) mimarilerinin şematik olarak birlikte gösterimi [41]

Tablo 1’den de görüleceği üzere, her iki mimarinin de giriş bilgileri  $224 \times 224$  piksel olmasına rağmen VGG19’da 3 konvolüsyon ve 13 ReLU katmanının fazla olduğu görülmektedir. Ayrıca VGG16’da 64 ve 128’lik filtreler kullanılırken, VGG19’da bunlara ek olarak 256 ve 512’lik filtreler kullanılmıştır. VGG19 mimarisi literatürde; beyin tümörü tespitinde [42], makine arıza teşhisinde [43], görüntü tabanlı kötü amaçlı yazılım sınıflandırmasında [44], yüz ifadesi tanımada [45] ve bitki patolojisi sınıflandırması [46] gibi birçok farklı alanda kullanılmıştır ve halen kullanılmaya devam etmektedir.

Tablo 1. VGG16 ile VGG19 mimarileri arasındaki farkların tablo halinde gösterilmesi [47]

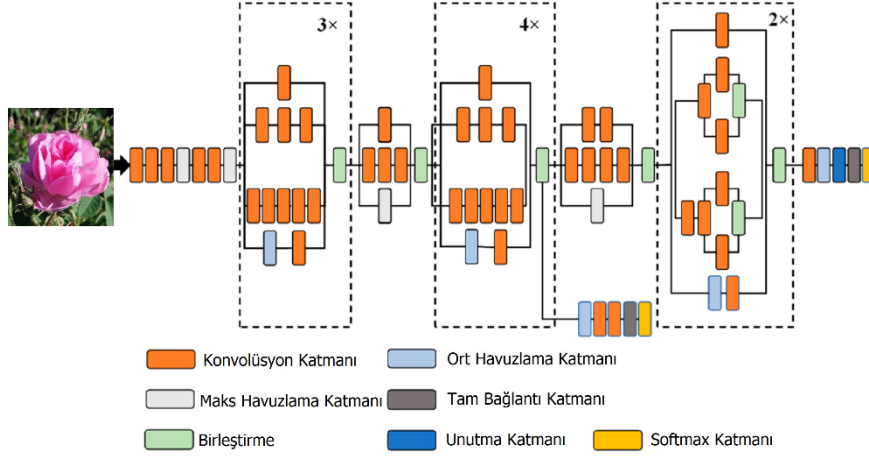
Katman	VGG16	VGG19
Katman sayısı	16	19
Görüntü giriş boyutu	$224 \times 224$ piksel	$224 \times 224$ piksel
Konvolüsyon Katmanı	13	16
Filtre Boyutu	64,128	64, 128,256, 512
ReLU	5	18
Maksimum Havuzlama	5	5
Tam Bağlantı Katmanı	3	3
Unutma	0,5	0,5
Softmax	1	1

### 3.4. InceptionV3

Szegedy vd. tarafından literatüre kazandırılan Inception ağı, ILSVRC 2014 görüntü sınıflandırma yarışmasında birinci olmuştur [48]. Inception ağında, ağın genişletilmesi ile zamansal olarak hesaplama maliyeti ve gradyan kaybı azaltılmıştır. Bu ağda, büyük çekirdekler ile görüntülerdeki global bilgilere, küçük çekirdekler ile de lokal bilgilere erişim sağlanabilmektedir [49]. Inception V1 ağında, en büyük problem kullanılan  $5 \times 5$ ’lik evrişim çekirdeklerinden dolayı artan hesaplama maliyetidir. Bunun çözümü için, Inception V2 ağında  $3 \times 3$ ’lük evrişim çekirdekleri kullanılarak zamanlama maliyeti 2.78 kat azaltılmıştır. Inception V3 ise, faktörizasyon fikri ile ortaya çıkmıştır. İşlem sayısını daha da azaltmak için Inception V3 ağında, işlemsel parametreler azaltılarak ağın etki derecesinin aynı kalması sağlanmıştır [50].



Mimarisi Şekil 6’da verilen Inception V3 ağında, model simetrik ve asimetrik bloklardan oluşmaktadır. Her blokta farklı farklı evrişim, ortalama ve maksimum havuzlama, birleştirme (concat), unutmama ve tam bağlı katmanları bulunmaktadır. Ağın en sonunda ise sınıflandırma işlemi için Softmax katmanı kullanılmaktadır. Yaklaşık 20 milyonun üzerinde parametreden ve 48 katman derinliğinden oluşan bu ağda, 5×5’lik evrişimler yerine, 1×1 ve 3×3’lük evrişimler kullanılarak parametre sayısı azaltılarak, ağın eğitim hızı artırılmıştır.



Şekil 6. Inception V3 mimarisinin şematik gösterimi [51]

Inception V3 ağı literatürde, göğüs kanserinin erken tespiti gibi tıp uygulamalarında [52], el yazısı olarak Yunanca karakter tanımda [53], tohumları çeşidine göre sınıflandırma işlemlerinde [54], eklemeli imalatta kusur tespitinde [55], hasarlı ve hasarsız arabaların sınıflandırılması [17] gibi farklı birçok alanda kullanılmaktadır.

Literatürde iki sınıftan oluşan görüntülerin sınıflandırması için yapılan güncel çalışmalardan elde edilen doğruluk sonuçları Tablo 2’de verilmiştir. Tabloda literatürde yapılan çalışmalardan, sadece bu çalışmada yer alan sınıflandırıcılar ile elde edilmiş olan doğruluk değerleri gösterilmiştir.

Tablo 2. İki sınıftan oluşan verilerin sınıflandırılması için yapılan çalışmalar

Referans	DVM	VGG-16	VGG-19	InceptionV3
[17]	-	84,11	81,96	94,11
[18]		85,40	90,40	90,00
[15]	79,71	88,75	91,25	92,50
[56]		66,20	65,2	55,10
[14]		76,25	69,81	78,75
[16]		99,00	98,00	99,00
[57]		81,20	83,10	86,10
[58]		79,15	78,42	76,77
[59]		93,00	92,00	49,00
[60]		90,20	90,20	89,70

### 3.5. Performans Ölçütleri

Yapay zekâda, sınıflandırma modellerinin performans ölçümlerinde; doğruluk, F1-Skor, Duyarlılık, Kesinlik ve alıcı çalışma karakteristik (Receiver Operating Characteristic-ROC) eğrisi kullanılmaktadır. Tüm bu performans ölçümlerinde gerçek ve tahmin sınıfının dört farklı durumunu içeren Şekil 7’de gösterilen Hata Matrisinden yararlanır.

	Gerçek Pozitif	Gerçek Negatif
Tahmini Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
Tahmini Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

**Şekil 7.** Hata Matrisi


Eşitlik 5 ile gösterilen doğruluk oranı ise doğru olan tahmin sayısının, toplam tahmin sayısına olan oranıdır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (5)$$

Şekil 7’de hata matrisinde ve Eşitlik 5’deki doğruluk oranında ki DP; Doğru olarak belirlenen pozitif sınıfların tahmin sayısı, DN; Doğru olarak belirlenen negatif sınıfların tahmin sayısı, YP; Yanlış olarak belirlenen pozitif sınıfların tahmin sayısı ve YN; Yanlış olarak belirlenen negatif sınıfların tahmin sayısını ifade etmektedir [55].

#### 4. Bulgular ve Tartışma

Yapılan çalışmada, yağ gülü bitkisine ait görüntüler, Isparta ili Merkez, Gönen, Keçiborlu ve Atabey ilçeleri sınırları içerisinde bulunan tarlalardan rastgele örnekleme yöntemi ile elde edilmiştir. Görüntüler 2021 yılı Mayıs ayında farklı günlerde Xiaomi Redmi Note 9 Pro cep telefonu ile çekilmiştir. Görüntüler 6944 piksel genişliğinde, 9280 piksel yüksekliğinde, 72 dpi yatay ve dikey çözünürlüğünde, 24 bit derinliğindedir. Veri setinde 677 adet toplanabilir ve 283 adet toplanamaz olmak üzere toplamda 960 adet yağ gülü görüntüsü bulunmaktadır (Şekil 8).



**Şekil 8.** Veri setinde yer alan ve model için yeniden boyutlandırılmış örnek yağ gülü resimleri

Veri setindeki veriler %75 eğitim ve %25 test verisi olmak üzere rastgele olarak ayrılmıştır. Çalışma Kaggle platformunda Python Programlama dili ile ön eğitimli derin öğrenme modelleri ve Tensor Flow kütüphanesi kullanılarak gerçekleştirilmiştir.


Deneysel çalışmada kullanılan veriler “toplanabilir” ve “toplanamaz” olmak üzere iki sınıfa ayrılmıştır. Eğitim ve test verileri kullanılarak DVM, VGG16, VGG19 ve InceptionV3 modelleri ayrı ayrı eğitilmiştir. Veri setindeki görüntüler önışleme olarak 6944x9280 boyutundan, 1200x898 boyutuna indirgenmiştir. Tablo 3’de eğitilen modellerden elde edilen Doğruluk oranları (%) ve Kayıp değerleri verilmiştir. En yüksek performans %97,96 Doğruluk oranı ile VGG19 modelinden elde edilmiştir.



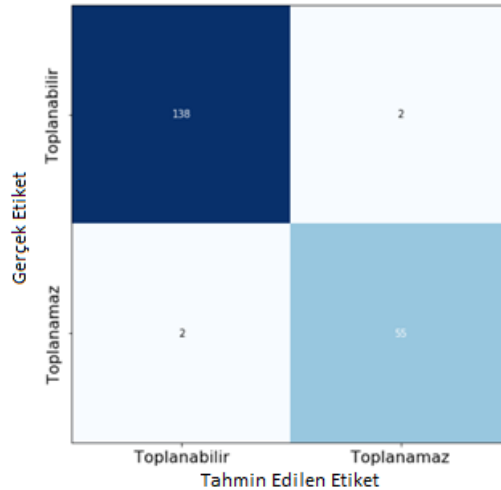
**Tablo 3.** Eğitilen modellerin performans karşılaştırılması

Model	Doğruluk Oranı (%)	Kayıp
VGG16	96,44	0,25
VGG19	97,96	0,05
InceptionV3	72,08	4,36
DVM	71,06	-

Çalışmada en yüksek başarı oranı, VGG19 modelinde elde edilirken birçok farklı değerler denenmiş, %97,96 doğruluk oranına 0.0001 öğrenme oranı, 50 periyot, 40 grup boyutu ve adam optimizatörü ile ulaşılmıştır. Modelin öğrenme veri seti üzerinden ölçülen doğruluk ve kayıp değerlerinin değişim grafiği Şekil 9’da sunulmuştur.

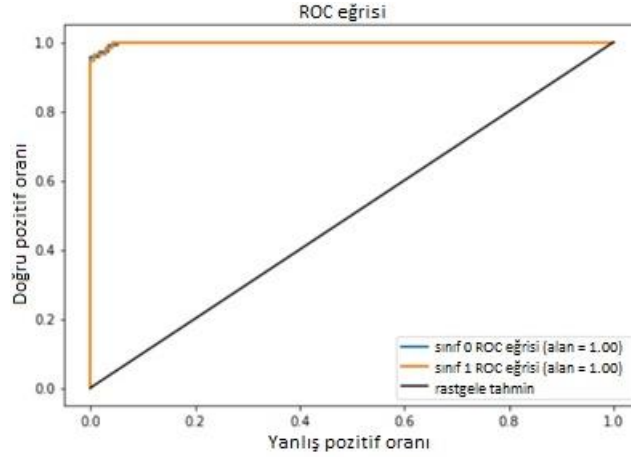
**Şekil 9.** Performans grafikleri (a) kayıp, (b) doğruluk

Önerilen VGG19 modelinin hata matrisinde 138 görüntü gerçek toplanabilir, 2 görüntü yanlış toplanabilir, 55 görüntü gerçek toplanamaz, ve 2 görüntü yanlış toplanamaz olarak sınıflandırılmıştır (Şekil 10). Model hata matrisinden de anlaşılacağı üzere model başarılı bir şekilde yağ gülünün toplanabilir ve toplanamaz olduğunu ayırabilmektedir.

**Şekil 10.** Model hata matrisi

Modelin başarılı veya başarısız olduğunu gösteren bir diğer etmen ise ROC eğrisidir. Bu eğriden istenen, eğri altında kalan alanın 1 veya 1'e çok yakın bir değer olmasıdır. Şekil 11'den de

görülebileceği üzere eğri altında kalan alan 1'dir, bu da modelin tahmin etme başarısının çok yüksek olduğunu göstermektedir.



**Şekil 11.** Model ROC eğrisi

Literatür incelendiğinde Tablo 2'den de görüleceği üzere VGG16, VGG19 ve InceptionV3 modelleri ile yapılan ikili sınıflandırma uygulamalarında, VGG16 modeli ile %66,20- %99,00, VGG19 modeli ile %65,20- %98,00 ve InceptionV3 modeli ile %49,00-%99,00 arasında doğruluk oranlarına sahip olan çalışmalar bulunmaktadır. Yapılan çalışmada da VGG16 ile %96,44, VGG19 ile %97,96, InceptionV3 ile %72,08 ve DVM ile %71,06 oranlarında başarımlar elde edilmiştir. Elde edilen başarımlar değerleri literatürde yapılan ikili sınıflandırma çalışmaları ile paralellik göstermektedir.

## 5. Sonuç ve Öneriler

Tıbbi ve aromatik bitkilerden olan yağ gülü başta kozmetik olmak üzere çok farklı alanlarda kullanılmaktadır. Ürünün yetiştirme koşullarına bakıldığında ise her yerde yetişmeyen Yağ Gülü özellikle Mayıs ve Haziran aylarında hasat edilmektedir. Yağ gülünden iyi derecede yağ elde edilebilmesi için hasat işlemi sabah erken saatlerde yapılması gerekmektedir. Şu ana kadar yağ gülünün hasadı insan gücü ile yapılmakta olup tarımsal mekanizasyon ile yapılan hasat işlemine pek rastlanılmamıştır. Akıllı tarım ile beraber tarımın pek çok alanında kullanılan tarımsal robotlar ile yağ gülünün hasat işlemi de gerçekleştirilebilecektir. Hasat işleminin tarımsal robotlarla yapılabilmesi için hangi güllerin toplanabileceği, hangi güllerin ise toplanamayacağına yapay zekâ sistemleri ile karar verilebilecektir.

Yapılan çalışmada, yağ gülünün toplanabilen ve toplanamayan olmak üzere iki farklı sınıfa ait yaklaşık 1000 adetten oluşan bir veri seti oluşturulmuştur. Makine öğrenmesi ve derin öğrenme modelleri, oluşturulan veri seti kullanılarak eğitilmiş ve hangi yöntemin daha uygun olduğunun tespit edilmesi amaçlanmıştır. Çalışmada en iyi sonuç, %97.96 doğruluk değerinde VGG19 modeli ile elde edilmiştir. Derin öğrenme modellerinin yüksek oranda başarımlar gösterdiği ve bu alanda kullanılabileceği tespit edilmiştir.

Literatür incelendiğinde bu amaç için daha önceden oluşturulmuş bir veri setine rastlanılmamıştır. Bu yüzden oluşturulan veri setinin, bu alanda çalışmak isteyen araştırmacılara da faydalı olacağı düşünülmektedir.

İlerleyen çalışmalarda, veri setinde bulunan 960 görüntü döndürme, kaydırma, parlaklık vb. gibi farklı veri çoğaltma teknikleri ile artırılabilir ve elde edilen sonuçlar incelenebilir. Çalışmada

kullanılan sınıflandırma algoritmalarından farklı modeller denenerek başarımlarının artıp artmadığı gözlemlenebilir.

### Teşekkür

Veri setinin oluşturulma aşamasında, gül resimlerini fotoğraflayan Ayşe Pelin ULUSOY'a teşekkür ederiz.

### Yazar(lar)ın Katkıları

KK giriş ve literatür kısımlarını hazırladı, veri setini modeller için uygulanabilir hale getirdi. BD Makine Öğrenmesi ve Derin Öğrenme modelleri ile eğitim ve test işlemlerinin gerçekleştirdi. BD ve KK makaleyi birlikte oluşturdu.

Her iki yazar da makalenin son halini okudu ve onayladı.

### Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

### Veri Seti

Çalışmada kullanılan veri setine aşağıdaki bağlantıdan ulaşılabilmektedir;

<https://www.kaggle.com/datasets/1684654f84496eabe23b1728faab7cb9f687086d290f853978658746b65e65e8>

### Kaynaklar

- [1]. Gökdoğan,O., Isparta yöresinde yağ gülü yetiştiriciliğinin Türkiye ekonomisindeki yeri, Süleyman Demirel Üniversitesi Sos. Bilim. Enstitüsü Derg., 2013, 51–58.
- [2]. Dilmen, R., Baydar, N. G., Yağ Gülü (Rosa damascena Mill.)'nün mikroçoğaltımında en uygun sürgün ve köklenme ortamlarının belirlenmesi, Süleyman Demirel Üniversitesi Fen Bilim. Enstitüsü Derg., 2020, 24(1), 209-216.
- [3]. Baydar, H., Erbaş, S., Kıneci, S., Kazaz, S., Yağ gülü (Rosa damascena Mill.) damıtma suyuna katılan tween-20'nin taze ve fermente olmuş çiçeklerin gül yağı verimi ve kalitesi üzerine etkisi, Ziraat Fakültesi Derg., 2007, 2(1), 15-20.
- [4]. Mileva, M., Krumova, E., Miteva-Staleva, J., Kostadinova, N., Dobрева, A., Galabov, A.S., Chemical compounds, in vitro antioxidant and antifungal activities of some plant essential oils belonging to Rosaceae family, Compt. Rend. Acad. Bulg. Sci, 2014, 67(10), 1363-1368.
- [5]. Özkan, G., Sagdiç, O., Baydar, N.G., Baydar, H., Note: Antioxidant and antibacterial activities of Rosa damascena flower extracts, Food Sci. Technol. Int., 2004, 10(4), 277-281.
- [6]. Khosh-Khui, M., Biotechnology of scented roses: a review, Int. J. Hortic. Sci. Technol., 2014, 1(1), 1-20.
- [7]. Niazi, M., Hashempur, M.H., Taghizadeh, M., Heydari, M., Shariat, A., Efficacy of topical Rose (Rosa damascena Mill.) oil for migraine headache: A randomized double-blinded placebo-controlled cross-over trial, Complement. Ther. Med., 2017, 34, 35-41.
- [8]. Heydari, N., Abootalebi, M., Jamalimoghadam, N., Kasraeian, M., Emamghoreishi, M., Akbarzaded, M., Evaluation of aromatherapy with essential oils of Rosa damascena for the management of premenstrual syndrome, Int. J. Gynecol. Obstet., 2018, 142(2), 156-161.
- [9]. Dagli, R., Avcu, M., Metin, M., Kiyamaz, S., Ciftci, H., The effects of aromatherapy using

- rose oil (*Rosa damascena* Mill.) on preoperative anxiety: A prospective randomized clinical trial, *Eur. J. Integr. Med.*, 2019, 26, 37-42.
- [10]. Anonim, Tarım Ürünleri Piyasaları Gül, Tarım Ürünleri Piyasaları, 2021. [https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF Tarım Ürünleri Piyasaları/2021-Haziran Tarım Ürünleri Raporu/Gül, Haziran-2021, Tarım Ürünleri Piyasa Raporu, TEPGE.pdf](https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20Tarim%20Urunleri%20Piyasaları/2021-Haziran%20Tarim%20Urunleri%20Raporu/Gul,%20Haziran-2021,%20Tarim%20Urunleri%20Piyasa%20Raporu,%20TEPGE.pdf).
- [11]. Gorji-Chakespari, A., Nikbakht, A.M., Sefidkon, F., Ghasemi-Varnamkhasti, M., Brezmes, J., Llobet, E., Performance comparison of fuzzy ARTMAP and LDA in qualitative classification of iranian *rosa damascena* essential oils by an electronic nose, *Sensors*, 2016, 16(5), 636.
- [12]. Gorji Chakespari, A., Mohammad Nilbakht, A., Sefidkon, F., Ghasemi Varnamkhasti, M., Investigation of electronic nose system in classification of *Rosa damascena* Mill. essential oil by artificial neural network, *Iran. J. Med. Aromat. Plants Res.*, 2017, 33(3), 339-349.
- [13]. Sevli, O., Elma bitkisi hastalıklarının derin öğrenme ile tespiti, *Present. EUROASIA Int. Congr. Sci. Res. Recent Trends-IX*, 2022, 1(1), 339-346.
- [14]. De A. Rodrigues, D., Ivo, R. F., Satapathy, S. C., Wang, S., Hemanth, J., Reboucas Filho, P. P., A new approach for classification skin lesion based on transfer learning, deep learning, and IoT system, *Pattern Recognit. Lett.*, 2020, 136, 8-15.
- [15]. Patra, S., Middy, A. I., Roy, S., PotSpot: Participatory sensing based monitoring system for pothole detection using deep learning, *Multimed. Tools Appl.*, 2021, 80(16), 25171-25195.
- [16]. Pancholi, N., Goel, S., Nijhawan, R., Gupta, S., Classification and Detection of Acne on the Skin using Deep Learning Algorithms, in *2021 19th OITS International Conference on Information Technology (OCIT)*, 2021, 110-114.
- [17]. Ünal, Y., Öztürk, Ş., Dudak, M. N., Ekici, M., Comparison of Current Convolutional Neural Network Architectures for Classification of Damaged and Undamaged Cars, in *Advances in Deep Learning, Artificial Intelligence and Robotics*, Springer, 2022, 141-149.
- [18]. Vivek, P., Goel, S., Nijhawan, R., Gupta, S., CNN Models and Machine Learning Classifiers for Analysis of Goiter Disease, in *2022 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)*, 2022, 1-6.
- [19]. Malik, M., Ikram, A., Batool, S. N., Aslam, W., A performance assessment of rose plant classification using machine learning, in *International Conference on Intelligent Technologies and Applications*, 2018, 745-756.
- [20]. Köse, U., Zeki optimizasyon tabanlı destek vektör makineleri ile diyabet teşhisi, *Politek. Derg.*, 2019, 22(3), 557-566.
- [21]. Metlek, S., Kayaalp, K., Derin Öğrenme ve Destek Vektör Makineleri İle Görüntüden Cinsiyet Tahmini, *Düzce Üniversitesi Bilim ve Teknol. Derg.*, 2020, 8(3), 2208-2228.
- [22]. Vapnik, V. N., Lerner, A.Y., Recognition of patterns with help of generalized portraits, *Avtomat. i Telemekh*, 1963, 24(6), 774-780.
- [23]. Boser, B. E., Guyon, I. M., Vapnik, V. N., A training algorithm for optimal margin classifiers, in *Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory*, 1992, 144-152.
- [24]. Battineni, G., Chintalapudi, N., Amenta, F., Machine learning in medicine: Performance calculation of dementia prediction by support vector machines (SVM), *Informatics Med. Unlocked*, 2019, 16, 100200.
- [25]. Sui, X., Wan, K., Zhang, Y., Pattern recognition of SEMG based on wavelet packet transform and improved SVM, *Optik (Stuttg.)*, 2019, 176, 228-235.
- [26]. J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, A comprehensive survey on support vector machine classification: Applications, challenges and trends, *Neurocomputing*, 2020, 408, 189-215.
- [27]. Metlek, S., Kayaalp, K., Makine Öğrenmesinde, Teoriden Örnek MATLAB Uygulamalarına Kadar Destek Vektör Makineleri, *İksad Yayınevi*, 2020.

- [28]. Chang, Y.-W., Hsieh, C.-J., Chang, K.-W., Ringgaard, M., Lin, C.-J., Training and testing low-degree polynomial data mappings via linear SVM., *J. Mach. Learn. Res.*, 2010, 11(4).
- [29]. Chaudhuri, A., De, K., Fuzzy support vector machine for bankruptcy prediction, *Appl. Soft Comput.*, 2011, 11(2), 2472-2486.
- [30]. Sanjaa, B., Chuluun, E., Malware detection using linear SVM, in *Ifost*, 2013, 2, 136-138.
- [31]. Simonyan, K., Zisserman, A., Very deep convolutional networks for large-scale image recognition, *arXiv Prepr. arXiv1409.1556*, 2014.
- [32]. Neurohive, VGG16-Convolutional Network for Classification and Detection, 2018. <https://neurohive.io/en/popular-networks/vgg16/>.
- [33]. Krishnaswamy Rangarajan, A., Purushothaman, R., Disease classification in eggplant using pre-trained VGG16 and MSVM, *Sci. Rep.*, 2020, 10(1), 1-11.
- [34]. Swasono, D. I., Tjandrasa, H., Fathicah, C., Classification of tobacco leaf pests using VGG16 transfer learning, in *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, 2019, 176-181.
- [35]. Pravitasari, A. A., et al., UNet-VGG16 with transfer learning for MRI-based brain tumor segmentation, *Telkomnika*, 2020, 18(3), 1310-1318.
- [36]. Chhabra, M., Kumar, R., An Advanced VGG16 Architecture-Based Deep Learning Model to Detect Pneumonia from Medical Images, in *Emergent Converging Technologies and Biomedical Systems*, Springer, 2022, 457-471.
- [37]. Patilkulkarni, S., Visual speech recognition for small scale dataset using VGG16 convolution neural network, *Multimed. Tools Appl.*, 2021, 80(19), 28941-28952.
- [38]. Hridayami, P., Putra, I. K. G. D., Wibawa, K. S., Fish species recognition using VGG16 deep convolutional neural network, *J. Comput. Sci. Eng.*, 2019, 13(3), 124-130.
- [39]. Dubey, A. K., Jain, V., Automatic facial recognition using VGG16 based transfer learning model, *J. Inf. Optim. Sci.*, vol. 41, no. 7, pp. 1589–1596, 2020.
- [40]. Mateen, M., Wen, J., Song, S., Huang, Z., Fundus image classification using VGG-19 architecture with PCA and SVD, *Symmetry (Basel)*, vol. 11, no. 1, p. 1, 2018.
- [41]. Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F., Zhang, Y., Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery, *Remote Sens.*, vol. 10, no. 7, p. 1119, 2018.
- [42]. Rajinikanth, V., Joseph Raj, A. N., Thanaraj, K. P., Naik, G. R., A customized VGG19 network with concatenation of deep and handcrafted features for brain tumor detection, *Appl. Sci.*, 2020, 10(10), 3429.
- [43]. Zhou, J., Yang, X., Zhang, L., Shao, S., Bian, G., Multisignal VGG19 network with transposed convolution for rotating machinery fault diagnosis based on deep transfer learning, *Shock Vib.*, 2020, 2020.
- [44]. Awan, M. J. et al., Image-Based Malware Classification Using VGG19 Network and Spatial Convolutional Attention, *Electronics*, 2021, 10(19), 2444.
- [45]. Cheng, S., Zhou, G., Facial expression recognition method based on improved VGG convolutional neural network, *Int. J. Pattern Recognit. Artif. Intell.*, 2020, 34(07), 2056003.
- [46]. Subetha, T., Khilar, R., Christo, M. S., A comparative analysis on plant pathology classification using deep learning architecture-Resnet and VGG19, *Mater. Today Proc.*, 2021.
- [47]. Setiawan, W., Damayanti, F., Layers modification of convolutional neural network for pneumonia detection, in *Journal of Physics: Conference Series*, 2020, 1477(5), 52055.
- [48]. Szegedy, C. et al., Going deeper with convolutions, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, 1-9.
- [49]. Li, Y., Liu, L., Image quality classification algorithm based on InceptionV3 and SVM, in *MATEC Web of Conferences*, 2019, 277, 2036.
- [50]. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z., Rethinking the inception architecture for computer vision, in *Proceedings of the IEEE conference on computer vision*

- and pattern recognition, 2016, 2818-2826.
- [51]. Ali, L., Alnajjar, F., Al Jassmi, H., Gochoo, M., Khan, W., Serhani, M. A., Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures, *Sensors*, 2021, 21(5), 1688.
- [52]. Al Husaini, M. A. S., Habaebi, M. H., Gunawan, T. S., Islam, M. R., Elsheikh, E. A. A., Suliman, F. M., Thermal-based early breast cancer detection using inception V3, inception V4 and modified inception MV4, *Neural Comput. Appl.*, 2022, 34(1), 333-348.
- [53]. Tallapragada, V. V., Alivelu Manga, N., Nagabhushanam, M. V., Venkatanaresh, M., Greek Handwritten Character Recognition Using Inception V3, in *Smart Systems: Innovations in Computing*, Springer, 2022, 247-257.
- [54]. Jaithavil, D. Triamlumlerd, S., Pracha, M., Paddy seed variety classification using transfer learning based on deep learning, in *2022 International Electrical Engineering Congress (iEECON)*, 2022, 1-4.
- [55]. Duman, B., Özsoy, K., Toz yatak füzyon birleştirme eklemeli imalatta kusur tespiti için öğrenme aktarımı kullanan derin öğrenme tabanlı bir yaklaşım, *Gazi Üniversitesi Mühendislik Mimar. Fakültesi Derg.*, 2022, 37(1), 361-376.
- [56]. Awais, M., et al., Can pre-trained convolutional neural networks be directly used as a feature extractor for video-based neonatal sleep and wake classification?, *BMC Res. Notes*, 2020, 13(1), 1-6.
- [57]. Noor, F. N. M., et al., The Diagnosis of Diabetic Retinopathy: A Transfer Learning with Support Vector Machine Approach, in *International Conference on Innovative Technology, Engineering and Science*, 2020, 391-398.
- [58]. Gour, M., Jain, S., Sunil Kumar, T., Residual learning based CNN for breast cancer histopathological image classification, *Int. J. Imaging Syst. Technol.*, 2020, 30(3), 621-635.
- [59]. Abhishek, A., Jha, R., Sinha, K.R., Jha, K., Automated classification of acute leukemia on a heterogeneous dataset using machine learning and deep learning techniques, *Biomed. Signal Process. Control*, 2022, 72, 103341.
- [60]. Srivastava, S., Kumar, P., Mohd, N., Singh, A., Gill, F. S., A Novel Deep Learning Framework Approach for Sugarcane Disease Detection, *SN Comput. Sci.*, 2020, 1(2), 1-7.