

## Asma Yaprağı Türünün Sınıflandırılması için Doğal ve Sentetik Verilerden Derin Öznitelikler Çıkarma, Birleştirme ve Seçmeye Dayalı Yeni Bir Yöntem

Andaç İmak<sup>1\*</sup>, Gürkan Doğan<sup>2</sup>, Abdulkadir Şengür<sup>3</sup>, Burhan Ergen<sup>4</sup>

<sup>1</sup>Munzur Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Tunceli, Türkiye,

<sup>2</sup>Munzur Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Tunceli, Türkiye,

<sup>3</sup>Fırat Üniversitesi, Teknoloji Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Elâzığ, Türkiye,

<sup>4</sup>Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elâzığ, Türkiye

\*andacimak@munzur.edu.tr<sup>ID</sup>, gurkanog@munzur.edu.tr<sup>ID</sup>, ksengur@firat.edu.tr<sup>ID</sup>, bergen@firat.edu.tr<sup>ID</sup>

Makale gönderme tarihi:17.07.2022, Makale kabul tarihi:13.12.2022

### Öz

Son yıllarda Türkiye’de zengin mineral, diyet lif ve vitamin içeren asma yapraklarının üretimi ve tüketimi yoğun olarak gerçekleşmektedir. Bununla birlikte hazır gıda sektöründe asma yapraklarından yapılan dolma yemeğine talep, farklı ülkelere ihracat olanaklarını da arttırmaktadır. Bunun gibi ticari tarım faaliyetlerinde sürdürülebilir bir pazarlama için kalite standartlarının oluşturulması önemlidir. Araştırmacılar, akıllı tarım uygulamalarında derin öğrenme ile birlikte olumlu ilerlemeler kaydetmiştir. Bu çalışmada, tüketim için kullanılacak asma yapraklarının türünün tanınması için yeni bir yöntem önerilmektedir. Önerilen yöntemde Ak, Ala Idris, Büzgülü, Dimnit ve Nazli olmak üzere 5 farklı asma yaprak türünden 500 görüntü içeren bir veri seti kullanılmıştır. Bu görüntülerden veri artırma teknikleri ile 3500 adet görüntü elde edilmiştir. Ayrıca elde edilen görüntülere ESRGAN modeli uygulanarak daha ayrıntılı dokulardan oluşan bir veri kümesi elde edilmiştir. Bu görüntülerden öznitelik çıkarmak için VGG 19 derin öğrenme modeli kullanılmıştır. Oluşturulan iki ayrı veri setinden elde edilen öznitelikler birleştirilmiştir. Bu şekilde hibrit bir öznitelik çıkarıcı model oluşturulmuştur. PCA algoritması kullanılarak en iyi 175 adet öznitelik alt kümesi seçilmiştir. Son olarak elde edilen özniteliklerin sınıflandırılması için Destek Vektör Makinesi (DVM) kullanılarak %96,14 oranında doğruluk hesaplanmıştır.

**Anahtar Kelimeler:** Asma yaprağı, öznitelik çıkarma, öznitelik seçme, PCA, DVM, ESRGAN

## A New Method Based on Extracting, Combining and Selecting Deep Features from Natural and Synthetic Data for Classification of Grapevine Leaf Species

### Abstract

In recent years, the production and consumption of grapevine leaves containing rich minerals, dietary fiber and vitamins has been intensively realized in Turkey. However, the demand for stuffed food made from grapevine leaves in the convenience food sector increases the export opportunities to different countries. In commercial agricultural activities such as this, it is important to determine quality standards for sustainable marketing. Researchers have made positive progress with deep learning in smart farming applications. In this study, we propose a new method for recognizing the type of grapevine leaves to be used for consumption. In the proposed method, a dataset containing 500 images of 5 different grapevine leaf species, namely Ak, Ala Idris, Büzgülü, Dimnit and Nazli, was used. From these images, 3500 images were obtained with data augmentation techniques. In addition, a dataset consisting of more detailed textures was obtained by applying the ESRGAN model to the obtained images. VGG 19 deep learning model was used to extract features from these images. The features obtained from the two separate data sets were combined. In this way, a hybrid feature extraction model was created. The best 175 feature subsets were selected using the PCA algorithm. Finally, 96.14% accuracy was calculated using a Support Vector Machine (SVM) for classification of the obtained features.

**Keywords:** Grapevine leaf, feature extraction, feature selection, PCA, SVM, ESRGAN

## GİRİŞ

Türkiye’de bağcılık önemli tarım kollarından birisidir. Bağcılık çok sayıda çiftçinin geçim kaynağı olması ile birlikte farklı değerlendirme şekilleri ile tarımsal ürünler içerisinde önemli bir yere sahiptir. Ülkemizde asmadan elde edilen üzüm; kurutmalık, şaraplık ve sofralık olarak tüketilmesi ile birlikte asmadan elde edilen yapraklarda geleneksel türk mutfağında kullanıldığı bir üründür. Asma yapraklarından yapılan sarma geleneksel Osmanlı mutfağını temsil eden yemeklerden birisidir. Aynı zaman asma yaprağı, bazı üzüm türlerinde meyveden daha iyi ekonomik getiri sağlamaktadır. Üzüm üretiminin uygun olmadığı iklim bölgelerinde asma yaprağı üretimi mümkündür. Bu tip bölgelerde kırsal kalkınma projeleri kapsamında göçü önlemek için tarımla uğraşan insanlara getirisi yüksek olan salamura asma yaprağı üretimi önerilmektedir. Türkiye’nin asma yaprak ihracatından yaklaşık 13,5 milyon dolar, yapraktan üretilen sarma ve dolmadan ise 135 milyon dolar ihracat geliri elde edildiği bildirilmektedir. Üzüm çeşitleri kalınlık, dilimlik, tüylülük ve şekil bakımından farklı yaprak özelliklerine sahiptirler. Asma yaprağının her çeşidi yemek için tercih edilmemektedir. Tüketim için kullanılacak olanlar mümkün olduğunca ince damarlı, tüysüz ve ince olmalıdır. Ayrıca dilimsiz ve damakta ekşimsi bir tat bırakan çeşitleri daha çok tercih edilmektedir. Bu yüzden tüketim için kullanılacak asma türünün diğerlerinden ayrılması bu alanda önemli bir ihtiyaçtır (Cangi ve Yağcı, 2017).

Günümüzde yapay zekâ içeren sistemler tarım alanlarında da kullanılmaktadır. Literatürde bitki çeşitlerinin belirlenmesine yönelik birçok yöntem sunulmuştur. Ayırt edici parametre olarak yaprak tabanlı özelliklerin kullanıldığı bu sistemlerde, yüksek başarımlarına sahip derin öğrenme modelleri tercih edilmektedir. Araştırmacılar bitki yapraklarının sınıflandırılması için farklı veri setleri kullanarak çok ölçekli bir birleşimden oluşan evrişimli sinir ağı MSF-CNN (Hu vd., 2018), üç derin öğrenmeye dayalı model SWP-Leaf NET (Beikmohammadi vd., 2022), sekiz katmanlı yapı içeren 26 katmanlı bir derin öğrenme modeli ResNet26 (Sun vd., 2017), çok bölümlü evrişimsel sinir ağı modeli MD-CNN (Turkoglu vd., 2021), ResNet-50 mimarisi ve bu özelliklerin birleştirilmesi için Bonferroni ortalama operatörünün kullanıldığı BLeafNet (Ganguly vd., 2022), beş evrişim ve tam bağlantılı katman ile toplamda altı öğrenilebilir katman içeren

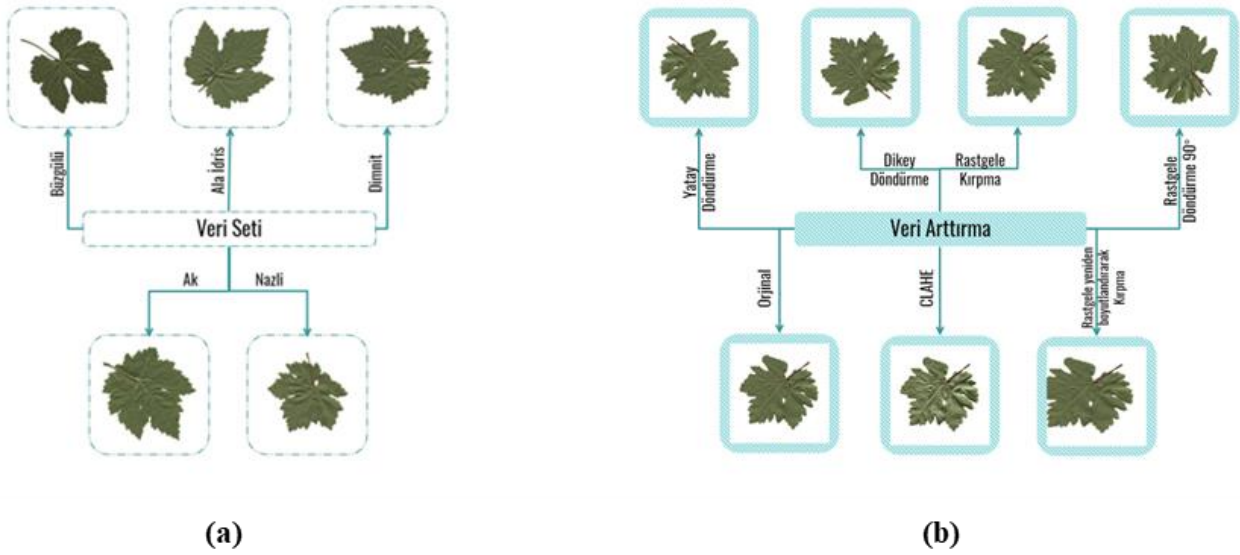
SeedNet (Loddo vd., 2021) ve önceden eğitilmiş evrişimli sinir ağının kullanıldığı DeepPlant (Lee vd., 2015) modeli gibi derin mimariler önermişlerdir. Ayrıca makalede kullanılan veri seti ile literatürde bir adet çalışma mevcuttur. Koklu ve arkadaşları asma yaprak çeşitlerinden oluşturdukları veri setinin sınıflandırılması için derin özelliklere dayalı bir CNN-SVM modeli önermişlerdir. Önceden eğitilmiş MobileNetV2 transfer öğrenme yaklaşımı ile derin özellikler elde edilmiştir. Sınıflandırma başarımının artırılması için Chi-Squares özellik seçim algoritması uygulanmıştır. Son olarak elde edilen özellikler destek vektör makineleri tarafında sınıflandırılmıştır (Koklu vd., 2022).

Görsel olarak ayırt edilmesi oldukça zor olan asma yapraklarının toplandığı gıda sektöründe kalitesine göre ayrıştırılması önemlidir. Özellikle ihracat için hazırlanan konserve türüne göre kullanılan asma yaprakları çeşitlilik göstermektedir ve bir çok çeşidi barındıran yaprakları sınıflandırmak zor bir problemdir. Bu çalışmada, söz konusu problemin üstesinden gelebilmek için asma yapraklarını türlerine göre otomatik olarak belirlenmesini sağlayan yeni bir yöntem önerilmiştir. Önerilen yöntem derin öğrenmeye dayalı ve dört temel aşamadan oluşmaktadır. Önerilen yöntemin ilk aşamasında, geleneksel veri artırma teknikleri ile birlikte ESRGAN modeli de kullanılarak verilerin ayrıntılı doku özelliğinin korunduğu veri artırma işlemi yapılmıştır. İkinci aşamasında, Arttırılmış Veri (AV) ve Süper Çözünürlüklü Verilerle (SÇV), önceden eğitilen VGG19 CNN modeli ile eğitim yapılarak özellik çıkarma işlemi uygulanmıştır. Üçüncü aşamada, elde edilen özellikler birleştirilerek en iyi özellik alt kümesinin PCA algoritması ile seçilmesi sağlanmıştır. Son aşamada, bu seçilen özellik alt kümesi ile Destek Vektör Makinesi (DVM) algoritması kullanılarak sınıflandırma işlemi yapılmıştır. Önerilen model Koklu ve arkadaşlarının (Koklu vd., 2022) oluşturdukları asma yaprağı veri seti kullanılarak test edilmiş ve %96,14 doğruluk oranı ile yüksek başarı elde edilmiştir.

Makalenin diğer bölümleri şu şekilde organize edilmiştir: Çalışmanın ikinci bölümünde Materyal ve Metot başlığı altında kullanılan veri seti ve teorik bilgiler sunulmuş, üçüncü bölümde önerilen yöntemden bahsedilmiş, dördüncü bölümde deneysel sonuçlar analiz edilerek literatürdeki ilgili çalışma ile

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1144615

karşılaştırılmıştır. Son bölümde ise çalışmanın sonuç kısmına yer verilmiştir.



Şekil 1. (a) Asma yaprağı çeşitleri, (b) Elde edilen yeni asma yaprak görüntüleri

## MATERYAL VE METOT

### Veri Seti

Bu çalışmada Koklu ve arkadaşları (Koklu vd., 2022) tarafından oluşturulan asma yaprağı veri seti kullanılmıştır. Üzüm hasadı öncesi elde edilen asma yaprak görüntülerinden bir veri seti hazırlanmıştır. Bu veri seti Ak, Ala İdris, Büzgülü, Dimnit ve Nazli olmak üzere beş farklı sınıftan oluşmaktadır. Her bir sınıfa ait 100 adet görüntü mevcuttur. Şekil 1 (a)'da beş farklı sınıf için örnek görüntüler verilmiştir.

### Veri Arttırma

Görüntüleri sınıflandırılırken etkili veri büyütme ile sistemin performansı oldukça artırılabilir. Bu çalışmada asma yaprağı görüntülerinden oluşan veri setine Python kütüphanelerinden olan ve içerisinde çeşitli arttırma tekniklerini bulunduran Albumentation kullanılmıştır. Bu kütüphanedeki random resized crop, clahe, horizontal flip, vertical flip, random crop and random rotate 90 teknikleri kullanılarak toplamda 3500 adet görüntü elde edilmiştir. Şekil 1 (b)'de bir asma yaprağının veri arttırma teknikleri ile elde edilen yeni görüntüleri gösterilmiştir (Albumentations, 2022).

### Geliştirilmiş Süper Çözünürlüklü Çekişmeli Üretici Ağlar

2018'de Wang ve arkadaşları, Geliştirilmiş Süper Çözünürlüklü Çekişmeli Üretici Ağ (Enhanced Super-Resolution Generative Adversarial Networks / ESRGAN) modelini önermiştir (Wang vd., 2018). PIRM-SR Challenge'da birinciliği kazanan ESRGAN modeli düşük çözünürlüklü görüntülerden, daha yüksek çözünürlüklü görüntü elde etmeyi amaçlamaktadır. Model, SRResNet (Ledig vd., 2017)'in temel mimarisindeki temel (basic) blokların yoğun (dense) blokları ile değişmesi ve katmanlardaki toplu normalleştirilmenin (batch normalization) kaldırılması ile oluşturulmuştur. Şekil 2'de Dimnit sınıfına ait düşük çözünürlüklü bir görüntüden ESRGAN yöntemi ile süper çözünürlüklü görüntü elde edilmesi ve ESRGAN modelinin genel blok yapısı gösterilmiştir.


### Transfer Öğrenimi

Veri setinin sınırlı boyutu, CNN katmanları ile ayırt edici öznelikleri çıkarmak için yeterli olmamaktadır. Bu yüzden küçük bir veri kümesi kullanılarak sıfırdan eğitilmiş bir derin öğrenme modelinin yüksek performans elde etmesi oldukça zordur. Bu problemin çözümü için transfer öğrenme yöntemi yaygın olarak kullanılmaktadır (Imak vd., 2022). Önerilen modelde ImageNet ile önceden

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1144615

eğitilmiş VGG 19 mimarisi kullanılmıştır. Simonyan ve Zisserman tarafından önerilen VGG 19 mimarisi, beş evrişim katmanından, beş maksimum havuzlama katmanından ve ardından üç tam bağlantılı katmandan oluşur (Simonyan ve Zisserman, 2015). Mimari, 3x3 boyutunda ve adım sayısı bir olan evrişim katmanlarını içermektedir. Ayrıca her bir evrişim işlemi sonucunda elde edilen öznitelikler ReLU aktivasyon fonksiyonundan geçirilmektedir.

Havuzlama işlemi olarak 2x2'lik adım sayısı 2 olan maksimum havuzlamadan (max pooling) oluşur (Carvalho vd., 2017). Bu çalışmada, ESRGAN ve diğer veri artırma teknikleri uygulanarak elde edilen görüntülerden 512 adet öznitelik çıkarılmıştır. Bu öznitelikler, VGG19 modelinin küresel ortalama havuzlama (global average pooling) katmanından elde edilen ağırlıklardır.



Şekil 2. ESRGAN modeli

### Temel Bileşen Analizi (PCA)

Öznitelik seçimi, veriyi temsil eden en iyi öznitelik alt kümesinin tespitidir. Bu sayede, öznitelik boyutu azaltırken aynı zamanda bilginin maksimum olarak korunması sağlanır. Bu çalışmada derin özellikleri daha az sayıda değişkenle ifade edebilecek en iyi dönüşümü belirlemek için PCA algoritması kullanılmıştır. Karl Pearson (Pearson, 1901) tarafından önerilen yöntem, sınıf etiketini yok sayar ve bilgi kaybını en aza indiren maksimum varyans temel bileşenlerin yönlerini bulur. PCA'nın temel yaklaşımı aşağıdaki gibi tanımlanır (Nkengfack vd., 2021):

- Giriş d-boyutlu öznitelik uzayında bir dizi vektörü  $X^T(x_1, x_2, x_3, \dots, x_N)$ ;
- Kovaryans matrisini hesapla  $\Sigma$ :

$$\Sigma = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^T (x_i - \bar{x})$$

Burada x verilerin ortalama değeridir.

- Kovaryans matrisinin özvektörlerini ve özdeğerlerini hesapla ve azalan düzende sıralayın;
- En büyük özdeğerlere karşılık gelen ilk özvektörleri kullanarak temel bileşenlerin  $dxk$  izdüşüm matrisini  $W = (w_1, w_2, w_3, \dots, w_k)$  tanımla

- Son adımda, orijinal veri  $X$ 'in bilgilerinin büyük bir kısmını aşağıdakileri kullanarak yeni  $k$ -boyutlu alt uzayda  $Y$  üzerine yeniden yapılandır:

$$Y = X * W$$

### Önerilen Yöntem

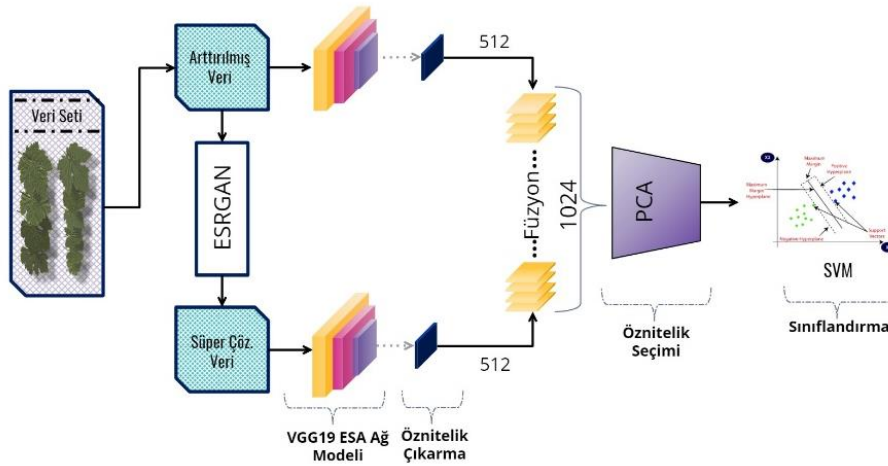
Önerilen yöntem, beş temel adımdan oluşmaktadır. Şekil 3'te gösterilen modelin ilk adımında, CNN modellerinin öğrenmesini optimum şekilde sağlamak için orijinal veri setine görüntü artırma teknikleri uygulanır ve 3500 adet görüntüden oluşan yeni veri seti, Arttırılmış Veri (AV) olarak adlandırılır. Daha sonra, arttırılmış verinin %80 eğitim ve %20'si test verisi olarak ayrılır. Ardından, bu eğitim ve test verisi ayrı ayrı ESRGAN yöntemiyle yeni sentetik veri üretimine tabi tutulur. Bu şekilde eğitim ve test verisinin ayrı ayrı yapılmasının nedeni, eğitim ve test verilerinin birbirine karışması önlenmektedir. Yeni veri üretiminde 2800 eğitim ve 700 test verisi oluşurken bu veri seti, Süper Çözünürlüklü Veri (SÇV) olarak adlandırılmıştır. Yeni veri üretiminde ESRGAN yönteminin kullanılmasının nedeni ise, diğer süper çözünürlüklü yöntemlere göre daha doğal ve ayrıntılı doku bilgisini üretme özelliğinden faydalanmaktadır. İkinci adımda, AV ve SÇV'den sınıfları öğrenebilmek için VGG19



Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1144615

CNN modelleri ile transfer öğrenme yapılmıştır. Bu CNN modelinin seçilmesinin nedeni, küçük veri setlerinde gösterdikleri başarılı performanslarından dolayıdır. Ayrıca, transfer öğrenmeli CNN modeliyle birlikte kullanılan minimum gereksinimli katmanlar; küresel ortalama havuzlama (global average pooling) ve softmax sınıflandırıcı tam bağlantılı (dense) katmandır. Dolayısıyla, bu çalışmada kullanılan VGG19 CNN modelinin çıkış / son

katmanları, bu iki katman ile değiştirilmiştir. Buradaki amaç; sınıf sayısını bizim probleme uyarlayabilmektir. Bu adımda, VGG19 CNN modeli AV ve SÇV setleri ile eğitilir. Üçüncü adımda, eğitilen CNN modellerinin çıkış katmanında yer alan tam bağlantılı katmanından 512 adet öznelik çıkarılır. Her bir modelden çıkarılan öznelikler birleştirilerek (füzyon) 1024 adet öznelik olması sağlanır. Dördüncü adımda, PCA kullanılarak önemli



Şekil 3. Önerilen yöntemin şematik tasarımı

öznelikler seçilir. Bu noktada, seçilecek öznelik alt kümesinin en iyi özneliklerden oluşmasını sağlamak için bileşen sayısı 25'ten başlatılarak 1000'e kadar 25'er artacak şekilde Destek Vektör Makinesi (DVM) ile doğruluk değerlendirmesine tabi tutulmuştur. Bu şekilde, sınıflandırıcı için PCA'nın bileşen sayısı ve DVM'nin düzenleme (regularization, C) ve RBF çekirdeğinin katsayı ( $\gamma$ ) parametrelerinden optimum değerler belirlenmiştir. Beşinci adımda, DVM yöntemi kullanılarak sınıflandırma yapılır. Önerilen yöntemin şematik tasarımı Şekil 3'te sunulmuştur.

VGG19 ESA modelinde kullanılan hiperparametreler Tablo 1'de verilmiştir. Ek olarak, bu modellerde kategorik çapraz entropi (categorical cross entropy) kayıp fonksiyonu kullanılmıştır. Optimizasyon yöntemi olarak Adam, SGD ve RMSprop denenerek en iyi sonuçları veren SGD algoritması seçilmiştir. Momentum ve Öğrenme Oranı değerleri ise iteratif olarak denenerek en iyi sonucu veren değerler seçilmiştir.

## DENEYSSEL SONUÇLAR

Bu çalışmada önerilen yöntemin performansını ölçmek için Doğruluk (Acc.), Özgüllük (Spe.) Hassasiyet (Pre.), Anma (Rec.) ve F1-Skoru gibi karmaşıklık matrisinden elde edilen performans metrikleri kullanılmıştır. Bu metriklerin hesaplaması için true positive (TP), true negative (TN), false positive (FP) ve false negative (FN) olmak üzere 4 temel parametreye ihtiyaç duyulmaktadır (Koklu vd., 2022), (Doğan ve Ergen, 2022), (Doğan ve Ergen, 2022). Bu metrikler denklem (1), (2), (3), (4) ve (5)'de formüle edilmiştir.

$$Acc = (TP + TN)/(TP + FN + TN + FP) \quad (1)$$

$$Spe = TN/(TN + FP) \quad (2)$$

$$Pre = TP/(TP + FP) \quad (3)$$

$$Rec = TP/(TP + FN) \quad (4)$$

$$F1-Skoru = 2TP/(2TP + FP + FN) \quad (5)$$

Deneysel çalışmalarda, Python 3.7.13, Tensorflow 2.8.0, Keras 2.8.0 gibi yazılımsal

Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1144615

teknolojiler ve Intel(R) Xeon(R) CPU @ 2.30GHz, 27.6 GB RAM, Tesla T4 - 16 GB gibi donanımsal teknolojiler kullanılmıştır.

Bu çalışmada, deneysel çalışmalar, öznitelik çıkarılmasına veya öznitelik çıkarılmamasına göre temelde 2 aşamaya ayrılmıştır. Bu şekilde deneysel çalışmanın 2 aşamada olmasının nedeni, öznitelik çıkarmanın veya çıkarmamanın önerilen yöntemde nasıl bir katkı yapacağıının anlaşılmasını sağlamaktır. İlk aşamada, AV ve SÇV verisiyle öznitelik

çıkarılmadan VGG19 CNN modeli kullanılarak asma yaprağı sınıflandırması yapılarak deneysel sonuçlar elde edilmiştir. Bu şekilde, önerilen yöntemde kullanılan AV ve SÇV verisinin, VGG19 CNN modellerine her bir veri setinin ayrı ayrı değerlendirilebilir olması amaçlanmıştır. İkinci aşamada ise, AV ve SÇV verisiyle eğitilen VGG19 CNN modelleri, birer öznitelik çıkarıcı olarak kullanılmıştır. Öznitelik çıkarma görevinde kullanılan bu CNN modellerinin çıkışı küresel

**Tablo 1.** VGG19 CNN modelinde kullanılan hiper-parametreler

Veri Seti	ESA Modeli	Görüntü Boyutu	Optimizasyon Yöntemi	Momentum	Epoch	Mini Batch	Öğrenme Oranı
AV	VGG19	224x224	Stochastic Gradient	0.9	200	32	1e-2
SÇV	VGG19		Descent				

ortalama havuzlama (global average pooling) katmanı sağlamaktadır. Bu katman, VGG19 CNN modelinin transferden ve verilerden öğrenme düzeylerini optimumda tutmayı amaçlamaktadır. Ek olarak, bu katmandan 512 adet öznitelik ile öznitelik çıkarma yapılmıştır. Çıkarılan öznitelikler, bu aşamada, öncelikle birleştirilerek 1024 adet öznitelik elde edilmiştir. Daha sonra, 1024 adet öznitelikten etkisiz ve önemsiz olan öznitelikler atılarak en önemli özniteliklerin seçimi Temel Bileşenler Analizi (Principal Component Analysis/PCA) yöntemi ile yapılmıştır. Bu noktada, öznitelik seçimini en iyi bir şekilde başarabilmek için PCA 'nın en önemli parametrelerinden olan komponent sayısını iyi belirlemek gerekir. Bunun için, komponent sayısı 25'den başlatılarak 25'er artacak şekilde ve 1000'e kadar devam eden bir teknikle en iyi başarıma ulaşmak için en iyi komponent sayısı 175 olarak belirlenmiştir. Bununla birlikte, PCA ile seçilen özniteliklerin sınıflandırmadaki başarısını değerlendirmek için de DVM algoritması kullanılmıştır.

Diğer taraftan, orijinal veri setine veri artırma yöntemleri uygulanarak her bir sınıftan 500 adet görüntü olmak üzere toplam 3500 adet görüntü üretilmiştir ve bu üretilen veri, Arttırılmış Veri (AV) olarak adlandırılmıştır. Daha sonra, CNN yöntemlerinin eğitimi ve testinde kullanılmak üzere Arttırılmış Veri Setinin %80'i eğitim ve %20'si test

verisi için ayrılmıştır. Bunun yanı sıra, bu eğitim ve test veri seti ayrı ayrı ESRGAN yönteminden geçirilerek yeni bir sentetik veri seti elde edilmiştir ve bu da Süper Çözünürlüklü Veri (SÇV) olarak adlandırılmıştır. Özellikle, eğitim ve test veri seti ESRGAN'a ayrı ayrı verildiği için üretilen yeni veri seti de %80 eğitim ve %20 test verisi olmaktadır. Bu çalışmada, ESRGAN'ın kullanılmasının nedeni, diğer Süper Çözünürlüklü GAN' lardan daha doğal ve ayrıntılı doku bilgisini üretme özelliğinden faydalanmaktır. Arttırılmış ve Süper Çözünürlüklü Veri ile VGG19 CNN modellerine eğitim yapıldığında elde edilen doğruluk ve kayıp grafikleri Şekil 4'te verilmiştir. Şekil 4'te görüldüğü gibi AV seti ile yapılan eğitimde VGG19 CNN modelinin doğruluğu %87'ye ulaşırken kayıp değeri 0,36'ya kadar ulaşmaktadır. Ancak, SÇV seti ile VGG19 doğruluk değeri %84,7'e kadar ulaşırken kayıp grafiği 0.5'e kadar ulaşmaktadır.


Tablo 2'de AV ve SÇV veri setlerinin farklı kombinasyonlarına göre VGG19 modeli ile asma yaprağının sınıflandırma sonuçları verilmiştir. Bu tabloya göre, SÇV veri seti VGG19 ile eğitilip Softmax yöntemi ile sınıflandırıldığında yaklaşık olarak %85 doğruluk elde edilirken AV veri seti ile sınıflandırma yapıldığında doğruluk %87'ye çıkmaktadır. Önerilen yöntemde ise AV ve SÇV veri seti VGG19 CNN modeli kullanılarak elde edilen özniteliklerin füzyonu ve PCA öznitelik alt kümesi

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1144615

seçimi yapılarak DVM algoritması ile %96,14 oranında doğruluğa ulaşılmıştır. Bununla paralel olarak, hassasiyet, anma ve f1-skorunda da en yüksek başarılar elde edilmiştir.

Şekil 5-a'da öz nitelik sayısı 25'ten başlatılarak 1000'e kadar 25'er artarak PCA ile seçilip DVM algoritması ile doğruluk metriği değerlendirmeye alınmıştır. Bu şekilde yapılan değerlendirme sonucunda optimum öz nitelik sayısı 175 olurken DVM parametrelerinden düzenleme (regularization) parametresi  $1 \times 10^3$  ve RBF

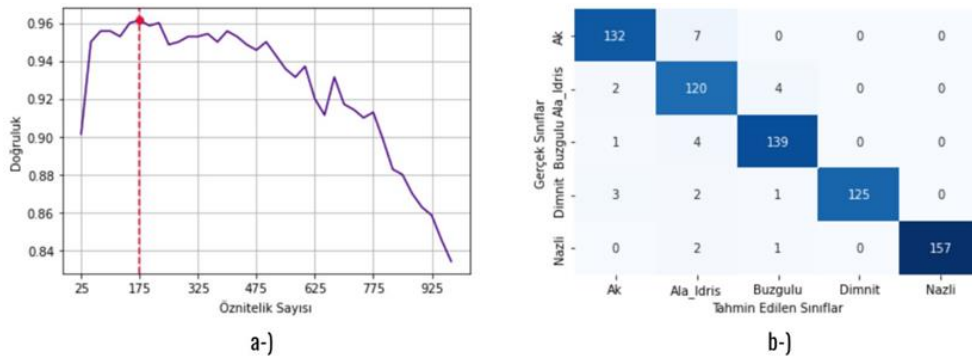
çekirdeğinin katsayısı  $5 \times 10^{-3}$  olarak belirlenmiştir. Dolayısıyla, nihai sonuçları elde etmek için 175 öz nitelik ile testler yapılmıştır. Buna göre DVM algoritması ile yapılan sınıflandırma sonucunda elde edilen karmaşıklık matrisi de Şekil 5-b'deki gibi görülmektedir. Karmaşıklık matrisinde de görüldüğü gibi 27 adet görüntünün sınıfı hatalı tahmin edilmiştir. Bu da, 700 adet test görüntüsünden 27'sinin yani  $27 \times 100 / 700 = \%3,86$  hatalı tahmin olduğu anlamına gelmektedir.



Şekil 4. AV ve SÇV verilerine göre VGG19 CNN yöntemi ile elde edilen doğruluk (a) ve kayıp (b) grafikleri

Tablo 2. VGG19 Modelinin Veri Setlerine Göre Kıyaslaması

Yöntemler	Doğruluk (Acc.)	Hassasiyet (Pre.)	Anma (Rec.)	F1-Skoru
SÇV + VGG19 + Softmax	0,8471	0,8644	0,8429	0,8456
AV + VGG19 + Softmax	0,8700	0,8689	0,8673	0,8663
<b>Füzyon + PCA + DVM</b>	<b>0,9614</b>	<b>0,9608</b>	<b>0,9605</b>	<b>0,9603</b>



Şekil 5. VGG19 CNN modelinin öz nitelik sayısına göre doğruluk grafiği (a) ve seçilen öz nitelik alt kümesine göre elde edilen karmaşıklık matrisi (b)

Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1144615

Önerilen yöntem olan Füzyon, PCA ve DVM kombinasyonu ile elde edilen karmaşıklık matrisi sonuçları sınıf bazlı olarak Tablo 3'te gösterilmektedir. Buna göre, tüm sınıflar için genel doğruluk oranı %96,14 olurken en yüksek hassasiyet, anma, ve F1-skoruna Nazli sınıfı ile ulaşılmıştır. Aksine, en düşük hassasiyet ve F1-skoru değeri Ala Idris sınıfında gerçekleşirken en düşük anma değeri Ak sınıfında gerçekleşmiştir. Tablo 4'te önerilen yöntemin literatürdeki diğer yöntemlere göre kıyaslaması sunulmuştur. Aynı veri seti ile sadece Koklu vd. (2022)'lerinin yaptığı çalışma bulunmaktadır. Buna göre, 175 öznitelik ve RBF çekirdeği ile önerilen çalışma, linear, cubic ve gaussian çekirdekli 1000 öznitelik ve linear

çekirdekli 250 öznitelik ile yaptıkları çalışmaya göre %96,14 doğrulukla daha başarılı olmuştur. Önerilen çalışmada, VGG19 ESA modeli kullanılırken, karşılaştırma yapılan çalışmada MobileNetV2 ESA kullanılmıştır. Farklı ESA modellerinin kullanımı iyi özniteliklerin elde edilmesi için farklı oranlarda etkili olmaktadır. Ancak, öznitelik alt kümesinin seçimi ve sınıflandırma yöntemleri de sınıflandırma başarısını büyük oranda etkilemektedir. Tablo 2'de görüldüğü gibi sadece VGG19 ESA modeli ile sınıflandırma yapıldığında en yüksek doğruluk %87 olurken önerilen yöntem ile sınıflandırma yapıldığında doğruluk %96,14'e kadar çıkmaktadır. Bu da, yaklaşık olarak %9 oranında daha yüksek başarısı ile önerilen yöntemin önemini ortaya koymaktadır.

**Tablo 3.** Önerilen yöntem ile elde edilen karmaşıklık matrisi sonuçları

Sınıflar	Doğruluk (Acc.)	Hassasiyet (Pre.)	Anma (Rec.)	F1-Skoru	Görüntü sayısı
<b>Ak</b>		0,9565	0,9496	0,9531	139
<b>Ala_Idris</b>		0,8889	0,9524	0,9200	126
<b>Buzgulu</b>	0,9614	0,9586	0,9653	0,9619	144
<b>Dimnit</b>		1,0000	0,9542	0,9766	131
<b>Nazli</b>		1,0000	0,9812	0,9905	160
<b>Toplam</b>					700

**Tablo 4.** Önerilen yöntemin diğer yöntemler ile kıyaslaması

Çalışma	Yıl	Yöntem	Öznitelik Sayısı	Kernel	Doğruluk (Acc.)	Özgüllük (Spe.)	Hassasiyet (Pre.)	Anma (Rec.)	F1-Skoru
				Linear	0,9363	0,9840	0,9369	0,9360	0,9362
(Koklu vd., 2022)	2022	ESA + Chi-Square + DVM	1000	Cubic	0,9600	0,9900	0,9606	0,9600	0,9600
				Gaussian	0,9540	0,9885	0,9556	0,9540	0,9541
			250	Linear	0,9460	0,9865	0,9467	0,9460	0,9461
<b>Önerilen Yöntem</b>	?	<b>ESA+ Füzyon+ PCA+ DVM</b>	<b>175</b>	<b>RBF</b>	<b>0,9614</b>	<b>0,9904</b>	<b>0,9608</b>	<b>0,9605</b>	<b>0,9603</b>



Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1144615

## SONUÇ

Bu çalışmada 5 farklı asma yaprak çeşidinin belirlenmesi için derin özellik çıkarımı ve makine öğrenmesinden oluşan bir yöntem önerilmektedir. Önerilen yöntemde görüntü sayısının az olması nedeni ile sistemin performansını yükseltmek için veri artırma teknikleri kullanılmıştır. Bu teknikler sonucunda elde edilen 3500 görüntü daha ayrıntılı dokular ve yüksek çözünürlüklü sentetik görüntüler elde edilmesi için ESRGAN modeli ile yeniden yapılandırılmıştır. Önceden eğitilen VGG 19 modeli ile öznetelik çıkarımı yapılmıştır. En anlamlı derin özneteliklerin seçimi için PCA öznetelik seçim algoritması uygulanmıştır. Seçilen öznetelikler ise DVM algoritması ile sınıflandırılmıştır. Asma yaprağı veri seti için %96,14 doğruluk hesaplanmıştır. Önerilen yöntem, literatürde aynı veri seti kullanılarak yapılan çalışmaya göre daha iyi bir başarı göstermiştir. Gelecek çalışmalarda, akıllı tarım uygulamaları için bu yöntemin optimize edilip gömülü sistemler üzerinde gerçek zamanlı olarak çalışabilmesi ve asma yapraklarından oluşan daha kapsamlı bir veri setinin hazırlanarak literature kazandırılması hedeflenmektedir.

## ÇIKAR ÇATIŞMASI BEYANI

Yazarlar bu makale ile ilgili herhangi bir çıkar çatışması bildirmemektedir.

## ARAŞTIRMA VE YAYIN ETİĞİ BEYANI

Yazarlar bu çalışmanın araştırma ve yayın etiğine uygun olduğunu beyan eder.

## KAYNAKLAR

Albumentations, (2022). <https://albumentations.ai/>.  
 Beikmohammadi A., Faez K. ve Motallebi A. (2022). SWP-LeafNET: A novel multistage approach for plant leaf identification based on deep CNN. *Expert Systems with Applications*, 202, 117470.  
 Cangi R. ve Yağcı A. (2017). Bağdan sofraya yemeklik asma yaprak üretimi. *Nevşehir Bilim ve Teknolojisi Dergisi*, (6), 137-148.  
 Carvalho T., De Rezende E., R. Alves M. T., Balieiro F. K. ve Sovat R. B. (2017). Exposing computer generated images by eye's region classification via transfer learning of VGG19 CNN. In 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), 866-870.  
 Doğan G. ve Ergen B. (2021). İMobileNet CNN yaklaşımları ve özellik seçme yöntemleri kullanarak araç türlerini sınıflandırma. *Süleyman Demirel*

Üniversitesi Fen Bilim. Enstitüsü Dergisi, 25(3), 618-628.  
 Doğan G. ve Ergen B. (2022). A new mobile convolutional neural network-based approach for pixel-wise road surface crack detection. *Measurement*, (195), 111119.  
 Ganguly S., Bhowal P., Oliva D. ve Sarkar R. (2022). BLeafNet: A Bonferroni mean operator based fusion of CNN models for plant identification using leaf image classification. *Ecological Informatics*, (69), 101585.  
 Hu J., Chen Z., Yang M., Zhang R. ve Cui Y. (2018). A multiscale fusion convolutional neural network for plant leaf recognition. *IEEE Signal Processing Letters*, 25(6), 853-857.  
 Imak A., Celebi A., Siddique K., Turkoglu M., Sengur A. ve Salam I. (2022). Dental Caries Detection Using Score-Based Multi-Input Deep Convolutional Neural Network. *IEEE Access*, (10), 18320-18329.  
 Koklu M., Unlarsen M. F., Ozkan I. A., Aslan M. F. ve Sabanci K. (2022). A CNN-SVM study based on selected deep features for grapevine leaves classification. *Measurement*, (188), 110425.  
 Ledig C., Theis L., Huszár F., Caballero J., Cunningham A., Acosta A. ve Shi W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4681-4690.  
 Lee S. H., Chan C. S., Wilkin P. ve Remagnino P. (2015). Deep-plant: Plant identification with convolutional neural networks. In 2015 IEEE International Conference on Image Processing (ICIP), 452-456.  
 Loddo A., Loddo M. ve Di Ruberto C. (2021). A novel deep learning based approach for seed image classification and retrieval. *Computers and Electronics in Agriculture*, (187), 106269.  
 Nkengfack L. C. D., Tchiotso D., Atangana R., Tchinda B. S., Louis-Door V. ve Wolf D. (2021). A comparison study of polynomial-based PCA, KPCA, LDA and GDA feature extraction methods for epileptic and eye states EEG signals detection using kernel machines. *Informatics in Medicine Unlocked*, (26), 100721.  
 Pearson K. (1901). LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2(11), 559-572.  
 Simonyan K. ve Zisserman A. (2015). Very deep convolutional networks for large-scale image recognition. 3rd Int. Conf. Learn. Represent. ICLR 2015, 1-14.  
 Sun Y., Liu Y., Wang G. ve Zhang H. (2017). Deep learning for plant identification in natural environment. *Computational Intelligence and Neuroscience*, 2017.

*Research article/Araştırma makalesi*  
DOI:10.29132/ijpas.1144615

- Turkoglu M., Aslan M., Arı A., Alçın Z. M. ve Hanbay D. (2021). A multi-division convolutional neural network-based plant identification system. *PeerJ Computer Science*, 7.
- Wang X., Yu K., Wu S., Gu J., Liu Y., Dong C. ve Change Loy C. (2018). Esrgan: Enhanced super-resolution generative adversarial networks. In *Proceedings of the European conference on computer vision (ECCV) workshops*.