

Yağ Gülü Hasat Durumunun Belirlenmesi için Siyam Sinir Ağları: Yeni Nesil Bir Bitki Tanıma Sistemi

Birkan BÜYÜKARIKAN^{1*}

¹ Bilgisayar Teknolojileri Bölümü, Uluborlu Selahattin Karasoy Meslek Yüksekokulu, Isparta Uygulamalı Bilimler Üniversitesi, Isparta, Türkiye
* birkanbuyukarikan@isparta.edu.tr

(Geliş/Received: 15/04/2024;

Kabul/Accepted: 7/8/2024)

Öz: Bitki biliminde önemli bir alan olan yağ gülünün hasat durumunu belirlemek, doğal yaşamın anlaşılması ve korunmasında kritik bir rol oynar. Geleneksel yöntemlerle yağ gülünün hasat durumunun sınıflandırılması ve tanınması oldukça karmaşıktır. Bu problemi çözmek amacıyla Evrişimsel Sinir Ağı (ESA) tabanlı yaklaşımlar, yağ gülünün hasat durumunu belirlemede başarılı sonuçlar sergilemiştir. Ancak, veri setindeki görüntü sayısının az olması, ESA yaklaşımlarının istenilen performans seviyesine ulaşmalarını engellemektedir. ESA'nın bir türü olan Siyam Sinir Ağları (SSA), bu zorluğa yenilikçi bir çözüm sunmaktadır. SSA, her bir görüntüyü tanımlayan benzersiz özellik vektörlerini çıkartmakta ve daha sonra bu özellik vektörleri bir mesafe ölçütü kullanılarak karşılaştırılmaktadır. Sonuç, benzerlik veya farklılık skoruna göre değerlendirilmektedir. Çalışmanın amacı, SSA ile yağ gülü bitkisinin hasat durumunun belirlenmesidir. Çalışmada modellerin değerlendirilmesinde önceden eğitilmiş VGG16 ve VGG19 modelleriyle birlikte farklı kayıp fonksiyon modelleri ile optimizasyon yöntemlerinin kombinasyonları değerlendirilmiştir. Çalışmada Kosinüs benzerliği mesafe ölçütü olarak kullanılmıştır. Deneyle, herkese açık bir veri seti olan Isparta Gulu (Rosa Damascena Mill.)'nde gerçekleştirilmiştir. Yağ gülü hasat durumu sınıflandırma doğruluğu en yüksek, önerilen SSA-VGG19, Karşılaştırmalı kayıp fonksiyonu ve RMSprop optimizasyon modelindedir. Önerilen bu modelin doğruluk değeri 0,986 ve eğri altında kalan alan (AUC) değeri 0,990 oranlarındadır. Deneyle, yağ gülü hasat durumunun tespitinde önerilen modelin etkili olduğu göstermektedir.

Anahtar kelimeler: Yağ gülü, hasat durumu belirleme, siyam sinir ağları.

Siamese Neural Networks for Determining Oil Rose Harvest Status: A Next-Generation Plant Recognition System

Abstract: Determining the harvest status of oil roses, an important area of botany, plays a critical role in understanding and conserving natural life. Traditional methods for classifying and detecting the harvest status of oil roses are quite complex. To solve this problem, Convolutional Neural Network (CNN)-based approaches have shown successful results in determining the harvest status of oil roses. However, the small number of images in the data set prevents CNN approaches from achieving the desired level of performance. Siamese Neural Networks (SNN), a type of CNN, provides an innovative solution to this challenge. SNNs extract unique feature vectors describing each image and then compare these feature vectors using a distance metric. The result is evaluated based on a similarity or difference score. The aim of this study is to use SNNs to determine the harvest status of the oil rose plant. In this study, different combinations of pre-trained VGG16 and VGG19 models with different loss function models and optimization methods were evaluated. Cosine similarity was used as the distance metric. The experiments were conducted on the publicly available Isparta Gulu (Rosa Damascena Mill.) data set. The highest accuracy for the classification of the harvest status of oil roses was achieved with the proposed SSN-VGG19, Contrastive loss function and RMSprop optimization model. The accuracy of the proposed model is 0.986 and the area under the curve (AUC) is 0.990. The experiments indicate that the proposed model is effective in detecting the harvest status of oil roses.

Key words: Oil rose, harvest status determination, siamese neural networks.

1. Giriş

Tıbbi ve aromatik bir bitki olan yağ gülü, gül yağı elde etmek için kullanılan önemli bir gül türüdür. Bu eşsiz bitkiden elde edilen gül yağı, gıda, sağlık ve kozmetik endüstrilerinde kullanılan vazgeçilmez bir hammaddedir [1]. Ancak, yağ gülünden kaliteli yağ elde edilmesi doğru hasat zamanına bağlıdır. Ne var ki, gül hasadı halen daha geleneksel yöntemlerle diğer bir deyişle insan gücüyle gerçekleştirilmektedir. Zamanında hasadın gerçekleştirilememesi, ürün kalitesini olumsuz yönde etkileyebilmektedir. Bu bağlamda, hasat işleminin zamanında gerçekleşmesi için akıllı hasat sistemlerinin benimsenmesi ve uygulanması önemlidir [2]. Bu sistemler, kaliteli ürünler elde etmek için insan emeği kullanımını minimize eder ve bu sistemlerde modern teknolojilerin

* Sorumlu yazar: birkanbuyukarikan@isparta.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-9703-9678

kullanımıyla verimlilik artar [3]. Bitkinin hızlı, doğru ve otomatik olarak tanınmasına olanak tanıyan bu sistemler, geleneksel ve son teknoloji yöntemler yardımıyla çözümler sunar [4].

Araştırmalarda, geleneksel el yapımı özellik çıkarma yöntemleriyle bitki görüntülerinden elde edilen özelliklerin tanımlanması ve sınıflandırılması için klasik makine öğrenmesi (MÖ) metodları tercih edilmiştir. Bu yöntemle yapılan bitki sınıflandırma işlemi; ön işleme, özellik çıkarma ve sınıflandırma gibi adımları içerir [5]. Bu yöntemleri kullanan gül bitkisiyle ilgili araştırmalarda, genellikle yapraklardan gül türü ve hastalıklar sınıflandırılmıştır. Burada, el yapımı özellik çıkarma yöntemleriyle sınıflandırma görevi gerçekleştirilmiştir. Örneğin, [6] çalışmalarında toplamda 100 görüntüden oluşan dört farklı gül bitkisi türünü sınıflandırmak için MÖ'yu kullanmışlardır. Önerdikleri çalışmada en yüksek sınıflandırma doğruluğu, %65 oranıyla k-en yakın komşu algoritmasındadır. [7] gül yapraklarının histogram ve doku özelliklerini MÖ tabanlı metodlarla sınıflandırmışlardır. Önerdikleri çalışmada, rastgele orman (RO) modelinin, kullanılan diğer modellere göre daha iyi performans sonuçları sergilediğini belirtmişlerdir. [8] gül yaprağından hastalıkların tespiti için MÖ kullanmışlar ve RO modelinde etkili sonuçlar elde ettiklerini ifade etmişlerdir. [9] gül yapraklarından çıkarılan özellikleri MÖ ile sınıflandırmışlardır. [10] çalışmalarında gül toplamak için MÖ tabanlı bir tarım robotu geliştirmişlerdir.

Son 5 yıldaki araştırmalarda, derin öğrenme tabanlı bitki görüntüsünün sınıflandırılması, bitkinin hızlı, doğru ve otomatik olarak tanınması uygulamalarında umut verici sonuçlar ortaya koymuştur [11]. Bu avantajı kullanan araştırmacılar, gül bitkisini sınıflandırmak için derin öğrenme mimarilerinden evrimsel sinir ağlarını (ESA) başarıyla uygulamışlardır. Örneğin, [2] yağ güllü bitkisinin hasat durumunu belirlemek için destek vektör makineleri, VGG16, VGG19 ve InceptionV3 modellerini kullanmışlardır. Önerdikleri VGG19 modeli %97,96 oranında doğruluk elde etmiştir. Önerdikleri çalışmada, hasat edilebilir ve hasat edilemez olmak üzere ikili sınıflandırma kullanılmıştır. [12] taze kesilmiş gülün kalitesine ilişkin gerçek zamanlı bir uygulama geliştirmişlerdir. Önerdikleri çalışma, ShuffleNet V2 mimarisi temeline dayanmakta ve bu mimariyle %98,891 ile %99,915 oranları arasında bir sınıflandırma doğruluğu elde etmişlerdir. [13] farklı gül türlerini sınıflandırmak için ESA ve RO birleşiren bir model kullanmışlardır. Önerdikleri yaklaşımda toplam 5367 görüntü kullanılmış ve ortalama kesinlik değerinin %91,76 oranında olduğunu belirtmişlerdir. [14] gül türlerini sınıflandırmak için ESA kullanmışlar ve önerdikleri ESA modeli %85 doğruluk göstermiştir. Önerdikleri çalışmada, gül türü sınıf sayısının altı olduğunu belirtmişlerdir. Az sayıda olan bu çalışmalar, gül bitkisinin hasat durumunu belirlemede henüz yeterince araştırılmadığını göstermektedir. Özellikle, gül bitkisinin hasat durumunun ve gül kalitesinin belirlenmesine yönelik araştırmalarda ESA'nın kullanılması, gelecekteki çalışmalar için önemli bir potansiyel sunmaktadır.

ESA, genellikle eğitim sürecinde çok derin ağlar kullanmaları nedeniyle yüksek hesaplama gücüne ve büyük etiketli verilere gereksinim duyar [5]. Ancak, ESA az sayıda veriyle eğitildiğinde, model genellikle başarısız sonuçlar üretebilir. Siyam sinir ağları (SSA), bitki tanıma sistemlerinde yeni bir nesil teknoloji olarak öne çıkmaktadır. ESA'nın bir türü olan SSA, az sayıdaki örnekle bile başarı sağlayabilen bir modeldir [15-18]. Ayrıca, ESA veri setindeki görüntülerin hangi sınıfa ait olduğunu dikkate alırken, SSA örnek çitlerinin birbirine benzeyip benzemediğine odaklanır [18]. SSA, ulusal ve uluslararası literatürde birçok alanda kullanılan bir araştırmadır. Genellikle imza tanıma [19], yazı karakteri tanıma [20, 21] ve kişi doğrulama [18] gibi kişisel bilgilerin kullanıldığı çalışmalarda SSA'nın uygulandığı görülmektedir. Ayrıca, görüntülerden kusur tespiti [22] ve hastalık tespitinin [15, 23-25] yanı sıra, son zamanlarda tarım alanında bitki hastalığının tespiti [5, 26] gibi çalışmalarda da SSA'nın kullanımı bu çalışmanın çıkış noktasını oluşturmaktadır.

Bu çalışmada, yağ güllü bitkisinin hasat durumunun belirlenmesi için SSA'nın kullanımı incelenmiştir. Çalışmada, Kaggle'den elde edilen Isparta Gulu (Rosa Damascena Mill.) veri seti üzerinde gerçekleştirilen analizlerle, SSA'nın potansiyelinin ortaya çıkarılması hedeflenmektedir. Bu veri seti toplanabilir ve toplanamaz olmak üzere iki sınıftan oluşmaktadır. Çalışmada, öncelikle veri setindeki görüntülerin arka planları çıkarılmıştır. Daha sonra, bazı anlamsız görüntülerin veri setinden silinmesi sonucunda 877 görüntü (241 toplanamaz ve 636 toplanabilir) üzerinde uygulama gerçekleştirilmiştir. Veri setindeki görüntüler %80 eğitim ve %20'si test olacak şekilde ayrılmış ve eğitim ile test setleri için görüntü çiftleri oluşturulmuştur. Çalışmada VGG16 ve VGG19 modelleri SSA'nın yapısına göre yeniden düzenlenmiştir. Görüntüleri karşılaştırmak için mesafe ölçütü olarak Kosinüs benzerliği, kayıp fonksiyonu için İkili çapraz entropi (Binary cross-entropy) ile Karşılaştırmalı kayıp (Contrastive loss) modelleri ve optimizasyon yöntemi için de Adam, Adamax, Nadam ve RMSprop fonksiyonlarının kombinasyonları kullanılmıştır.

Bu çalışma, yağ güllü hasat sürecini modernize etmek ve bitki tanıma sistemlerini geliştirmek için bir adım olacaktır. Küçük ve sınıf dengesizliğine sahip yağ güllü görüntülerinden hasat durumunu belirlemek için SSA'nın kullanılması, bu çalışmanın önemli bir katkısını oluşturur.

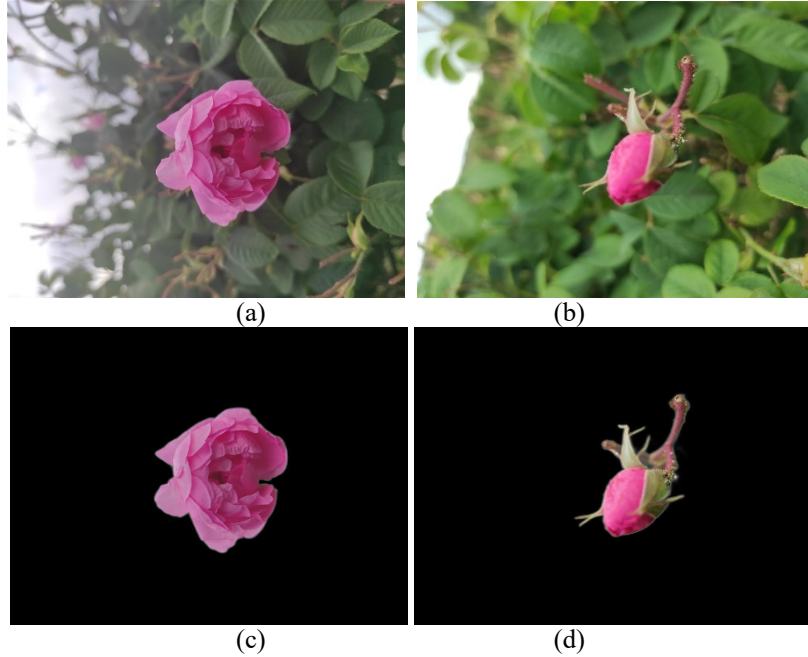
2. Materyal ve Yöntem

Bu bölüm, veri seti ve üzerinde uygulanan ön işlemleri, SSA'nın temelini, önerilen sınıflandırıcı yaklaşımı ve değerlendirme ölçütlerini içerir. Tüm bu içerikler sırasıyla alt başlıklar altında toplanmıştır.

2.1. Veri seti ve ön işleme

Çalışmada, herkese açık olarak Kaggle platformunda bulunan Isparta Gulu (*Rosa Damascena* Mill.) veri seti kullanılmıştır [27]. Veri setindeki görüntüler, Isparta ili Atabey, Gönen, Keçiborlu ve Merkez ilçelerindeki gül bahçelerinden, 64 MP kamera çözünürlüğüne sahip olan Xiaomi Redmi Note 9 Pro cep telefonu kamerasıyla elde edilmiştir. Görüntüler 2021 yılı mayıs ayında, farklı günlerde (güneşli ve bulutlu hava koşulları), farklı yükseklik ve açılardan çekilmiştir. Kaggle'dan indirilen veri setindeki 961 görüntünün, 282'si hasat edilemez (toplanamaz) ve 679'u hasat edilebilir (toplanabilir) şeklindedir [2]. Veri setinde toplanamaz sınıfı tüm görüntülerin yaklaşık %29'unu ve toplanabilir sınıfı ise tüm görüntülerin yaklaşık %71'ini oluşturmaktadır. Dolayısıyla veri setindeki sınıflar arasında herhangi bir denge bulunmamaktadır. Şekil 1'de, veri setinde toplanabilir ve toplanamaz yağ gülü bitki sınıfına ait örnekler görülmektedir (Şekil 1a ve Şekil 1b).

SSA modellerinin sadece görüntülerdeki yağ güllerine odaklanabilmesi için görüntülerin arka planlarının kaldırılması önemlidir. Veri setindeki görüntülerin arka plandan ayrılması için U2-Net tabanlı rembg fonksiyonu kullanılmıştır (Şekil 1c ve Şekil 1d). Arka plan çıkarılması sonucunda bazı görüntülerden anlamlı sonuçlar elde edilememiş, dolayısıyla bu görüntüler veri setinden çıkarılmıştır. Bu bağlamda, 877 görüntü içeren yeni veri setinin toplanamaz sınıfında 241 ve toplanabilir sınıfında 636 görüntü bulunmaktadır. Bu yeni veri setindeki görüntülerin yaklaşık %28'si toplanamaz ve yaklaşık %72'sini toplanabilir sınıfını oluşturmaktadır. Daha sonra bu veri setindeki görüntüler 224 x 224 x 3 piksel boyutuna uyarlanarak, %80'i eğitim seti ve %20 test seti olacak şekilde ayarlanmıştır. Ardından görüntüler 1/255 oranında ölçeklendirilmiştir. Son olarak, SSA yapısı için eğitim ve test setleri hedef görüntü ile referans görüntü olacak şekilde ilişkilendirilerek ikili çiftler oluşturulmuştur.



Şekil 1. Isparta Gulu (*Rosa Damascena* Mill.) veri seti, (a) Toplanabilir (orijinal görüntü), (b) Toplanamaz (orijinal görüntü), (c) Toplanabilir (arka planı silinmiş), (d) Toplanamaz (arka planı silinmiş).

2.2. Siyam sinir ağları (SSA)

SSA, aynı ağırlık ve mimariyi paylaşan iki simetrik sinir ağ yapısıdır. Bu özel yapı, iki örneği girdi olarak alır ve ESA yardımıyla görüntülere ait özellik vektörlerini çıkarır. İki örnek arasındaki benzerlik veya farklılığın öğrenilmesi, genellikle özellik vektörleri arasındaki mesafenin bir ölçüt yardımıyla ölçülmesine dayanır [26, 28]. Literatürde Öklid mesafesi, Manhattan mesafesi, Minkowski mesafesi ve Kosinüs benzerliği gibi ölçütler bulunmaktadır. Çalışmalarda özellikleri temsil eden bu vektörler arasındaki benzerlik veya farklılıkları ölçmek


için yaygın olarak Kosinüs benzerliği kullanılır [29]. Kosinüs benzerliği, özellikler arasındaki açıyı ölçen bir ölçüttür. Bu çalışmada, Kosinüs benzerliği yardımıyla özellikler arasındaki benzerlikler ölçülmüştür.

Şekil 2, SSA tabanlı yağ güllü hasat durumunu tanımayı yönelik genel bir bakış sunmaktadır. Önerilen SSA, aynı anda iki farklı yağ güllü görüntüsünü girdi olarak alan iki alt ağdan oluşmaktadır. Her iki alt ağdan elde edilen çıktı özellikleri, karar verme sürecinde kullanılan Kosinüs benzerlik ölçütüyle karşılaştırılır. Bu benzerliğin hesaplanmasına ilişkin formül, Denklem 1’de verilmiştir.

$$d(F(X1), F(X2)) = \frac{F(X1).F(X2)}{\|F(X1)\|\|F(X2)\|} \quad (1)$$

Denklem 1’de, ilk yağ güllü görüntüsünün (X1) özellik vektörünü F(X1) ve İkinci yağ güllü görüntüsünün (X2) özellik vektörünü F(X2) ifade eder. Burada X1 ve X2 oluşturulan görüntü çiftidir.

Şekil 2’de de görüldüğü gibi, X1 ESA modelindeki evrişim katmanlarından ve tam bağlantılı bir katmandan geçtikten sonra bir özellik vektörü (F(X1)) elde edilir. X2, aynı katmanları, ağırlıkları ve parametreleri paylaşan ESA modelinden geçirilir ve ardından ikinci özellik vektörü (F(X2)) çıkarılır. Daha sonra özellik vektörleri arasındaki Kosinüs benzerliği hesaplanarak karşılaştırılır [30]. Burada, F(X1) ve F(X2) benzerse Kosinüs benzerliği yüksek, F(X1) ve F(X2) farklıysa Kosinüs benzerliği de düşüktür.



Şekil 2. SSA'nın genel anlatımı.

2.3. Önerilen yöntemin genel çerçevesi

Duman ve Kayaalp özellikle VGG16 ve VGG19 gibi derin öğrenme yöntemlerinin, yağ güllü bitkisinin hasat durumunun otomatik olarak tespit edilmesinde oldukça etkili olabileceğini belirtmişlerdir [2]. Dolayısıyla çalışmada önceden eğitilmiş farklı ESA modelleri denenmiş ancak yağ güllü hasat durumunun belirlenmesi için çalışmada VGG16 ve VGG19 modelleri tercih edilmiştir [2, 31]. VGG16 ve VGG19 modelleri derinlik ile ağırlık yeteneği arasındaki ilişkiyi temsil etmek için sırasıyla 16 ve 19 derinlik katmanı üzerine kurulmuştur. VGG16, 13 evrişim katmanına ve VGG19, 16 evrişim katmanına sahiptir. Bunlara 3 tam bağlantılı katman eklenerek modeller oluşturulmuştur. Genel olarak, VGG16 ve VGG19 modellerinin tam bağlantılı katmanlarındaki nöron sayıları sırasıyla 4096, 4096 ve 1000'dir [32].

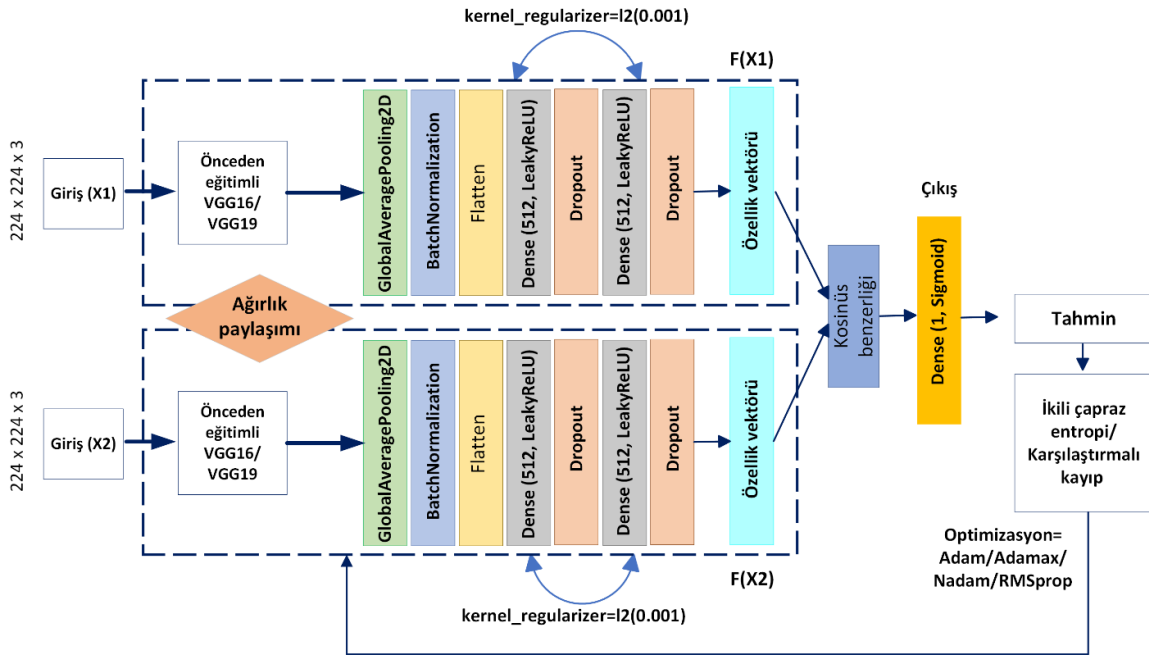
Şekil 3, aynı ağırlık, parametre ve mimariyi paylaşan iki simetrik sinir ağı yapısına sahip, SSA yaklaşımının detaylarını sunmaktadır. Çalışmada VGG16 ve VGG19 modelleri üzerinde ince ayar yapılarak eğitim süreci gerçekleştirilmiştir. İlk olarak, önceden eğitilmiş modellerin tüm katmanları dondurulmuştur. Daha sonra bu modellere küresel ortalama havuzlama (GlobalAveragePooling2D), yığın normalleştirme (BatchNormalization) ve düzleştirici (Flatten) [33] katmanları eklenmiştir. Bu katmanları, 512 nöronlu ve 128 nöronlu Dense katmanları takip etmektedir. Her iki Dense katmanından sonra 0,5 oranında seyreltme katmanı eklenmiştir. Burada, küresel ortalama havuzlama katmanı, özellik haritalarının doğrusal dönüşümleri yapması ve yığın normalleştirme katmanı, eğitim süresinin azaltılması ve modelin daha iyi performans sergilemesi için kullanılmıştır.

ESA modellerinin Dense katmanlarında genellikle ReLU aktivasyon fonksiyonu kullanılsa da ölü nöron problemiyle başa çıkmak için bu çalışmada aktivasyon fonksiyonu olarak LeakyReLU tercih edilmiştir. Bu aktivasyon fonksiyonu Denklem 2’de görülmektedir [34]. Ayrıca, çalışmada aşırı uyum problemini azaltmak için çekirdek düzgünleştirici olarak L2 fonksiyonu kullanılmıştır. Çalışmada, L2 düzenlemesinin değeri 0,001’dir.

$$LeakyReLU = \begin{cases} x, & x \geq 0 \\ 0.01 * x & x \leq 0 \end{cases} \quad (2)$$

Denklem 2’de, x girdi değerini ifade eder.

Tüm bu katmanlardan elde edilen özellikler, Kosinüs benzerlik ölçütüyle (Denklem 1) ayırt edildiği bir benzerlik kontrolünden geçirilmiştir. Ayırt edilen özellik, verilen girdiye benzer veya farklı olup olmadığını gösteren bir Sigmoid fonksiyonuyla son katmana iletilmiştir. Son katman, 1 nöronlu bir Dense katmandır. Sonuç olarak, Sigmoid aktivasyon fonksiyonuyla 0-1 değer aralığında bir çıkış değeri üretilir. Bu çıkış değeri, iki girdinin birbirine anlamsal olarak ne kadar benzeyip benzemediğini belirtir.



Şekil 3. Önerilen yöntemin ağ yapısı.

Deneylerde kayıp fonksiyonları olarak İkili çapraz entropi ve Karşılaştırmalı kayıp tercih edilmiştir. Bu kayıp fonksiyonlarına ilişkin formüller sırasıyla Denklem 3 ve Denklem 4’te görülmektedir [34].

$$Kayıp = -(y \log(d) + (1 - y) \log(1 - d)) \quad (3)$$

$$Kayıp = yd^2 + (1 - y) \max(marj - d, 0)^2 \quad (4)$$

Denklem 3 ve Denklem 4’te, d gerçek ve y tahmin edilen çıktıyı ifade eder. Burada marj değeri 1 olarak tanımlanan bir sabittir.

Maliyet fonksiyonunu en aza indirmek ve model parametrelerini azaltmak için eğitim aşaması, Adam, Adamax, Nadam ve RMSprop optimizasyon algoritmalarıyla gerçekleştirilmiştir. Tüm modeller 100 devirde eğitilmiştir. Çalışmada yığın boyutu 64, ilk öğrenme oranı 0,001 ve ağırlık azalma katsayısı 1e-6 olarak seçilmiştir. Önerilen yaklaşımda kullanılan parametreler ve bu parametrelerin değeri Tablo 1’de listelenmiştir.

Tablo 1. Modellerin parametre ve değerleri.

Parametre	Değerler
Görüntü boyutu	224 x 224 x 3
Model	VGG16 ve VGG19
Aktivasyon fonksiyonu	LeakyReLU
Çekirdek düzgünleştirici	L2=0,001
Optimizasyon yöntemi	Adam, Adamax, Nadam ve RMSprop
Öğrenme oranı	0,001
Ağırlık azalma katsayısı	1e-6
Devir sayısı	100
Yığın boyutu	64
Kayıp fonksiyonu	İkili çapraz entropi ve Karşılaştırmalı kayıp

2.4. Performans değerlendirme

Çalışmanın performansının ölçülmesi için doğruluk (Denklem 5), kesinlik (Denklem 6), duyarlılık (Denklem 7) ölçütleri karışıklık matrisinden elde edilen doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) değerlerine göre belirlenmiştir.

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

$$\text{kesinlik} = \frac{DP}{DP+YP} \quad (6)$$

$$\text{duyarlılık} = \frac{DP}{DP+YN} \quad (7)$$

Modellerin sınıfları tahmin olasılık değerlerinin avantaj ve dezavantajlarını belirlemek için alıcı işlem karakteristiği (Receiver Operating Characteristic, ROC) eğrisi kullanılabilir. Eğrideki sınıflandırıcıların performansları, eğri altında kalan alan (AUC) değerine göre değerlendirilmiştir. AUC değeri, 1'e ne kadar yakında sınıflandırma performansı da o kadar güçlüdür [26]. Denklem 8, AUC değerinin hesaplanması için kullanılır.

$$AUC = \frac{1}{2} * \frac{DP}{DP+YN} + \frac{DN}{DN+YP} \quad (8)$$

Eğitim için modelin kesin genelleştirme farkının bilinmesi için Ortalama Kare Hatası (Mean Squared Error, MSE) kullanılabilir [23]. Çalışmada önerilen modellerin performansı; doğruluk, MSE, karışıklık matrisi, ROC eğrisi, AUC değeri, Kesinlik-Duyarlılık grafiğine göre incelenmiştir.

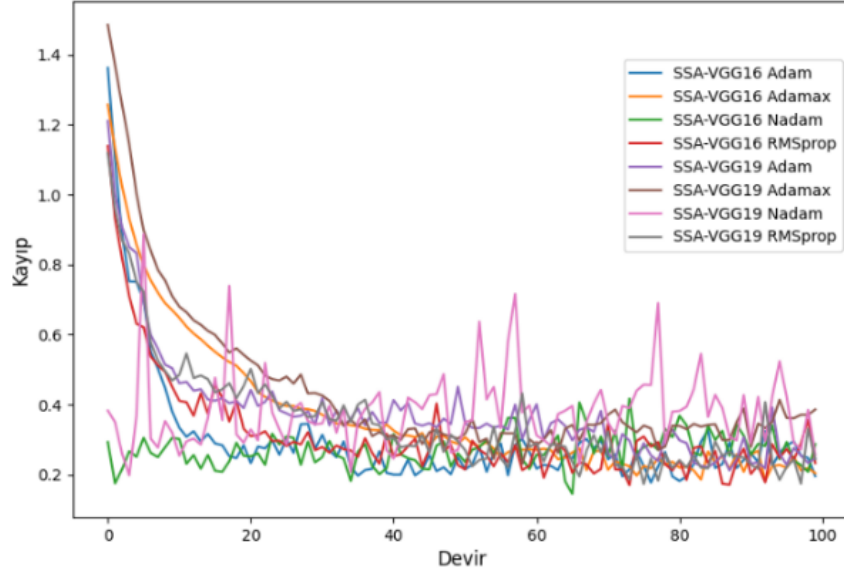
3. Deneysel Sonuçlar ve Tartışma

Bu çalışmada toplanabilir ve toplanamaz yağ güllü bitkisine ait görüntülerin bulunduğu Isparta Gulu (Rosa Damascena Mill.) veri seti kullanılmıştır. Çalışmanın ön işlem aşamasında, veri setindeki görüntülerin arka planları çıkarılmıştır ve deneylerde 877 adet görüntü kullanılmıştır. Çalışmada önceden eğitilmiş VGG16 ve VGG19 modelleri kullanılmış ve tüm deneysel çalışmalar Python dili ile Google Colab yazılımında gerçekleştirilmiştir.


3.1. Deneysel sonuçlar

ESA modellerinin SSA ile yeniden değerlendirilmesi sonucunda oluşturulan SSA-VGG16 ve SSA-VGG19 modellerinin, test seti kayıp ve doğruluk değerlerinin grafikleri Şekil 4 ve Şekil 5'te verilmiştir. Buna göre; Şekil 4a ile 4b kayıp ve 5a ile 5b doğruluk grafiklerini göstermektedir. Rastgele sonuçların deney sonuçları üzerindeki etkisini en aza indirmek için kayıp fonksiyonu ve optimizasyon yöntemlerine göre kombinasyonlar oluşturularak SSA-VGG16 ve SSA-VGG19 modelleri eğitilmiştir.

Şekil 4a'dan da görüleceği üzere, İkili çapraz entropi modeliyle oluşturulan tüm SSA modellerinde dalgalanmalar büyüktür. Dalgalanmaların bu kadar fazla olması öğrenme davranışının devirler boyunca devam ettiğini göstermektedir. Diğer taraftan Şekil 4b görüldüğü gibi, Karşılaştırmalı kayıp modeliyle oluşturulan SSA modellerinde dalgalanmalar nispeten daha düşüktür.



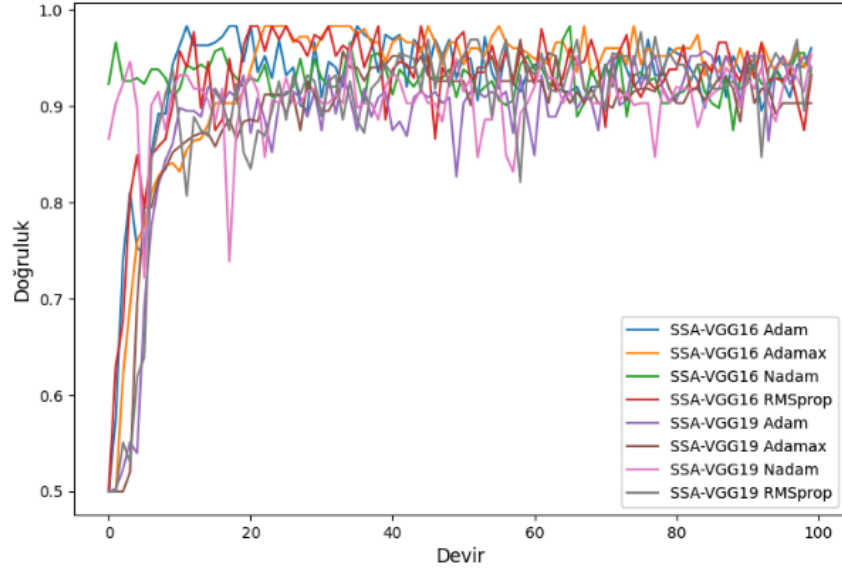
(a)




(b)

Şekil 4. SSA modellerinin kayıp grafikleri, (a) İkili çapraz entropi kayıp grafiği, (c) Karşılaştırmalı kayıp grafiği.

Doğruluk grafiklerine göre (Şekil 5a ve Şekil 5b), modellerin doğruluk değerleri yaklaşık olarak 20. Devire kadar hızlı bir şekilde artmıştır. Dalgalanmaların devirler boyunca devam etmesinin sebebinin eğitim ve test setlerinin ayrılması sırasındaki dağılımından kaynaklandığı düşünülmektedir. Ayrıca sınıflar arasında verilerin dağılım dengesinin olmaması da dalgalanmaların arttığını gösterebilir.



(a)



(b)

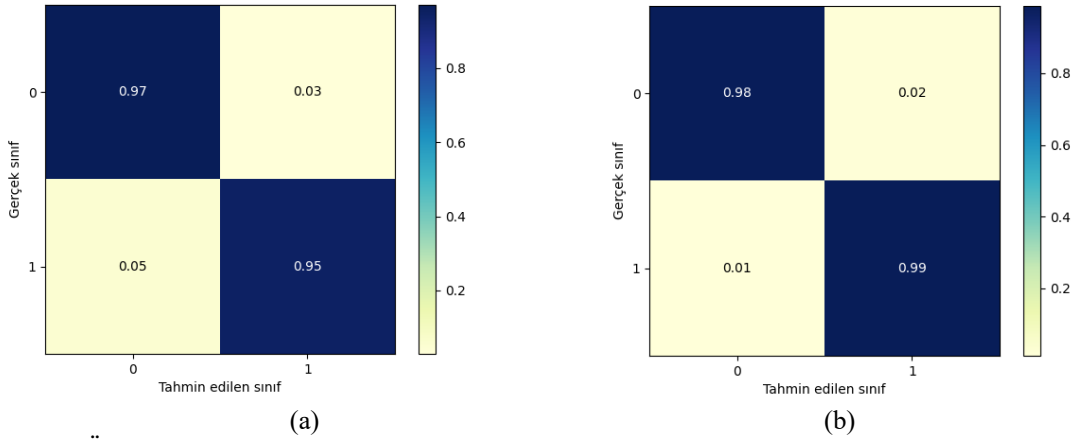
Şekil 5. SSA modellerinin doğruluk grafikleri, (a) İkili çapraz entropi doğruluk grafiği, (b) Karşılaştırmalı doğruluk grafiği.

VGG16 ve VGG19 modellerinin farklı optimizasyon yöntemleri ve kayıp fonksiyonlarına göre değerlendirilmesine ilişkin sınıflandırma performans sonuçları Tablo 2’de listelenmiştir. Modellerin değerlendirilmesinde benzerlik ölçütü olarak Kosinüs benzerliği kullanılmıştır. İkili çapraz entropi modeli, SSA-VGG16 ile Adam optimizasyon yöntemi ve Karşılaştırmalı kayıp modeli, SSA-VGG19 ile RMSprop yöntemi diğer modellere göre daha iyi performans sonuçları göstermiştir. SSA-VAGG16 Adam optimizasyon yönteminde doğruluk, kayıp ve MSE değerleri sırasıyla 0,906, 0,250, 0,040 ve SSA-VGG19 ve RMSprop yönteminde doğruluk, kayıp ve MSE değerleri sırasıyla 0,986, 0,056, 0,014’tür. Son olarak, İkili çapraz entropi modelinde kayıp değeri Karşılaştırmalı kayıp modeline göre daha yüksektir.

Tablo 2. Modellerin farklı kayıp modellerine göre sınıflandırma performans sonuçları, En iyi sonuçlar koyu yazı tipindedir.


Model	Optimizasyon	İkili çapraz entropi				Karşılaştırmalı kayıp			
		Doğruluk	Kayıp	MSE	Süre (s)	Doğruluk	Kayıp	MSE	Süre (s)
SSA-VGG16	Adam	0,960	0,250	0,040	1644,24	0,932	0,047	0,068	1629,07
	Adamax	0,952	0,307	0,048	1712,91	0,972	0,099	0,028	1741,46
	Nadam	0,932	0,261	0,068	1555,31	0,938	0,077	0,063	1704,27
	RMSprop	0,932	0,210	0,068	1791,92	0,972	0,108	0,28	1731,60
SSA-VGG19	Adam	0,940	0,347	0,060	1912,34	0,946	0,077	0,054	1905,42
	Adamax	0,903	0,300	0,097	1956,36	0,926	0,098	0,074	1811,25
	Nadam	0,955	0,271	0,045	1940,82	0,940	0,063	0,060	1748,55
	RMSprop	0,938	0,270	0,063	1944,47	0,986	0,056	0,014	1935,70

Önerilen sınıflandırıcı modellerin performans ve hata durumunu belirlemek için karışıklık matrisleri kullanılmıştır. Şekil 6'da kayıp fonksiyonlarına göre en yüksek doğruluk sonucu gösteren modellerin sonuçları verilmiştir. Burada, 0 etiketi toplanamaz yağ gülü sınıfını ve 1 etiketi ise toplanabilir yağ gülü sınıfını ifade etmektedir. Şekil 6a'da toplanamaz yağ gülü sınıfını 0,97 değerindeki yüksek bir oranla tahmin etmiştir. Şekil 6b'de ise toplanamaz ve toplanabilir yağ gülü sınıfları yüksek bir oranla tahmin edilmiş. Önerilen model neredeyse tüm sınıfları doğru bir şekilde tahmin ettiği görülmektedir.




Şekil 6. Önerilen modellerin karışıklık matrisleri, (a) SSA-VGG16 ikili çapraz entropi modeli ve Adam optimizasyon yöntemi karışıklık matrisi, (b) SSA-VGG19 karşılaştırmalı kayıp modeli ve RMSprop optimizasyon yöntemi karışıklık matrisi.

Önerilen sınıflandırıcı modellerin genel performanslarını değerlendirmek için modellerin ROC grafikleri incelenebilir. Bu grafikte, eğri ne kadar sol üste yakında model o kadar iyi performans sunmaktadır. Diğer bir ifadeyle ROC eğrisi altında kalan alan 1 değerine ne kadar yakınsa veya yüksekse sınıfların ayrılması daha iyi olduğu söylenebilir. Kayıp değerlerine göre en yüksek doğruluk elde eden modellerin ROC eğrisi grafikleri Şekil 7'de verilmiştir. SSA-VGG16 İkili çapraz entropi ve Adam optimizasyon modelinin (Şekil 7a) elde ettiği AUC değeri 0,96 ve SSA-VGG19 Karşılaştırmalı kayıp ve RMSprop optimizasyon modelinin (Şekil 7b) elde ettiği AUC değeri 0,99'dur. Sonuç olarak, SSA-VGG19 Karşılaştırmalı kayıp ve RMSprop optimizasyon yöntemiyle oluşturulan model diğer modele göre daha iyi performans göstermektedir.



Şekil 7. Önerilen modellerin ROC eğrileri, (a) SSA-VGG16 ikili çapraz entropi modeli ve Adam optimizasyon yöntemi ROC eğrisi, (b) SSA-VGG19 karşılaştırmalı kayıp modeli ve RMSprop optimizasyon yöntemi ROC eğrisi

Daha önceden de belirtildiği gibi, veri setinde az sayıda görüntü bulunmaktadır. Önerilen SSA modellerinin veri setindeki az sayıda görüntüsü olan sınıflarla nasıl başa çıktığını görebilmek için ROC eğrisine ek olarak Kesinlik-Duyarlılık grafiği inceleyebilir. Kesinlik-Duyarlılık grafiğine göre ideal bir sınıflandırıcı hem kesinlik hem de duyarlılık değerlerinin yüksek olduğu bir noktada olacaktır. Kayıp fonksiyonuna göre yüksek doğruluk gösteren modellerin Kesinlik-Duyarlılık grafiği Şekil 8’de verilmiştir. Şekil 8a ve Şekil 8b’den de görüleceği üzere grafik sağ üst köşeye yakındır. Şekil 8b, SSA-VGG19, Karşılaştırmalı kayıp modeli ve RMSprop optimizasyon yöntemiyle oluşturulan model, azınlık sınıflardan (toplanamaz yağ güllü) görüntülerini uygun bir şekilde sınıflandırabildiğini göstermektedir.



Şekil 8. Önerilen modellerin Kesinlik-Duyarlılık grafikleri, (a) SSA-VGG16 ikili çapraz entropi modeli ve Adam optimizasyon yöntemi Kesinlik-Duyarlılık grafiği, (b) SSA-VGG19 karşılaştırmalı kayıp modeli ve RMSprop optimizasyon yöntemi Kesinlik-Duyarlılık grafiği.

3.2. Tartışma

DeneySEL sonuçlara göre en iyi sınıflandırma doğruluğu SSA-VGG19, Karşılaştırmalı kayıp modeli ve RMSprop optimizasyon yöntemiyle oluşturulan modelde elde edilmiştir. Bu modelin doğruluğu 0,986’dır. En düşük sınıflandırma doğruluğu ise SSA-VGG16, İkili çapraz entropi modeli ve Adamax optimizasyon yöntemindedir. Bu modelin elde ettiği sınıflandırma doğruluğu 0,903’tür. Bilindiği gibi veri sayısı ESA modellerinin performansını etkiler. Ancak deneylerden elde edilen sonuçlarda da görüldüğü gibi önerilen SSA modelleri, eğitilecek az sayıda örnek olmasına rağmen iyi bir sınıflandırma yeteneği göstermiştir. Ayrıca eğitim süreci için seçilen parametreler modelin performans sonuçlarına olumlu katkı sağlamıştır. Tablo 3, son 5 yıldır literatürde gül çiçeğinin ESA modelleri kullanılarak sınıflandırılmasına yönelik çalışmaların özeti içermektedir.

Literatürde aynı veri setini kullanan [2] aktarım öğrenmeyle oluşturdukları çalışmada en yüksek sınıflandırma doğruluğunu VGG19 modelinde elde etmişlerdir. Önerdikleri çalışmadaki sınıflandırma doğruluğu %97,96’dır.

Yağ gülü hasat durumu sınıflandırma sonuçları literatürde bulunan benzer yöntemlerin sonuçlarıyla karşılaştırılmış ve SSA-VGG19 modeli doğruluk performans ölçütüne dayanarak daha etkili sonuçlar ürettiğini göstermiştir.

ESA kullanan başka bir çalışmada [12] ShuffleNet V2 mimariyle taze kesilmiş gül kalitesini %98,891 ile %99,915 arasındaki bir doğrulukla sınıflandırmışlardır. [13] kapsamlı bir veri setinde denedikleri gül türü sınıflandırma çalışmasında ESA ve MÖ birleştiren bir çalışma önermişler ve önerdikleri modelle kesinlik değerini %91,76 olarak bulduklarını belirtmişlerdir. [14] önerdikleri ESA modeliyle yaptıkları çalışmada gül türlerini %85 oranındaki doğrulukla sınıflandırmışlardır. Bu çalışmanın literatürde incelenen diğer çalışmalarla kıyaslanabilir bir sonuç üretmesi, önerilen SSA modellerinin kullanılabilir olduğunu göstermektedir.

Tablo 3. Literatürde gül çiçeğinin sınıflandırılmasıyla ilgili çalışmalar.

Referans	Görüntü sayısı	Uygulama türü	Model	Performans metriğinin sonucu (En yüksek)
[2]	961	Yağ gülü toplanabilirliği sınıflandırma	VGG19	Doğruluk: %97,96
[12]	434	Kesme gül kalitesini sınıflandırma	ShuffleNet V2	Doğruluk: %99,915
[13]	5367	Gül türlerini sınıflandırma	ESA+RO	Kesinlik: %91,76
[14]	538	Gül türlerini sınıflandırma	ESA	Doğruluk: %85
Bu çalışma	877	Yağ gülü toplanabilirliği sınıflandırma	SSA-VGG19	Doğruluk: 0,986

4. Sonuç ve Öneriler

Çalışmada yağ gülü bitkisinin hasat durumunun sınıflandırılması SSA yapısıyla incelenmiştir. ESA'nın bir türü olan SSA, yağ gülü hasat durumunu belirlemek için yağ gülü görüntülerinden her bir yağ gülünü benzersiz bir şekilde tanımlayan özellik vektörlerini çıkarmaktadır. Daha sonra, bu özellik vektörleri, bir mesafe ölçütü fonksiyonu kullanılarak karşılaştırılmakta ve sonuç benzerlik veya farklılık skoruna göre değerlendirilmektedir. Çalışmada, İkili çapraz entropi ve Karşılaştırmalı kayıp modelleri, Adam, Adamax, Nadam ile RMSprop optimizasyon yöntemleri ve VGG16 ve VGG19 ESA modellerinin kombinasyonları denenmiştir. Çalışmada, benzerlik ve farklılık skoru Kosinüs benzerliğine göre değerlendirilmiştir. Deneysel sonuçlara göre en yüksek sınıflandırma doğruluğu 0,986'dır ve bu doğruluk değeri SSA-VGG19, Karşılaştırmalı kayıp modeli ve RMSprop ile oluşturulan modelden elde edilmiştir. Deneylerden elde edilen bulgular doğrultusunda geliştirilen model, yağ gülü hasat durumunun belirlenmesinde yardımcı olabileceği göstermektedir. Deneysel sonuçlarda da görüldüğü gibi, SSA'nın görüntü sayısının az olduğu durumlarda etkili bir şekilde sınıflandırma işlemini gerçekleştirmesi bir avantaj sağlamaktadır. Ancak, eğitim ve test setleri rastgele oluşturulan görüntü çiftlerine bağlı olduğundan bu durum farklı deneylerde farklı doğruluk ve kayıp değerlerini verebilir. Bu durum çalışmanın sınırlılığını oluşturmaktadır.

Çalışma, bu yaklaşımla farklı gül türlerini sınıflandırmak için genişletilebilir. Farklı gül türlerini sınıflandırmak, geliştirilen yaklaşımlara olan güveni sağlayacak ve uygulanabilirliğini artıracaktır. Ayrıca farklı ESA modellerinin çalışmaya eklenmesiyle modellerin karşılaştırılabilirliği de sağlanabilir. Gelecek çalışmalarda etiketli ve az görüntü içeren farklı veri setlerinde az çekimli öğrenme (Few-Shot learning) modelinin kullanılmasına odaklanılacaktır.

Kaynaklar

- [1] Timor AN. World production oil rose and rose oil. *Nature Sciences* 2011; 6 (2): 93-110.
- [2] Duman B, Kayaalp K. Yağ gülü (*Rosa damascena* Mill.) bitkisinin hasat durumunun makine öğrenmesi ve derin öğrenme yöntemleri ile tespiti. *El-Cezeri* 2022; 9 (4): 1328-1341.
- [3] Eli-Chukwu NC. Applications of artificial intelligence in agriculture: A review. *Engineering, Technology & Applied Science Research* 2019; 9 (4): 4377-4383.
- [4] Abdelmigid HM, Baz M, AlZain MA, Al-Amri JF, Zaini HG, Abualnaja M, Morsi MM, Alhumaidi A. Spatiotemporal deep learning model for prediction of taif rose phenotyping. *Agron J* 2022; 12 (4): 807.
- [5] Thuseethan S, Vigneshwaran P, Charles J, Wimalasooriya C. Siamese network-based lightweight framework for tomato leaf disease recognition. *arXiv preprint* 2022; arXiv:220911214.
- [6] Malik M, Ikram A, Batoool SN, Aslam W. A performance assessment of rose plant classification using machine learning. *Intelligent Technologies and Applications: First International Conference, INTAP 2018; 23-25 October 2018; Bahawalpur, Pakistan*, pp. 745-756.
- [7] Malik M, Aslam W, Nasr EA, Aslam Z, Kadry S. A performance comparison of classification algorithms for rose plants. *Comput Intell Neurosci* 2022.
- [8] Sobolu R, Stanca L, Pusta D, Pop I, Cordea M. Image processing technique applying to detect black spot and rust diseases at roses. *Managerial Challenges of the Contemporary Society Proceedings* 2019; 12 (1): 68-73.

- [9] Sazzad S, Rajbongshi A, Shakil R, Akter B, Kaiser MS. RoseNet: Rose leave dataset for the development of an automation system to recognize the diseases of rose. *Data Brief* 2022; 44: 108497.
- [10] Bhaskar S, Kumar P, Avinash M, Harshini S. Real time farmer assistive flower harvesting agricultural robot. 2021 6th International Conference for Convergence in Technology (I2CT); 2-4 April 2021, Pune, India, pp. 1-8.
- [11] LeCun Y, Bengio Y, Hinton G. Deep learning. *nature*, 2015; 521 (7553): 436-444.
- [12] Fei Y, Li Z, Zhu T, Ni C. A lightweight attention-based convolutional neural networks for fresh-cut flower classification. *IEEE* 2023; 11: 17283-17293.
- [13] Saw S, Mahato A, Kumar B, Kukreja V. Rose Multiclassification: Harnessing Hybrid CNN and Random Forest Model. In 2024 International Conference on Automation and Computation (AUTOCOM); 14-16 March 2024, Dehradun, India, pp. 38-41.
- [14] Mujahid F, Chowdhury PK, Zaman TB, Rahman MM, Reza MT, Nasir NA, Quader MA, Quader MA. Classification of Mixed Color Rose Types Using Convolutional Neural Network. In 2023 5th International Conference on Sustainable Technologies for Industry 5.0 (STI); 09-10 December 2023, Dhaka, Bangladesh, pp. 1-5.
- [15] Liu C-F, Padhy S, Ramachandran S, Wang VX, Efimov A, Bernal A, Shi L, Vaillant M, Ratnanather JT, Faria AV. Using deep Siamese neural networks for detection of brain asymmetries associated with Alzheimer's disease and mild cognitive impairment. *Magn Reson Imaging* 2019; 64: 190-199.
- [16] Bromley J, Guyon I, LeCun Y, Säckinger E, Shah R. Signature verification using a siamese time delay neural network. *Adv Neural Inf Process Syst* 1993; Denver, Colorado, USA, pp. 737-744.
- [17] Shalaby M, Belal NA, Omar Y. Data clustering improves siamese neural networks classification of Parkinson's disease. *Complexity* 2021; 2021: 1-9.
- [18] Yaşar İD, Çakır H, Coşkun A. Siyam sinir ağları ve yerel ikili örüntü kullanılarak temassız avuç içi doğrulaması. *J Polytech* 2023; 26 (4): 1475-1483.
- [19] Arısoy MV. Signature verification using siamese neural network one-shot learning. *International Journal of Engineering and Innovative Research* 2021; 3 (3): 248-260.
- [20] Toğaçar M, Cömert Z, Ergen B. Siyam sinir ağlarını kullanarak Türk işaret dilindeki rakamların tanımlanması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi* 2021; 23 (68): 349-356.
- [21] Koch G, Zemel R, Salakhutdinov R. Siamese neural networks for one-shot image recognition. *ICML deep learning workshop* 2015.
- [22] Güçlü E, Aaydın İ, Akın E. DCGAN ve Siyam Sinir Ağını Kullanarak Demiryolu Bağlantı Elemanlarındaki Kusurların Tespiti. *Demiryolu Mühendisliği* 2022; (15): 46-59.
- [23] Madhu G, Bharadwaj BL, Rohit B, Vardhan KS, Kautish S, Pradeep N. Convolutional Siamese networks for one-shot malaria parasite recognition in microscopic images. In: *Demystifying Big Data, Machine Learning, and Deep Learning for Healthcare Analytics* Eds, Elsevier, 2021, pp. 277-306.
- [24] Alakuş TB. Prediction of Monkeypox on the Skin Lesion with the Siamese Deep Learning Model. *Balkan Journal of Electrical and Computer Engineering* 2023; 11 (3): 225-231.
- [25] Öztürk Ş. Hash code generation using deep feature selection guided siamese network for content-based medical image retrieval. *Gazi U J Sci* 2021; 34 (3): 733-746.
- [26] Lu Y. Research on Small Sample Apple Defect Classification Method Based on Siamese Network. 2023 4th International Conference on Computer Vision, Image and Deep Learning (CVIDL); 12-14 May 2023, Zhuhai, China, pp. 489-493.
- [27] Duman B. 2022. Erişim Tarihi: 02.02.2024 IspartaGulu(RosadamascenaMill.)_Dataset. <https://www.kaggle.com/datasets/1684654f84496eabe23b1728faab7cb9f687086d290f853978658746b65e65e8>.
- [28] Liu C, Miyauchi H, Hayashi K. DeepSniffer: A meta-learning-based chemiresistive odor sensor for recognition and classification of aroma oils. *Sens Actuators B* 2022; 351: 130960.
- [29] Lakshmi TS, Govindarajan M, Srinivasulu A. Embedding and Siamese deep neural network-based malware detection in Internet of Things. *Int J Pervasive Computing Commun* 2022.
- [30] Meddad M, Moujahdi C, Mikram M, Rziza M. Convolutional siamese neural network for few-shot multi-view face identification. *SIViP* 2023; 17 (6): 3135-3144.
- [31] Lachgar M, Hrimech H, Kartit A. Transfer learning for plants' disease classification with siamese networks in low data regime. *International Journal of Computer Engineering and Data Science (IJCEDS)* 2021; 1 (1): 8-13.
- [32] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proc IEEE Conf Comput Vis Pattern Recognit* 2016; 27-30 June 2016, Las Vegas, NV, USA, pp. 770-778.
- [33] Alirezazadeh P, Schirrmann M, Stolzenburg F. Improving deep learning-based plant disease classification with attention mechanism. *Gesunde Pflanz* 2023; 75 (1): 49-59.
- [34] Vasconcellos ME, Ferreira BG, Leandro JS, Neto BF, Cordeiro FR, Cestari IA, Gutierrez MA, Sobrinho A, Cordeiro TD. Siamese convolutional neural network for heartbeat classification using limited 12-lead ECG datasets. *IEEE* 2023; 11: 5365-5376.