

# Derin Öznitelikler Kullanılarak Aşırı Öğrenme Makineleri ile Kayısı Yapraklarının Sınıflandırılması

## Classification of Apricot Leaves with Extreme Learning Machines Using Deep Features

Berna Arı

Bilişim Teknolojileri Bölümü  
Sürgü Çok Programlı Anadolu Lisesi  
Malatya, Türkiye  
bernagurler.a@gmail.com

Ali Arı

Bilgisayar Teknolojileri Bölümü  
Malatya Turgut Özal Üniversitesi  
Malatya, Türkiye  
ali.ari@ozal.edu.tr

Abdulkadir Şengür

Elektrik Elektronik Müh. Bölümü  
Fırat Üniversitesi  
Elazığ, Türkiye  
ksengur@firat.edu.tr

Seda Arslan Tuncer

Yazılım Mühendisliği Bölümü  
Fırat Üniversitesi  
Elazığ, Türkiye  
satuncer@firat.edu.tr

**Özet**— Makine öğrenmesi ve görüntü işleme tabanlı otomatik bitki türlerinin sınıflandırılması, bitki uzmanları için önem arz etmektedir. Literatüre konu ile ilgili birçok çalışma kazandırılmıştır. Günümüzde araştırmacılar derin öğrenmeyi çeşitli görüntü tabanlı nesne tanıma görevlerine uygulamıştır. Bu çalışmada Derin Evrimsel Sinir Ağları (DESA) tabanlı otomatik kayısı türlerinin sınıflandırılması yapılmıştır. Önerilen yöntemde önceden eğitilmiş bir DESA modeli olan VGG19 modeli kullanılmıştır. Üç farklı tam bağlı katmandan elde edilen öznitelikler farklı kombinasyonlar ile birleştirilerek yedi farklı öznitelik vektörü elde edilmiştir. Bu öznitelik vektörleri Aşırı Öğrenme Makinelerinin (AÖM) girişine verilerek çalışma için oluşturulan veri setindeki yedi farklı kayısı türü sınıflandırılmıştır. En yüksek başarımlar oranı %98,8 ile fc8 katmanından alınırken en düşük başarımlar oranı ise %95,2 ile fc6 ve fc7 katmanlarının birleşiminden elde edilen öznitelik vektöründen elde edilmiştir.

**Anahtar Kelimeler**—*derin evrimsel sinir ağları, derin öğrenme, sınıflandırma, aşırı öğrenme makineleri*

**Abstract**— Machine learning and image processing-based classification of automated plant species is significant for plant experts/ herbalists. Many studies on the subject have been gained to the literature. Today, researchers have applied deep learning to various image-based object recognition tasks. In this study, the classification of automatic apricot species based on Deep Convolutional Neural Networks (DCNN) has been made. The proposed method used the VGG19 model, a pre-trained DCNN model. Seven different feature vectors were obtained by combining the features obtained from three different fully connected layers in different combinations. These feature vectors were given to the input of Excessive Learning Machines and seven different apricot types were classified. The highest performance rate was obtained from the fc8 layer as 98.8%, and the lowest performance rate was obtained from the feature vector obtained from the combination of fc6 and fc7 layers as 95.2%.

**Keywords**—*deep convolutional neural network, deep learning classification, extreme learning machines*

### I. GİRİŞ

Bitkiler, hayatımızı sürdürmemizde önemli rol oynamaktadır. Günümüzde gıda, ilaç tedavi, tekstil, iklim kontrolü, yakıt elde etme gibi birçok alanda sıklıkla kullanılan ve her biri farklı işlevde kullanılan bu bitki türlerinin korunup geleceğe aktarılabilmesi tanınabilmesinden geçmektedir. Bitki türlerinin tanınması temel olarak bitki yaprağı özniteliklerinin tanınmasına bağlıdır [1]. Ancak uzmanlar tarafından manuel olarak her bitkinin ve bitki yaprağının tek tek incelenmesi mümkün olmayacak kadar zor ve zahmetlidir. Bu sebeple bitkiyi tanımlayacak olan öznitelik ve şekillerin çıkarılması ve bitkiyi tanımlayıcı etkenlerin belirlenmesi gerekmektedir. Her bir sınıfın öznitelikleri ayrıca belirlenmeli o sınıfı temsil edecek en öncelikli seçimler yapılmalıdır [2]. Görüntü işleme ve makine öğrenmesi temelli sistemlerin tasarlanmasıyla bitki türlerinin tanınması ve sınıflandırılması, uzmanlara zaman ve emek açısından destek olabilecektir.

Makine öğrenmesi tabanlı bitki tanıma yaklaşımlarında bitki yaprakları kullanılmıştır. Son yıllarda makine öğrenmesi tabanlı bitki tanıma sistemleri araştırmacılar için popüler bir araştırma haline gelerek literatüre çok sayıda çalışma sunulmuştur. Wang ve arkadaşları [3] tarafından bitki yaprağı tanımda yeni bir yöntem önerilmiştir. Görüntülerdeki gürültüyü yok etmek ve ayırt edici öznitelikleri çıkarmak için tasarladıkları bu yeni algoritmaları iki aşamadan oluşmaktadır. İlk aşamada, bitki yaprağı görüntüsü uyarlamalı bir dalgacık şemasıyla birkaç alt banda ayrıştırılmıştır. Diğer aşamada ise değişken ölçekli Gauss filtreler grubu kullanılarak her bir alt bant filtelenmiştir. Yerel İkili Örüntülerle (YİÖ) elde edilen şekilsel ve dokusal öznitelikler kullanılmıştır. Sınıflandırma 15 farklı ağaç türünün her birinden alınan 75 yaprağa sahip olan Swedish veri seti ve 225 bitki türüne ait 20000'den fazla yaprak içeren ICL veri seti kullanılarak k-En Yakın Komşu (k-EYK) algoritması ile yapılmıştır. Sınıflandırma başarımları

bahsedilen veri setleri için sırasıyla %91,9 ve %96,5 olarak bulunmuştur. Chaki ve arkadaşları [4], bitki yapraklarını tanıma işleminde yaprak dokularını Gabor filtre ve Gri Seviyeli Eş Oluşum Matrisi (GSEOM) kullanarak modellemiştir. Yaprığın şekilsel öznelikleri bir dizi Curvelet dönüşüm katsayısı kullanılarak elde edilmiştir. Öznelik çıkarımından önce çeşitli ölçeklendirme ve döndürme işlemleri için bir ön işleme aşaması geçirilmiştir. İki nöral sınıflandırıcı ile yapraklar incelenmiştir. Sınıflandırıcılardan biri Nöro-Bulanık Denetleyici (NBD) diğeri ise bir ileri beslemeli geri yayımlı Çok Katmanlı Algılayıcı (ÇKA) olarak belirlenmiştir. Yaprak tanıma işlemi her birinden 30 yaprak alınan 31 ağaçtan oluşan veri seti üzerinde denenmiş ve bu ağaç sınıflarındaki her 10 veri eğitim, her 20 veri de test amaçlı kullanılmıştır. Şekilsel ve dokusal olarak yapılan modelleme daha sonra birleştirilmiş ve NBD için %97,6 ve ÇKA için %85,6 doğruluk değeri elde edilmiştir. Türkoglu ve Hanbay [5], bitki türlerinin tanınması için Bölge Ortalama-YİÖ, Genel Ortalama-YİÖ ve hem Bölge Ortalaması-YİÖ hem de Genel Ortalama-YİÖ yöntemlerinin bir kombinasyonuna dayanan üç yeni görüntü tanımlayıcıları önermiştir. Bu yöntemler, bilinen görüntü tanımlayıcılarından biri olan YİÖ'nün geliştirilmiş versiyonlarıdır. Bu yöntemler, merkez piksel yerine bölge ve genel ortalamayı göz önüne alarak çalışmaktadır. Bununla birlikte, orijinal YİÖ yöntemi gri görüntüler kullanırken, Bölge Ortalama-YİÖ ve Genel Ortalama-YİÖ yöntemleri sırasıyla görüntülerin kırmızı ve yeşil renk kanallarını kullanmaktadır. Ek olarak, önerilen yöntemlerin etkinliği ve sağlamlığı gürültülü görüntülere karşı değerlendirilmiştir. Elde ettikleri öznelikler Flavia, Swedish, ICL ve Foliage veri setlerinde AÖM ile test edilmiş ve sırasıyla %98,9, %99,5, %83,7 ve %92,9 tanıma doğruluğu bulunmuştur. Şekeroğlu ve İnan [6], yaprak tanıma çalışmalarının son zamanlarda önem kazandığından bahsederek sınıflandırmada Yapay Sinir Ağlarını (YSA) tercih etmiştir. YSA'nın uygun parametrelerine ulaşana kadar dokuz adet normal ve dokuz adet gürültülü görüntüyü eğitmişlerdir. Test aşaması farklı gürültü parametrelerine sahip üç görüntü grubuyla uygulanmıştır. Her bir görüntü grubunda 27 ağaca ait 4 yaprak bulunduğu belirtilmiş ve sınıflandırmada en yüksek başarımlar %97,2 olarak bulunmuştur. Sladojevic ve arkadaşları [7], yaprak görüntülerini sınıflandırarak bitki hastalıklarını tanıma üzerine yeni bir yaklaşım geliştirmişlerdir. Geliştirilen model ile yapraklardan 13 farklı bitki hastalığı tanınabilmektedir. Giriş görüntülerinden elde edilen öznelikler, çoklu katmanlara sahip derin bir Evrişimsel Sinir Ağı (ESA) olan CaffeNet tarafından aşamalı olarak hesaplanmıştır. Yaklaşık 30000 görüntü ile ESA kullanılarak gerçekleştirilen deneysel sonuçlar ile ortalama %96 oranında başarımlar sağlanmıştır. Shah ve arkadaşları [8], yaprak görüntülerinden bitki türlerinin tasnifi için çift yönlü ESA önermektedir. Bu ESA mimarisinde biri şekle bağlı öznelikleri diğeri dokuya bağlı öznelikleri öğrenmek üzere iki yol bulunur. Daha sonra bu iki yoldan alınan tanımlayıcı bilgiler bir algılayıcıda birleştirilir. Yaprak görüntüsü, ön işleminden sonra ESA'da evrişim ve maksimum havuzlama katmanlarından geçirilir ve her bir evrişim katmanını parça normalizasyonu izler. Son katman hariç tüm katmanlarda ReLU aktivasyon fonksiyonu kullanılır. Her iki yoldan öğrenilen öznelikler bir araya getirilerek çok katmanlı algılayıcıya girdi olarak verilir. Sistemleri üç yaprak veri seti

(Flavia-1907 görüntü, Leafsnap-7710 görüntü, ImageClef-6630 görüntü) üzerinde denenerek ortalama %99 başarımlar göstermiştir. Doğan ve Türkoğlu [9], yaprak sınıflandırma çalışmalarını derin öğrenme algoritmaları ile gerçekleştirmiştir. ESA ile her biri 60 örnekten oluşan 32 sınıf üzerinden ön işlem ve öznelik çıkarımı yapılmıştır. Sınıflandırmada derin öğrenmenin AlexNet, GoogleNet, VGG16, VGG19 ve ResNet50 derin öğrenme algoritmaları kullanılmıştır. Bu mimarilerle bitki yapraklarını doğru sınıflandırma oranı %98,4 ve %99,7 aralığında bulunmuştur. Tang ve arkadaşları [10], tomurcuklu ve tomurcuksuz olarak farklı çay yapraklarının sınıflandırılması üzerine çalışmıştır. Kendi alan çalışmalarını farklı kılmak için taze çay yapraklarını sınıflandırmışlardır. Doku özneliklerini çıkarabilmek için YİÖ ve GSEOM'den faydalanılmış ve sonrasında sınıflama yapılmıştır. İnceledikleri beş doku görüntüsünden %80 ile %98 sınıflama bulguları elde edilmiştir. Aakif ve Khan [11], yaprak sınıflandırma üzerine yaptıkları çalışmalarında şekilsel öznelikleri Fourier tanımlayıcılar ile çıkarmış ve bu öznelikleri bir giriş vektörü olarak YSA'da kullanmışlardır. Sistemlerini 14 farklı meyve ağacından elde ettikleri 817 yaprakla eğitmiş ve %96 doğruluk elde etmişlerdir.

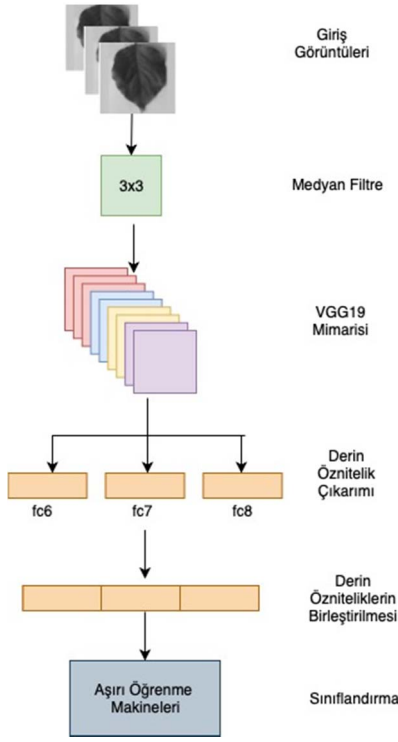
Çalışmanın yapıldığı bölgede bulunan Malatya ili yurt içi ve yurt dışı kayısı ihtiyacının büyük bölümünü karşılamaktadır. Uzmanlar bölgede yaklaşık 300 farklı kayısı türünün olduğunu söylemektedir. Bu çalışmada, en çok tercih edilen yedi farklı kayısı türünü tanımak ve sınıflandırmak için tarafımızca ilgili türlere ait kayısı yaprakları toplanarak görüntüleri ile bir veri seti oluşturulmuştur. Öncelikle kayısı yaprağı görüntüleri medyan filtre ile ön işleminden geçirilmiştir. Daha sonra VGG19 mimarisi kullanılarak öznelik çıkarımı yapılmıştır. Çıkarılan öznelikler AÖM'ye giriş olarak verilerek kayısı türleri sınıflandırılmıştır. Ayrıca önerilen bitki tanıma sisteminin performansı aynı veri setini kullanarak önceden yaptığımız çalışmaların deneysel sonuçları ile karşılaştırılmıştır.

## II. ÖNERİLEN YÖNTEM

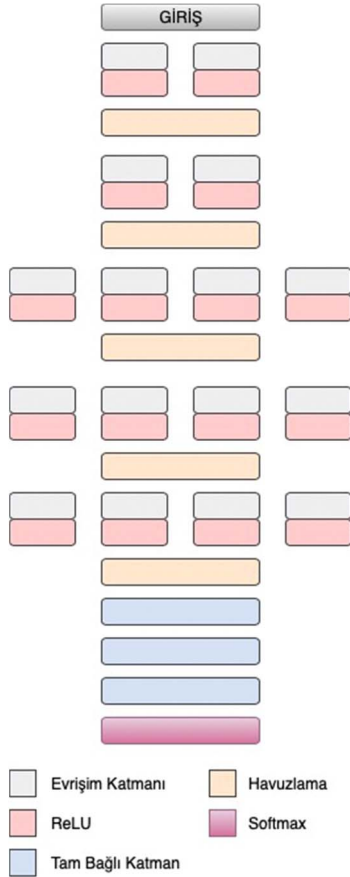
Önerilen yöntem beş temel aşamadan oluşmaktadır. İlk olarak kayısı yaprak görüntüleri 3x3 boyutunda medyan filtreler kullanılarak ön işleminden geçirilmiştir. Daha sonra kayısı görüntüleri önceden eğitilmiş ESA mimarisine giriş olarak verilmiştir. Bu amaçla, VGG19 mimarisi kullanılarak derin öznelik çıkarımı için fc6, fc7 ve fc8 katmanları kullanılmıştır. Çıkarılan derin öznelikler farklı kombinasyonlar ile birleştirilmiştir. Oluşturulan öznelik vektörlerine dayalı kayısı türleri AÖM sınıflandırıcısı ile sınıflandırılmıştır. Önerilen sisteminin prensibi Şekil 1'de verilmiştir.

### A. VGG19 Mimarisi

VGG19 mimarisi, daha önce etkileyici sonuçlar elde ederek ImageNet'de eğitilmiştir. VGG19 mimarisi, Simonyan ve arkadaşlarının önerdiği daha derin bir ESA mimarisidir [12,13]. Mimari, 16 evrişim katmanı ve 3 tam bağlı katmandan oluşmaktadır. Ayrıca maksimum havuzlama, tam bağlı katman, bırakma katmanı, ReLU ve softmax katmanlarıyla toplamda 47 katman bulunmaktadır. Giriş katmanı 224x224x3 boyutundadır [14,15]. Şekil 2, VGG19 mimarisinin yapısını ana hatlarıyla göstermektedir.



Şekil 1. Önerilen yöntemin akış şeması



Şekil 2. VGG19 mimarisi

## B. Aşırı Öğrenme Makineleri

Aşırı öğrenme makinesi (AÖM), Huang ve arkadaşları tarafından geliştirilmiştir [16]. AÖM; giriş ağırlıkları rastgele, çıkış ağırlıkları ise analitik olarak hesaplanan tek gizli katmanlı ileri beslemeli bir YSA modelidir. AÖM’de gizli katmanda sigmoid, sinc, Gauss ve hardlim gibi aktivasyon fonksiyonları kullanılırken çıkış katmanında doğrusal fonksiyon kullanılmaktadır. AÖM, hızlı öğrenebilme yeteneğinin yanında geleneksel geri yayılım algoritması ile öğrenen ileri beslemeli ağlara göre daha iyi genelleme başarımına sahiptir. AÖM’nin öğrenme algoritması aşağıdaki gibi tanımlanır;

Belirli bir  $N$  girdi-çıkı ilişkisi  $x_i$  ve  $t_i$  parametreleri kabul edilsin. Burada  $x_i, x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$  ve  $t_i$  ise  $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$  şeklinde ifade edilir.  $\tilde{N}$  tane gizli sinir hücresi ve  $g(x)$  aktivasyon fonksiyonuna sahip standart Tek Gizli Katmanlı ve İleri Beslemeli (TGKIB) ağ modeli matematiksel olarak aşağıdaki gibi modellenir:

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = o_j, j = 1, \dots, N \quad (1)$$

Burada  $w_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]^T$ ,  $i$ 'nci gizli katman sinir hücresine ve giriş sinir hücresine bağlı olan ağırlık vektörüdür,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$  ise  $i$ 'nci gizli sinir hücresine ve çıkış sinir hücrelerine bağlı olan ağırlık vektörüdür.  $b_i$  ise  $i$ 'nci gizli sinir hücresinin eşik değeridir.  $w_i \cdot x_j$  ise  $w_i$  ve  $x_j$ 'nin içsel çarpımını ifade eder.

$\tilde{N}$  tane gizli sinir hücresine ve  $g(x)$  aktivasyon fonksiyonuna sahip standart TGKIB ortalama sıfır hataya yaklaşabilir.  $\sum_{i=1}^{\tilde{N}} \|o_j - t_j\| = 0$ ,  $\beta_i$ ,  $w_i$  ve  $b_i$  arasındaki ilişki aşağıdaki eşitlikte verilmiştir;

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, j = 1, \dots, N \quad (2)$$

Denklem 2’de verilen  $N$  tane eşitlik, Denklem 3’deki gibi kısaltılabilir:

$$H\beta = T \quad (3)$$

Burada;

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (4)$$

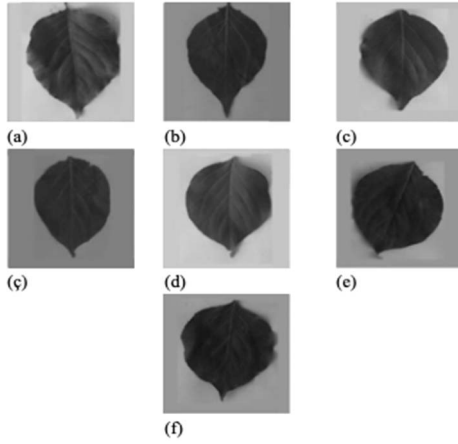
$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad \text{ve} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (5)$$

sinir ağırlığının gizli katmandaki çıkış matrisi  $H$  diye adlandırılır ve  $H$ 'ın  $i$ 'nci sütunu  $x_1, x_2, \dots, x_N$  girişlerinin  $i$ 'nci gizli sinir hücrelerinin çıkış vektörüdür [17].

### III. DENEYSSEL SONUÇLAR

#### A. Veri Seti

Bu çalışmada, Malatya ilinde bulunan Gıda Tarım ve Hayvancılık Bakanlığına bağlı Kayısı Araştırma Enstitüsü Müdürlüğü bahçesinde yetişen kayısı türüne ait 7 farklı genotip için veri tabanı oluşturulmuştur. Bu türler sırası ile Aprikoz Şalak, Çataloğlu, Çekirge İz, Hacıkızı, Hırmanlı, Paviot ve Tokatoğlu Erzincan'dır. Şekil 3'te her bir türe ait bir resim verilmiştir [18]. Bu genotiplere ait ağaçlardan olgunlaşmış yapraklar ziraat mühendisi ile birlikte toplanarak görüntüler veri tabanına kaydedilmiştir. Her yaprak, beyaz bir fon üzerine farklı açılarla yerleştirilmiş ve sabit 30 cm yükseklikten görüntüleri alınarak veri tabana kaydedilmiştir. Görüntünün gerçek boyutlu olabilmesi için bahsedilen yükseklikten ölçümleme (kalibrasyon) yapılmıştır. Ölçüm nesnesi olarak gerçek boyutu bilinen madeni para görüntüsü alınmış, paranın fotoğraftaki boyutları ile gerçek boyutları karşılaştırılmış ve değerlerin aynı olduğu görüldüğünden kullanılan yükseklik geçerli kılınmıştır. Bu şekilde resimlerin gerçek boyutlarından özneteliklerin çıkarılması sağlanmıştır. Veri tabanında yedi farklı kayısı türüne ait 1024x768x3 boyutunda toplam 357 adet kayısı yaprağı görüntüsü yer almaktadır. Görüntüler ön işlemden geçirilerek 224x224 boyutuna dönüştürülmüştür. Her bir kayısı sınıfındaki görüntü sayısı Tablo 1'de verilmektedir.



Şekil 3. Kullanılan kayısı yaprağı sınıflarının birer görüntü örneği ( a)Aprikoz Şalak, b)Çataloğlu, c)Çekirge İz, d)Hacıkızı, e)Hırmanlı, f)Paviot ve g)Tokatoğlu Erzincan)

TABLO 1. VERİ SETİNİ OLUŞTURAN KAYISI TÜRLERİ VE ADETLERİ

Kayısı Türü	Adedi
Aprikoz şalak	55
Çataloğlu	55
Çekirge iz	46
Hacıkızı	42
Hırmanlı	53
Paviot	54
Tokatoğlu Erzincan	52
Toplam	357

#### B. Deneysel Sonuçlar

Önerilen yöntemin kodları Matlab ortamında yazılmıştır. İlk olarak 1024x768x3 boyutundaki görüntüler 224x224 boyutuna dönüştürülmüştür.

VGG19 mimarisine ait tam bağlı katmanlardan fc6 ve fc7'den 4096'şar adet, fc8'den ise 1000 adet öznetelik vektörü elde edilmiştir. Daha sonra, bu öznetelik vektörleri farklı kombinasyonlar ile birleştirilmiştir. Tablo 2'de satırlar VGG19 mimarisine ait fc6, fc7 ve fc8 katmanları tarafından oluşturulan öznetelik vektörlerinin kombinasyonlarını gösterirken ikinci sütun öznetelik sayılarını üçüncü sütun ise doğruluk oranını ifade etmektedir.

Çalışmada aktivasyon fonksiyonu, bazı deneme yanılma adımlarından sonra ReLU olarak belirlenmiştir. 10-kat çapraz doğrulama testi kullanılmış ve gizli katmandaki nöron sayısı 10.000 olarak seçilmiştir.

TABLO 2. KAYISI ÖZNETELİKLERİNİN KULLANIMI VE SINIFLANDIRMA SONUÇLARI

Kullanılan ve Birleştirilen Katmanlar	Öznetelik Sayısı	Doğruluk Oranı (%)
fc6	4096	95,2
fc7	4096	96,2
<b>fc8</b>	<b>1000</b>	<b>98,8</b>
fc6+fc7	8192	95,2
fc6+fc8	5096	96,4
fc7+fc8	5096	96,3
fc6+ fc7+fc8	9192	96,2

Tablo 2 sayısal olarak incelendiğinde sonuçların birbirine yakın olduğu gözlenmektedir. En yüksek doğruluk oranı fc8 katmanından %98,8, en yüksek ikinci doğruluk fc6+fc8 katmanlarının birleşim öznetelik vektöründen %96,4 ile alınırken en düşük doğruluk oranı fc6+fc7 katmanlarının birleşim özneteliklerinden %95,2 olarak alınmıştır.

Tablo 3'de ise önceden eğitilmiş VGG19 mimarisinin kayısı türlerini sınıflandırma performansı verilmiştir.

TABLO 3. VGG19 MIMARISİNİN PERFORMANS SONUÇLARI

Mimari	Doğruluk Oranı (%)
VGG19	95,9

Tablo 2 ve Tablo 3 sayısal olarak incelendiğinde VGG19 mimarisinin kayısı türlerini sınıflandırma performansı derin özneteliklere dayalı AÖM'nin başarısından düşük olduğu görülmektedir. Bu durumun AÖM'nin hızlı öğrenme yeteneğinin yanında geleneksel geri yayılım algoritması ile öğrenen ileri beslemeli ağlara göre daha iyi genelleme başarımına sahip olmasına ya da tam bağlı katmanlarda yer alan işlemlere dayalı oluşmasına bağlı olması olarak düşünülebilir.

Ayrıca önceki yaptığımız [18] ve [19] çalışmaların sınıflandırma performansları ile bu çalışmada önerilen yöntemin sınıflandırma performansı karşılaştırılmıştır.

TABLO 4. SINIFLANDIRMA BAŞARIM PERFORMANSLARI

Kullanılan ve Birleştirilen Katmanlar	Doğruluk Oranı (%)
fc6	95,2
fc7	96,2
<b>fc8</b>	<b>98,8</b>
fc6+fc7	95,2
fc6+fc8	96,4
fc7+fc8	96,3
fc6+ fc7+fc8	96,2
[18]	90,4
[19]	97,3

#### IV. SONUÇLAR

Bitkilerin sınıflandırılması görüntü işleme alanında çalışan birçok araştırmacı için hala popülerliğini korumaktadır. Bu çalışmada son yıllarda popüler olan önceden eğitilmiş derin öğrenme mimarilerinden VGG19 mimarisi kullanılmıştır. Üç farklı tam bağlı katmandan elde edilen öznetelikler farklı şekillerde birleştirilerek AÖM'ye giriş olarak verilmiştir. Bu sayede kayısı türleri yaprak görüntülerinden sınıflandırılmaya çalışılmıştır. Elde edilen sınıflandırma performans sonuçları önceden yaptığımız iki çalışmamızın sınıflandırma performansları ile karşılaştırılmıştır. Bu çalışmanın amacı derin öğrenme mimarilerinin katmanlarından elde edilen öznetelikleri kullanmanın anlamlı sonuçlar üretip üretmediğinin fark edilmesidir. İleriki çalışmalarımız elde edilen öznetelik vektörlerinden literatürde yer alan veya kendimizin önerceği öznetelik seçici algoritmalar ile öznetelik vektör boyutlarını azaltarak sınıflandırma performans sonuçlarına etkisinin incelenmesi olacaktır. Ayrıca AlexNet gibi önceden eğitilmiş derin öğrenme mimarilerinin incelenmesi de planlanan çalışmalarımız arasındadır.

#### KAYNAKLAR

- [1] Zhu, X., Zhu, M., & Ren, H. (2018). Method of plant leaf recognition based on improved deep convolutional neural network. *Cognitive Systems Research*, 52, 223-233.
- [2] Hu, R., Jia, W., Ling, H., & Huang, D. (2012). Multiscale distance matrix for fast plant leaf recognition. *IEEE transactions on image processing*, 21(11), 4667-4672.
- [3] Wang, X., Liang, J., & Guo, F. (2014). Feature extraction algorithm based on dual-scale decomposition and local binary descriptors for plant leaf recognition. *Digital Signal Processing*, 34, 101-107.
- [4] Chaki, J., Parekh, R., & Bhattacharya, S. (2015). Plant leaf recognition using texture and shape features with neural classifiers. *Pattern Recognition Letters*, 58, 61-68.
- [5] Turkoğlu, M., & Hanbay, D. (2019). Leaf-based plant species recognition based on improved local binary pattern and extreme learning machine. *Physica A: Statistical Mechanics and its Applications*, 527, 121297.
- [6] Şekeroğlu, B., & İnan, Y. (2016). Leaves recognition system using a neural network. *Procedia Computer Science*, 102, 578-582.
- [7] Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience*, 2016.
- [8] Shah, M. P., Singha, S., & Awate, S. P. (2017, September). Leaf classification using marginalized shape context and shape+ texture dual-path deep convolutional neural network. In *2017 IEEE International Conference on Image Processing (ICIP)* (pp. 860-864). IEEE.
- [9] Doğan, F., & Türkoğlu, İ. (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- [10] Tang, Z., Su, Y., Er, M. J., Qi, F., Zhang, L., & Zhou, J. (2015). A local binary pattern based texture descriptors for classification of tea leaves. *Neurocomputing*, 168, 1011-1023.
- [11] Aakif, A., & Khan, M. F. (2015). Automatic classification of plants based on their leaves. *Biosystems Engineering*, 139, 66-75.
- [12] Cıbuk, M., Budak, U., Guo, Y., Ince, M. C., & Sengur, A. (2019). Efficient deep features selections and classification for flower species recognition. *Measurement*, 137, 7-13.
- [13] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- [14] Zhou, B., Lapedriza, A., Xiao, J., Torralba, A., & Oliva, A. (2014). Learning deep features for scene recognition using places database. In *Advances in neural information processing systems* (pp. 487-495).
- [15] Donahue, J., Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E., & Darrell, T. (2014, January). Decaf: A deep convolutional activation feature for generic visual recognition. In *International conference on machine learning* (pp. 647-655).
- [16] Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501.
- [17] Sengur, A. Derin Aşırı Öğrenme Makinesi ile Yüz Tanıma.
- [18] Arı, B., Şengür, A., & Arı, A. (2016, September). Local receptive fields extreme learning machine for apricot leaf recognition. In *International Conference on Artificial Intelligence and Data Processing (IDAP16)* (pp. 17-18).
- [19] Arı, B., Sengur, A., Arı, A., & Hanbay, D. (2016, March). Apricot Plant Classification Based On Leaf Recognition by Using Convolutional Neural Networks. In *International Conference on Natural Science and Engineering (ICNASE'16)*, Kilis, Türkiye (pp. 19-20).