



Plant recognition system based on extreme learning machine by using shearlet transform and new geometric features

Muammer Türkoğlu^{1*}, Davut Hanbay²

¹Department of Computer Engineering, Bingöl University, Bingöl, 12000, Turkey

²Department of Chemical Engineering, Inonu University, Malatya, 44280, Turkey

Highlights:

- A new ES-based feature extraction method for plant classification
- Hybrid feature extraction network based plant classification system
- High classification performance

Keywords:

- Leaf Recognition
- Image Processing
- Shearlet Transform
- Edge Step Method
- Extreme Learning Machines

Article Info:

Research Article

Received: 17.05.2018

Accepted: 15.04.2019

DOI:

10.17341/gazimmfd.423674

Correspondence:

Author: Muammer Türkoğlu
e-mail: mturkoglu@bingol.edu.tr
phone: +90 545 545 1223

Graphical/Tabular Abstract

The proposed hybrid system includes an image-based leaf identification system consisting of three main phases which pre-processing, feature extraction, and classification. According to the working principle of feature extraction methods, a number of pre-treatment methods have been applied. Then, the z-score normalization process is applied by combining all the features obtained from these methods. Finally, the classification and testing step are carried out using the Extreme Learning Machines method.

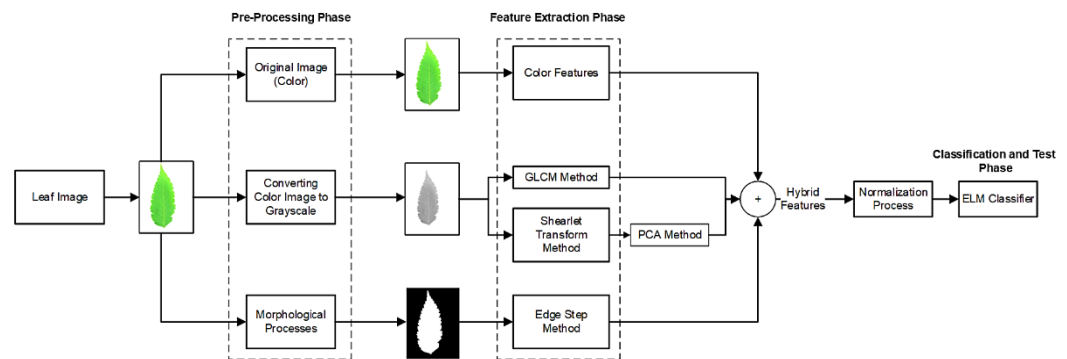


Figure A. General flow chart of recommended system

Purpose: The purpose of this study is to develop a plant recognition system based on shape, texture and color features using leaf images. The proposed hybrid system aims to extract the distinctive features of the leaf.



Theory and Methods: In this study, a new approach based on the edge points in the boundary curves of the leaf is proposed. This approach called edge step (ES) examines the differences between the boundary curves and geometric shapes of the leaf based on the angle, center-edge length, and edge distance characteristics. In addition, Shearlet Transform based feature extraction method was used to extract the invariant textural properties of the leaves. In addition to these methods, Gray-Level Co-Occurrence Matrix (GLCM) method and Color features were used to reveal differences between leaf vein tissues, which is an important distinguishing factor in plant classification. By combining the features obtained from all these methods, a deep and hybrid-based feature extraction system has been developed for the leaves. Finally, the features obtained from all these methods were tested performances as individually and hybrid performances by using the Extreme Learning Machines (ELM) classifier method.

Results: The proposed hybrid system has been tested using four leaf-based plant data sets such as Flavia, Swedish, ICL, and Foliage. According to these experimental results, the calculated accuracy values for Flavia, ICL, Swedish and Foliage datasets were 98.31%, 93.71%, 99.46%, and 96.62%, respectively. The results demonstrate that the proposed hybrid system was more successful when compared to the other studies based on shape, texture, and color features.

Conclusion: In this study, a hybrid system has been proposed to reveal the distinctive features based shape and texture of the leaf. The deep-hybrid system which is developed for the classification of leaf-based plant species is practical and applicable as well as having higher performances than previous studies.



Shearlet dönüşüm ve yeni geometrik özellikler kullanılarak aşırı öğrenme makinesine dayalı bitki tanıma sistemi

Muammer Türkoğlu^{1*} , Davut Hanbay² 

¹Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Bingöl, 12000, Türkiye

²İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Malatya, 44280, Türkiye

Ö N E Ç İ K A N L A R

- Bitki sınıflandırma için KA tabanlı yeni bir özellik çıkarma yöntemi
- Hibrit özellik çıkarma ağı tabanlı bitki sınıflandırma sistemi
- Yüksek sınıflandırma performansı

Makale Bilgileri

Araştırma Makalesi
Geliş: 17.05.2018
Kabul: 15.04.2019

DOI:

10.17341/gazimmfd.423674

Anahtar Kelimeler:

Yaprak tanıma,
görüntü işleme,
shearlet dönüşüm,
kenar adım yöntemi,
aşırı öğrenme makineleri

ÖZET

Bugüne kadar yapılan çalışmalarda, bitki türlerini doğru tespit edebilmek için farklı yaklaşımlar kullanılmıştır. Bu yaklaşımlardan en önemlisi ve bitki kısmı olarak yapraklar, şekil, renk ve damar dokusu gibi avantajlara sahip birçok özellik sağlamaktadır. Bu çalışmada açıdan bağımsız olarak yaprağın geometrik özelliklerine dayalı yeni bir yaklaşım önerilmiştir. Kenar Adım (KA) olarak adlandırılan bu yöntem, şeklin sınır eğrilerindeki kenar noktalar kullanılarak açı, merkez-kenar uzunluğu ve kenar mesafesi gibi özelliklerden oluşmaktadır. Ayrıca doku tanımada iyi hassasiyet göstermesi, hızlı hesaplama yapması ve yön bağımsızlığı gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi kullanılmıştır. Bu yöntemlere ek olarak, yaprak görüntülerinden renk ve doku özelliklerini çıkarmak için Renk Özellikleri ile Gri Seviye Eş-Oluşum Matrisleri (GSEM) yöntemi kullanılmıştır. Tüm bu yöntemlerden elde edilen özellikler ayrı ayrı ve bileşik olarak Aşırı Öğrenme Makineleri (AÖM) sınıflandırıcı yöntemi ile test edilmiştir. Flavia, Swedish, ICL ve Foliage gibi dört farklı bitki yaprak veri setleri kullanılarak önerilen çalışma test edilmiştir. Bu veri setleri kullanılarak doku, şekil ve renk özelliklerine dayalı yapılan çalışmalar ile önerilen yaklaşımın performansı kıyaslanmıştır. Sonuç olarak, önerilen çalışmanın diğer çalışmalara göre daha başarılı olduğu tespit edilmiştir.

Plant recognition system based on extreme learning machine by using shearlet transform and new geometric features

H I G H L I G H T S

- A new ES-based feature extraction method for plant classification
- Hybrid feature extraction network based plant classification system
- High classification performance

Article Info

Research Article
Received: 17.05.2018
Accepted: 15.04.2019

DOI:

10.17341/gazimmfd.423674

Keywords:

Leaf recognition,
image processing,
shearlet transform,
edge step method,
extreme learning machines

ABSTRACT

To date, different approaches have been used to be correctly identified of plant species. Leaves are the most important approaches as part of the plants which provide many features with advantages such as shape, color and vein texture. In this study, a new approach based on the geometrical properties of the leaf has been proposed. This method called Edge Step (ES), consists of features such as angle, center-edge length and edge distance by using edge points in the shape boundary curve. In addition, Shearlet Transform method, which has features such as good sensitivity to tissue identification, rapid calculation and directional independence, is used. In addition to these methods, Color features and Gray-Level Co-Occurrence Matrix (GLCM) method to extract color and texture properties from leaf images have been applied. Attributes derived from all these methods were tested with the Extreme Learning Machine (ELM) classifier method as separately and combination. The proposed study has been tested by using four different plant leaf datasets such as Flavia, Swedish, ICL and Foliage. Using these datasets, studies based on texture, shape and color characteristics have been compared with the performance of the proposed approach. As a result, the proposed method is identified to be more successful than the other methods.

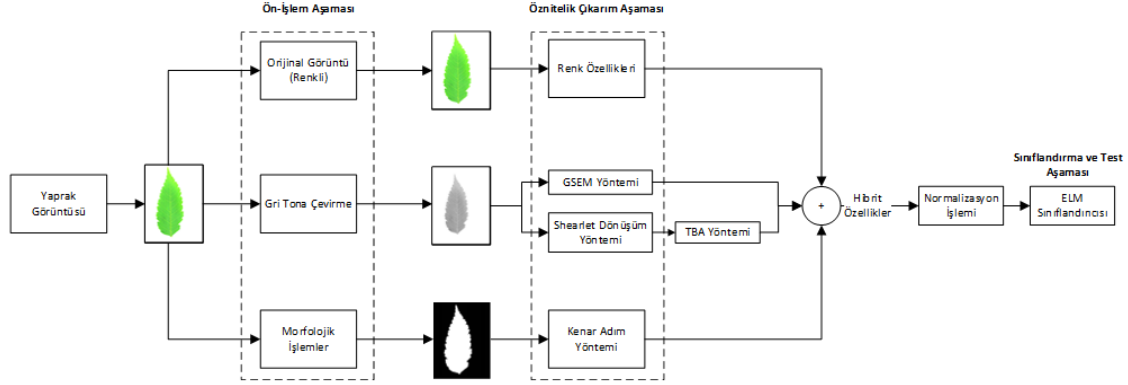
1. GİRİŞ (INTRODUCTION)

Bitkiler, dünyadaki yaşamın önemli bir parçasını oluşturmaktadır. Endüstri, beslenme, oksijen, tıbbi ve daha birçok alanlarda yaygın olarak kullanılmaktadırlar. Bu yüzden, yeni veya nadir bulunan bitki türlerinin belirlenmesi önemlidir [1, 2]. Bir bitkinin hangi türe ait olduğunu belirlemek uzman olmayan kişiler için çok zor olmaktadır. Bu tür işlemlerde uzman olarak en önemli rolü botanik ve ziraat üzerine ihtisaslaşmış kişiler üstlenmektedir. Uzmanlar tarafından bitki türlerinin belirlenmesi genel olarak görsel muayene ve daha sonrasında laboratuvar ortamında incelemeler olmak üzere iki ana aşamadan oluşmaktadır. Nihayetinde bu geleneksel yöntemler zaman alıcı, yorucu ve karmaşık süreçler içermektedir. Çünkü binlerce bitki arasından bir bitkinin türünü belirlemek için birçok biyolojik test ve mikroskopik araştırma yapılmaktadır. Özellikle aynı familyadan olan bitkiler benzer karakteristiklere sahip olduğu için kapsamlı analizlerin yapılması gerekmektedir [3]. Bitki tanıma süreci, önemli ve zor bir görevdir. Bitki tanıma sürecinde hücre ve molekül biyolojisi gibi birçok yönetime kıyasla bitki yapraklarına dayalı sınıflandırma en önemli etken olduğu gözlenmiştir. Çünkü bitki yapraklarının kolayca toplanabilir olması ile birlikte şekil, renk ve damar dokusu gibi birçok özellikleri içermesinden dolayı bitki sınıflandırılması için temel bir bileşen olmuştur. Bu yüzden, yaprak tanıma son yıllarda bilgisayar görmesi alanında popüler bir konu haline gelmiştir [1, 2].

Bitki yaprakları kullanılarak bitki türlerini sınıflandırma konusunda literatürde birçok çalışma mevcuttur. Yapılan çalışmaların büyük bir kısmında, Flavia [4], Swedish [5], ICL [6] ve Foliage [7] gibi etkili veri setleri kullanılmıştır. Wu vd. [4] çalışmalarında, bitki sınıflandırmak için temel geometrik özellikler kullanılarak yeni özellikler türetmişlerdir. Elde edilen bu özelliklerin sınıflandırılmasında ise Olasılıksal Sinir Ağı (OSA) yöntemi kullanılarak %90 başarımlı oranı elde edilmiştir. Mahdikhanlou vd. [8], yaprak şeklinin geometrik özelliklerine dayalı Merkez Kenar Uzunluğu (MKU) ve En Az Eylemsizlik Eksenini yöntemlerini önermişlerdir. Bu yöntemlerden elde edilen özellikler kullanılarak OSA yöntemi ile sınıflandırılmıştır. Swedish yaprak veri setlerinde başarımlı %82,05 iken Flavia yaprak veri setlerinde ise %80,10 olarak hesaplanmıştır. Kadir vd. [7] tarafından renk özellikleri, GSEM, ağız özellikleri ve Polar Fourier Dönüşüm (PFD) yöntemleri kullanılarak yapraklara ait özellikler çıkarılmıştır. Sınıflandırıcı olarak OSA yöntemi kullanılarak başarımlı oranları hesaplanmıştır. Yasar vd. [9], özellik çıkarım yöntemlerinden şekil ve doku özelliklerine dayalı bir sistem önermişlerdir. Bu yöntemlerden her bir görüntüye ait elde edilen 16 tane özellik, Levenberg-Marquardt algoritması tabanlı Yapay Sinir Ağı (YSA) modeli ile sınıflandırılmıştır. Lee vd. [10] çalışmalarında, geometrik ve morfolojik özellikler ile birlikte Hızlı Fourier Dönüşüm (HFD) yöntemine dayalı bir sistem önermişlerdir. Kadir vd. [11] tarafından renk özellikleri, GSEM, geometrik özellikler ve Zernike Momentler gibi özellik çıkarım

yöntemleri kullanılmıştır. Bu yöntemlerden elde edilen özellikler kullanılarak OSA, Öklid Uzaklığı ve Şehir Mesafe Uzaklığı yöntemleri ile sınıflandırılmıştır. Sari vd. [12], şekil özellikleri, Fourier tanımlayıcıları ve Çok-Boyutlu Mesafe Matrisi (ÇMM) yöntemlerinin birlikte kullanılmasına yönelik bir yaklaşım önermişlerdir. İki farklı veri setinin kullanıldığı bu çalışmada elde edilen özellikler Kuadratik diskriminant analizi (KDA), Destek Vektör Makinaları (DVM) ve k-En Yakın Komşu (k-EYK) yöntemleri ile sınıflandırılarak başarımlı oranları hesaplanmıştır. Naresh vd. [13] çalışmalarında, doku özelliklerine dayalı bitki yapraklarını sınıflandırmak için sembolik bir yaklaşım önermişlerdir. Bitki yapraklarından doku özelliklerini çıkarmak için Değiştirilmiş Yerel İkili Örüntüler (DYİÖ) yöntemi kullanılmıştır. Sınıflandırma aşamasında ise k-EYK yöntemi kullanılarak sistem başarımlı oranları gözlenmiştir. Kadir vd. [14] tarafından renk özellikleri, ağız özellikleri ve PFT yöntemleri kullanılarak yapraklara ait özellikler çıkarılmıştır. Elde edilen bu özellikler, Öklid Uzaklığı yöntemi ile sınıflandırılmıştır. Elhariri vd. [15] çalışmalarında, renk özellikleri, ağız özellikleri, şekil özellikleri ve doku özelliklerine dayalı bir sistem önermişlerdir. Farklı türde bitkileri sınıflandırmak için Rastgele Ormanlar (RO) ve Lineer Ayırt Etme Analizi (LAA) algoritmalarına dayalı sınıflandırıcı yöntemleri kullanmışlardır. Priya vd. [16], temel geometrik özellikler kullanılarak yeni özellikler türetmişlerdir. Elde edilen özellikler DVM yöntemi ile sınıflandırılarak önerilen yaklaşımın geçerliliği test edilmiştir. Tsolakidis vd. [17] tarafından bitki yaprak görüntülerinin sınıflandırılmasında Zernike Momentleri ve Yönlendirilmiş Gradyanların Histogramı (YGH) yöntemlerini içeren bir yaklaşım önerilmiştir. Ön işlem aşamasında sonra, Zernike Momentler kullanılarak şekil özelliklerini ve YGH yöntemi kullanılarak doku özellikleri hesaplanmıştır. Son olarak bitki yaprak görüntülerini sınıflandırmak ve tanımak için SVM sınıflandırıcısı kullanılmıştır. Kadir vd. [18] çalışmalarında, boyut azaltma yöntemi olan Temel Birleşen Analizi (TBA) yöntemine dayalı yaprak tanıma sistemi geliştirilmiştir. Şekil özellikleri, renk özellikleri, ağız özellikleri, Fourier Tanımlayıcıları ve GSEM yöntemleri kullanılarak bitki yapraklarına ait özellikler çıkarılmıştır. OSA yöntemi ile elde edilen özellikler sınıflandırılarak başarımlı oranları hesaplanmıştır. Wang vd. [19] bitki yaprağı görüntülerinden ayırt edici özelliklerin çıkarılması ve gürültüyle bozulma olasılığını azaltmak için, çift ölçekli ayrıştırma ve yerel ikili örüntüler yöntemlerine dayanan yeni bir özellik çıkarım algoritması önermişlerdir. Son olarak elde edilen bu özellikler k-EYK yöntemi kullanılarak sınıflandırma performansı hesaplanmıştır.

Bu çalışmada, bitki türlerini tanımlamak için MKU yönteminden esinlenerek yeni bir yaklaşım önerilmiştir. Kenar adım (KA) olarak adlandırılan bu yöntem; açı, merkez-kenar uzunluğu ve kenar mesafe özelliklerine dayalı yaprağın sınır eğrileri ve geometrik şekilleri arasındaki farklılıkları incelemektedir. Gerçekleştirilen deneysel çalışmalar sonucunda, KA yöntemi MKU yöntemine göre



Şekil 1. Önerilen Sistemin Genel Akış Şeması (General Flow Chart of Recommended System)

daha üstün performansa sahip olduğu gözlenmiştir (Tablo 7). Önerilen çalışmada, doku tanımda iyi hassasiyet göstermesi, hızlı hesaplama yapması ve yön bağımsızlığı gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi de kullanılmıştır. Bu yöntemlere ek olarak, yaprak görüntülerinden renk ve doku özelliklerini çıkarmak için istatistiksel momentlere dayalı Renk Özellikleri ile GSEM yöntemi kullanılmıştır. KA, Shearlet dönüşüm, renk özellikleri ve GSEM yöntemlerinden elde edilen öznitelikler, AÖM sınıflandırıcısı kullanılarak bireysel ve genel performansları hesaplanmıştır. Bu çalışmada, önerilen sistemin ana katkıları şunlardır;

- Önerilen KA yöntemi MKU yönteminin geliştirilmiştir bir versiyonudur. MKU yönteminde parametre olarak girilen açıya bağlı olan merkez kenar uzunluğu özellik olarak kullanılırken, KA yönteminde adımlar parametre olarak girilmektedir. Adım parametresi kullanılarak açı, merkez kenar uzunluğu ve kenar mesafe uzunlukları hesaplanır. Bu değerlere istatistiksel momentler uygulanarak 15 özellik elde edilir. Yapılan deneysel çalışmalar sonucunda, KA yönteminin MKU yönteminden daha başarılı olduğu gözlenmiştir. Bu makalede KA yöntemi ile bitki sınıflandırılması için yeni, basit ve efektif bir yaklaşım önerilmiştir.
- Yaprakların değişmez dokusal özelliklerini çıkarmak için Shearlet dönüşümü tabanlı bir özellik çıkarma yöntemi kullanılmıştır. Bu yöntemle ek olarak, bitki sınıflandırılmasında önemli bir ayırt edici etken olan yaprak damar dokuları arasındaki farklılıkları ortaya çıkarabilmek için pikseller arasındaki değişimleri hesaplayan GSEM yöntemi ve renk özellikleri kullanılmıştır. KA özellikleri ve bu maddede bahsettiğimiz metotlardan elde edilen özellikler birleştirilerek yapraklar için derin bir özellik çıkarma sistemi önerilmiştir.
- Elde edilen özelliklerin sınıflandırılması için AÖM yöntemi seçilmiştir. Bu sınıflandırma yönteminin en önemli avantajı eğitim süresinin hızlı olması ve büyük veriler için uygun ve düşük maliyetli bir sınıflandırıcı olmasıdır.
- Bu makalede literatürde yaygın olarak kullanılan 4 veri seti kullanılmıştır. Önerilen yöntem, literatürde daha

önceden yapılan çalışmalarla karşılaştırılmış ve en iyi sınıflandırma başarımını elde etmiştir.

- Sonuç olarak, bu makalede bitki türlerini sınıflandırmak için yüksek performansa sahip, basit ve etkili bir sistem önerilmiştir.

Çalışmanın ikinci bölümünde uygulama adımları, teorik bilgiler ve veri setleri anlatılmıştır. Üçüncü bölümde deneysel sonuçlar görsel ve sayısal olarak sunulmuştur. Çalışmanın sonuçları ise son bölümde yer verilmiştir.

2. MATERYALLER VE YÖNTEMLER (MATERIALS AND METHODS)

Önerilen çalışma, üç ana işlemten oluşan görüntü tabanlı yaprak tanımlama sistemini içermektedir. Bu işlemler sırasıyla ön-işlem, öznitelik çıkarım ve sınıflandırıcı aşamalarından oluşmaktadır. Önerilen yöntemin çalışma prensibi Şekil 1’de gösterilmiştir.

2.1. Ön-İşlem Aşaması (Pre-processing Phase)


Ön-işlem aşaması, yaprak görüntülerini bölütleme ve belirginleştirme işlemlerini kapsamaktadır. Bu aşamada, ilk olarak renkli yaprak görüntülerini gri tona çevirme işlemi yapılmıştır. İkinci adımda, normalizasyon işlemi kullanılarak daha net ve belirgin bir görüntü elde edilmiştir. Daha sonra deneme yanılma yöntemiyle uygun eşik değeri seçilerek bölütleme işlemi uygulanmıştır. Son adımda ise, aşınma, dolun ve mantıksal işlemler kullanılarak gürültüleri temizleme ve görüntüyü belirginleştirme işlemleri gerçekleştirilmiştir. Bu aşamada kullanılan adımlar Şekil 2’de gösterilmiştir.

Şekil 2’de gösterilen ön-işlem aşamasının matematiksel ifadelerle dayalı işlem adımları aşağıda verilmiştir.

Adım 1: Renkli imgeyi yükle.

Adım 2: Renkli imgeyi gri seviyeye çevir.

$$\text{gri} = R * 0.2989 + G * 0.5870 + B * 0.1140 \quad (1)$$



Şekil 2. Gürültü giderme adımları (Noise removal steps)

$$R = \text{renkli}(:, :, 1) \quad (2)$$

$$G = \text{renkli}(:, :, 2) \quad (3)$$

$$B = \text{renkli}(:, :, 3) \quad (4)$$

Yukarıdaki denklemlerde R, G, B sırasıyla kırmızı, yeşil ve mavi renk katmanlarıdır.

Adım 3: Gri resmi 0-1 aralığında normalize et.

$$gri^N = \frac{gri - \min(gri)}{\max(gri) - \min(gri)} \quad (5)$$

Eş. 5'de, gri^N normalize edilmiş gri resmi, $\min(gri)$ gri imgenin en küçük değeri ve $\max(gri)$ gri imgenin en büyük değerini temsil etmektedir.

Adım 4: Eşikleme değeri olan t değerini imgenin histogramını kullanarak belirle. (Flavia, ICL, Swedish ve Foliage veri setleri için sırasıyla 210, 130, 160 ve 185 olarak eşik değerleri belirlenmiştir.)

Adım 5: t değerini kullanarak normalize edilmiş gri imgeyi siyah beyaz forma dönüştür.

$$sb_{i,j} = \begin{cases} 0, & gri_{i,j}^N < t \\ 1, & gri_{i,j}^N \geq t \end{cases}, i = \{1, 2, \dots, M\} \quad j = \{1, 2, \dots, N\} \quad (6)$$

Eş. 6'da, sb siyah beyaz imgeyi, M ve N gri imgenin genişliğini ve uzunluğunu, i ve j değerleri ise indisleri temsil etmektedir.

Adım 6: 3×3 boyutunda örtüşen bloklar kullanılarak dolun, aşınma ve mantıksal işlemler uygula. Mantıksal işlemde siyah ve beyaz noktaların temizlenmesi amaçlanmaktadır.

$$sb = ((sb \oplus k) \ominus k) \odot k \quad (7)$$

Eş. 7'de, \oplus dolun, \ominus aşınma ve \odot mantıksal operatörü ifade etmektedir. k ise 3×3 boyutundaki blokları temsil etmektedir.

2.2. Öznitelik Çıkarım Aşaması (Attribute Extraction Phase)

Bu bölümde, bitki türlerinin sınıflandırılması için kullanılan KA, Shearlet Dönüşüm, Renk özellikleri ve GSEM yöntemlerinden bahsedilmiştir. Bu yöntemlerin, bitki yaprakları için ayırt edici yönleri aşağıda verilmiştir.

- Bu çalışmada, yaprağın geometrik özelliklerine dayalı yeni bir yaklaşım önerilmiştir. KA olarak adlandırılan bu yaklaşım; açı, merkez-kenar uzunluğu ve kenar mesafe özelliklerine dayalı yaprağın sınır eğrileri ve geometrik şekilleri arasındaki farklılıkları incelemektedir.
- Doku tanımda iyi hassasiyet göstermesi ve yön bağımsızlığı gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi kullanılmıştır.
- Bitki yapraklarının damar dokuları, bitki sınıflandırılması için önemli bir ayırt edici etkidir. Bu damarlar, görsel olarak ince, kaba ve sürekli-sürekli çizgili gibi değişik özelliklerde olabilmektedir. Bu çalışmada, bitki yapraklarındaki farklı dokuları ortaya çıkarmak için GSEM yöntemi kullanılmıştır. Bu yöntem, yaprak doku özelliklerine çıkarmak için ikili piksel grupları arasındaki gri seviyesi değişimlerinin farklı kombinasyonlarını hesaplamaktadır.
- Bitki türleri arasında şekil ve doku dışında renk özellikleri bakımından da önemli farklılıklar bulunmaktadır. Bu yüzden, istatistiksel momentler kullanılarak yaprak görüntülerinin renk dağılımlarına dayalı ayırt edici özellikler de kullanılmıştır.

Bu yöntemler devam eden alt başlıklarda teorik altyapısı detaylandırılmıştır.

2.2.1. Kenar adım yöntemi (Edge step method)

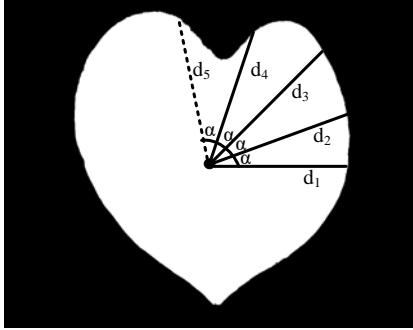
Kenar Adım (KA) yöntemi, MKU yönteminden esinlenerek önerilmiştir. MKU yöntemi, nesnenin ağırlık merkezinin sınır eğrilerine olan uzaklığıdır. Şekil 3'de gösterildiği gibi, ağırlık merkezi temel alınarak koordinat düzleminin x eksenine göre α derece artırılarak toplamda n ($n=360/\alpha$) adet olmak üzere sınır eğrilerine uzaklık değerleri ($d_1, d_2, d_3, \dots, d_n$) hesaplanır. Elde edilen bu değerler görüntünün öznitelikleri olarak kabul edilir.

KA yöntemi ise şeklin sınır eğrilerindeki kenar noktaları kullanılarak açı, merkez-kenar uzunluğu ve kenar mesafe gibi özelliklerden oluşmaktadır. Bu yöntem, açıdan bağımsız olarak ve şeklin sınır eğrisindeki piksel uzunlukları dikkate alınarak çalışmaktadır. Eş. 8'de, x adım değeri verilerek şeklin sınır eğrileri arasında eşit piksel uzunluklarında kenar noktaları belirlenir.

$$n = \frac{P}{x}, \quad K = k_1, k_2, k_3, \dots, k_n \quad (8)$$

Burada P şeklin çevresi, n toplam kenar sayısı, x adım değeri ve K ise kenar noktalarıdır. $k_1, k_2, k_3, \dots, k_n$ gibi ardışık kenar noktaları arasındaki mesafeler eşit piksel uzunluğuna

sahiptir. Şekil 4’de örnek bir yaprak için KA yönteminin çalışma prensibi verilmiştir.



Şekil 3. Örnek bir yaprak için MKU yaklaşımı (CCD approach for a sample leaf)

Şekil 4’de gösterildiği gibi, $k_1, k_2, k_3, \dots, k_n$ kenar noktaları tespit edildikten sonra aşağıda verilen istatistiksel formüllere dayalı üç farklı değişken (açı, merkez-kenar uzunluğu ve kenar mesafe) kullanılarak öznelik çıkarım işlemi yapılmaktadır. Bu istatistiksel parametreler Tablo 1’de verilmiştir.

- *Açı (α):* Şeklin ağırlık merkezi ile $k_1 - k_2, k_2 - k_3, \dots, k_n - k_1$ gibi kenar noktaları arasındaki açı değerleri $\alpha_1, \alpha_2, \dots, \alpha_n$ olarak hesaplanır (Şekil 4(a)). Ortalama, standart sapma, varyans, basıklık, çarpıklık ve en büyük değerin en küçük değere oranı (mm) gibi istatistiksel formüller kullanılarak $\alpha_1, \alpha_2, \dots, \alpha_n$ değerlerinden 6 öznelik elde edilmiştir.
- *Merkez-Kenar Uzunluğu (d):* Şeklin ağırlık merkezi ile $k_1, k_2, k_3, \dots, k_n$ gibi kenar noktaları arasındaki uzaklıklar Öklid formülü kullanılarak $d_1, d_2, d_3, \dots, d_n$ olarak hesaplanır (Şekil 4(b)). Ortalama, standart sapma, varyans, basıklık, çarpıklık ve en büyük değerin en küçük değere oranı gibi istatistiksel formüller kullanılarak $d_1, d_2, d_3, \dots, d_n$ değerlerinden 6 öznelik elde edilmiştir.
- *Kenar mesafesi (p):* $k_1 - k_2, k_2 - k_3, \dots, k_n - k_1$ gibi kenar noktaları arasındaki uzaklıklar Öklid formülü kullanılarak $p_1, p_2, p_3, \dots, p_n$ olarak hesaplanır (Şekil 4(c)). Ortalama, standart sapma ve ortalama kenar mesafesi (k)

gibi istatistiksel formüller kullanılarak $p_1, p_2, p_3, \dots, p_n$ değerlerinden 3 öznelik elde edilmiştir.


Tablo 1. İstatistiksel Denklemler (Statistical equations)

Ortalama:	$\mu = \frac{1}{N} \sum_{i=1}^N A_i$
Standart Sapma:	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N A_i - \mu ^2}$
Varyans:	$V = \frac{1}{N} \sum_{i=1}^N A_i - \mu ^2 = \sigma^2$
Basıklık:	$\gamma = \frac{\sum_{i=1}^N (A_i - \mu)^4}{N\sigma^4} - 3$
Çarpıklık:	$\theta = \frac{\sum_{i=1}^N (A_i - \mu)^3}{N\sigma^3}$
En Büyük Değerin En Küçük Değere Oranı:	$mm = \frac{\text{Max}(A)}{\text{Min}(A)}$
Ortalama Kenar Mesafesi:	$m = \left(\sum_{i=1}^N A_i \right) / P$

Tablo 1’de, A, açı ($\alpha_1, \alpha_2, \dots, \alpha_n$), merkez-kenar uzunluğu ($d_1, d_2, d_3, \dots, d_n$) veya kenar mesafesi ($p_1, p_2, p_3, \dots, p_n$) değerlerini içeren diziyi, N dizinin boyutunu, P şeklin çevresini ve i ise satır değerlerini temsil etmektedir. En Büyük Değerin En Küçük Değere Oranı denkleminde, açı, merkez-kenar uzunluğu veya kenar mesafelerinden elde edilen $1 \times N$ boyutundaki dizinin maksimum ve minimum değerlerinin birbirlerine oranını ifade etmektedir. Ortalama Kenar Mesafesi denkleminde ise sadece kenar mesafelerinin ($p_1, p_2, p_3, \dots, p_n$) her birinin şeklin çevresine oranlarının toplamını temsil etmektedir.

2.2.2. Renk özellikleri (Color features)

Bitki türlerinin sınıflandırılmasında yaprak görüntülerinin renk özellikleri önemli bir ayırt edici etmendir [7, 11, 14, 15]. Bu çalışmada, yaprak görüntülerinin renk dağılımları; ortalama, varyans, çarpıklık ve basıklık gibi istatistiksel momentler kullanılarak elde edilmiştir. Bu özellikler



Şekil 4. Örnek bir yaprak için KA yaklaşımı a) Açılar (α) b) Merkez-Kenar Uzunlukları (d) c) Kenar mesafeleri (p)

(ES approach for a sample leaf a) Angles (α) b) Edge-Center Lengths (d) c) Edge distances (p)

hesaplanırken, yaprak görüntüleri dışındaki renkli/renksiz kısımlar elemine edilmiştir. Ayrıca, yaprak görüntülerinin her bir kanalı için (R, G ve B) renk özellikleri çıkartılmıştır. Renk özelliklerinin çıkartılması için kullanılan istatistiksel formüller Tablo 2’de verilmiştir [7, 14];

Tablo 2. İstatistiksel formüller (Statistical formulas)

Ortalama:	$\mu = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N p_{ij}$
Standart Sapma:	$\sigma^2 = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (p_{ij} - \mu)^2}$
Basıklık:	$\gamma = \frac{\sum_{i=1}^M \sum_{j=1}^N (p_{ij} - \mu)^4}{MN\sigma^4} - 3$
Çarpıklık:	$\theta = \frac{\sum_{i=1}^M \sum_{j=1}^N (p_{ij} - \mu)^3}{MN\sigma^3}$

Tablo 2’de, $M \times N$ boyutundaki görüntülerine dayalı istatistiksel formüller gösterilmiştir. Burada M ve N resmin boyutunu, i ve j sırasıyla satır ve sütun renk değerlerini belirtir.

2.2.3. Gri seviye eş oluşum matrisi (Gray-Level Co-occurrence matrix)

GSEM, gri ölçekli bir görüntünün özelliklerini çıkarmak için iki komşu piksel arasındaki ilişkiyi temel almaktadır. Bu yöntem, görüntülerden doku özellikleri çıkartmak ve incelemek için kullanılan istatistiksel bir yöntemdir [21-23]. GSEM, 1970’lerde Haralick tarafından doku tanımlanması için önerilmiştir [24]. Nesne tanıma alanında yapılan çalışmalarda iyi performans göstermesi sayesinde popüler ve yaygın olmuştur [23]. Haralick, görüntü hakkında entropi, enerji, homojenlik ve korelasyon gibi 14 tane doku özelliği tanımlamıştır. Bu çalışmada, nesne tanıma ile ilgili önceki çalışmalarda yaygın olarak kullanılan ve performansı yüksek olan 5 adet doku özelliği kullanılmıştır. Bunlar;

1) Kontrast,

$$\sum_{ij} |i - j|^2 p(i, j) \quad (9)$$

2) Korelasyon,

$$\sum_{ij} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (10)$$

3) Enerji,

$$\sum_{ij} p(i, j)^2 \quad (11)$$

4) Entropi,

$$\sum_{ij} p(i, j) \log_2 p(i, j) \quad (12)$$

5) Homojenlik,

$$\sum_{ij} \frac{p(i, j)}{1 + |i - j|} \quad (13)$$

Eş. 9-13’de, i ve j satır-sütun indislerini, p indislerin belirttiği GSEM elemanını, μ ortalamayı ve σ standart sapmayı temsil etmektedir.

2.2.4. Shearlet dönüşüm yöntemi (Shearlet transform method)

Shearlet dönüşümü [25,26], görüntülerin analiz edilmesinde daha basit matematiksel yaklaşım kullanılmaktadır. Görüntülerin istenen ölçek ve yönde frekans bileşenlerini basit matematiksel yaklaşımlarla daha esnek geometrik yapılar içinde detaylı bir analiz imkânı sağlamaktadır [27-29]. Shearlet fonksiyonu kutupsal koordinat sisteminde şöyle tanımlanır;

$$\psi_{a,s,t}(x) = |\det M_{a,s}|^{-\frac{1}{2}} \Psi(M_{a,s}^{-1} x - t) \quad (14)$$

$a > 0, s \in R, t \in R^2$ için $M_{a,s} = \begin{pmatrix} a & \sqrt{as} \\ 0 & \sqrt{a} \end{pmatrix}$ olarak ifade edilir. Anlaşılacağı gibi $M_{a,s} = B_s A_a$ olmaktadır. Ayrıca $A_a = \begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix}$ parabolik ölçme matrisi, $B_s = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix}$ kesme matrisi ve t çevirme parametresidir [25-29].

Shearlet dönüşümünün görüntü işleme uygulamalarında kullanılabilmesi için dönüşümün kartezyen koordinat sisteminde tanımlanması gerekmektedir [27,29,30]. $j, l \in Z$ olmak üzere, $a = 2^{-j}$ ve $s = -l$ olarak seçilir. Buradan Eş. 15 elde edilir:

$$M_{2^{-j}, -l}^{-1} = M_{2^j, l} = \begin{pmatrix} 2^j & l2^{j/2} \\ 0 & 2^{j/2} \end{pmatrix} = B_0^l A_0^j \quad (15)$$

Eş. (18)’de $A_0 = \begin{pmatrix} 2 & 0 \\ 0 & \sqrt{2} \end{pmatrix}$ ve $B_0 = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}$ olarak alınır. $j, l \in Z, k \in Z^2$ olmak üzere Shearlet dönüşümünün ayrık sistemi Eş. 16 kullanılarak aşağıdaki gibi elde edilebilir [25]:

$$\psi_{j,l,k} = |\det A_0|^{\frac{j}{2}} \Psi(B_0^l A_0^j x - k) \quad (16)$$

Bu çalışmada, Shearlet dönüşümü uygulanırken ölçek sayısı dört olarak alınmıştır. Ölçek değerlerindeki kesme sayısı $2^{(a-1)+2}$ formülü ile her bir $a = 1,2,3,4$ değerini kullanarak hesaplanmıştır. Her bir ölçek sayı değeri için hesaplandığında [4 8 16 32] ve bir tane de alçak geçiren filtre olmak üzere toplam kesme sayısı 61 olarak belirlenmiştir [28]. Bu çalışmada bir birinden farklı boyutlarda yaprak resimleri içeren 4 farklı veri seti kullanılmıştır. Örneğin, 896×512 boyutundaki Swedish veri setine ait bir yaprak görüntüsü 61 frekans dilimi ile farklı açılarda filtre edilerek bu görüntü için $896 \times 512 \times 61$ boyutunda Shearlet katsayı matrisleri hesaplanmıştır. Daha sonra her bir Shearlet katsayı matrisinin ortalama ve varyans değerleri hesaplanmıştır. Sonuç olarak her bir görüntünün öznelik vektör boyutu 1×122 olarak elde edilmiştir.

Doku tanımadaki iyi hassasiyet göstermesi ve yön bağımsızlığı gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi, nesne tanıma alanında yaygın olarak kullanılmaktadır. Fakat bitki tanıma sistemlerinde, shearlet dönüşümü yöntemi ile ilgili kapsamlı bir çalışma yapılmamıştır. Bu çalışma ile birlikte shearlet dönüşümünün performansı incelenmiştir. Ayrıca shearlet dönüşüm yönteminden elde edilen yüksek sayıdaki özneliklerden dolayı bazen düşük performans gösterebilmektedir. Bu yüzden Temel Birleşen Analizi (TBA) yöntemi kullanılarak yüksek sayıdaki öznelik sayısı indirgenip başarı oranının yükseltilmesi amaçlanmıştır. Elde edilen sonuçlara göre bu metodun yüksek periyodiklik içeren yaprak görüntüleri üzerinde oldukça başarılı olduğu görülmüştür. Metodun uygulama detayları deneysel sonuçlar kısmında verilmiştir.

2.3. Temel Birleşen Analizi (Principal Component Analysis)

TBA [33-34], çok değişkenli veri tabanlarının analizi için ve büyük boyutlu verilerin daha düşük boyutlara düşürülebilmesinde kullanılan bir istatistiksel tekniktir. TBA günümüzde makine öğrenmesi ve veri madenciliği gibi birçok alanda sıkça kullanılan bir öznelik indirgeme yöntemidir [33-34].

$\mathbf{M} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$, d boyutlu ve n örneklili bir veri setleri olsun.

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (17)$$

Buradaki $\bar{\mathbf{x}}$, veri dizisinin ortalamasını ifade etmektedir. Kovaryans matrisi Eş. 18 kullanılarak hesaplanır:

$$\mathbf{K} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (18)$$

Kovaryans matrisi kullanılarak öz değer ve öz vektörler hesaplandıktan sonra indirgenmek istenilen öznelik sayısı kadar öz vektörler seçilir. Son olarak, her bir öz vektörün transpozu ile veri matrisi çarpılarak temel bileşen değerleri bulunur. Önerilen çalışmada, TBA yöntemi ile özneliklerin ağırlıkları hesaplanmaksızın özellik indirgemesi hızlı bir şekilde yapılarak performans yükseltilmesi amaçlanmıştır. Şekil 12' de ise, TBA yönteminin Shearlet özellikleri üzerinde pozitif etkisi olduğu açıkça gösterilmiştir.

2.4. Aşırı Öğrenme Makineleri (Extreme Learning Machines)

AÖM yöntemi, Tek-Gizli Katmanlı İleri Beslemeli (TGKİB) sinir ağı için Huang ve arkadaşları tarafından önerilen bir öğrenme algoritmasıdır [35-37]. AÖM yapısında, gizli katman ağırlıkları rastgele üretilirken, çıkış ağırlıklarının hesaplanmasında en küçük kareler yöntemi kullanılır. Bu yöntem sayesinde geleneksel geri yayılım algoritmaları ile öğrenen ileri beslemeli ağlara göre öğrenme süreci daha hızlı ve daha iyi genelleme başarımına sahip olmaktadır [35,38]. AÖM matematiksel olarak aşağıdaki gibi modellenir;

$$y = \sum_{i=1}^N \beta_i f(\mathbf{x}; w_i, b_i) \quad (19)$$

Burada $[\mathbf{x}_i, y_i]$ giriş-çıkış ikilisini, w_i giriş ağırlıklarını, b_i gizli katman eşikini ve β_i çıkış ağırlıklarını ifade etmektedir. Ağın çıkışı gerçek değerleri 0 hata ile yakınsadığı kabul edilirse Eş. 19, $Y = H\beta$ matris formunda yazılabilir. Burada H gizli katman çıkış matrisi;

$$H = \begin{bmatrix} g(w_{11} \cdot x_1 + b_1) & \dots & g(w_{N1} \cdot x_1 + b_N) \\ \vdots & \dots & \vdots \\ g(w_{1M} \cdot x_M + b_1) & \dots & g(w_{NM} \cdot x_M + b_N) \end{bmatrix}_{N \times M} \quad (20)$$

olarak hesaplanır. Burada Y ağın çıkışını ve β çıkış ağırlıklarını temsil etmektedir. β parametresi Eş. 21 tarafından belirlenebilir.

$$\beta = H^+ Y \quad (21)$$

Burada H^+ , H 'ın Moore Penrose genelleştirilmiş tersini göstermektedir [35-37,39,40]. AÖM algoritmasının sözde kodu, Şekil 5'de gösterildiği gibi tanımlanır.

2.5. Normalizasyon İşlemi (Normalization Process)

Normalizasyon, örüntü tanıma sistemlerinin sınıflandırma performansını artırmak için kullanılan bir veri işlemdir. Önerilen sistemde, birden fazla öznelik çıkarım yöntemi kullanıldığı için bazı özellikler aşırı büyük veya küçük değerlerden oluşabilmektedir. Bu durum, ağı yanlış yönlendirerek sınıflandırma performansının düşmesine neden olmaktadır. Bu çalışmada, öznelik çıkarım yöntemlerinden elde edilen özelliklerinin dağılımını düzenli hale getirmek için z-skor normalizasyon işlemi

Giriş: $1 \times N$ boyutunda özellik seti
Çıkış: Tahmin edilen bitki türleri
1: 10 kat çapraz doğrulama yöntemi kullanılarak eğitim ve test setlerine ayır.
2: Başlangıçtaki giriş ağırlıklarını ve biası rastgele belirle.
3: Eş. 20'yi kullanarak H matrisini hesapla. H matrisi için aktivasyon fonksiyonu sigmoid ve gizli nöron sayısı 10000 olarak seçilmiştir.
4: Eş. 21'i kullanarak sözde ters matrisi hesapla.
5: 10 kez Adım 2-4'ü tekrarla.
6: Tahmin edilen bitki türlerini elde et.

Şekil 5. AÖM yönteminin sözde kodu (Pseudo-code of the ELM method)

kullanılmıştır. Bütün girdilerin belirli aralıkta ölçeklendirilmesi için gerçekleştirilen bu normalizasyon işleminde, verinin ortalama ve standart sapma değerleri kullanılarak bu tür farklılıkların ortadan kaldırılması sağlanmıştır. Z-skor normalizasyon değeri Eş. 22 kullanılarak hesaplanmaktadır.

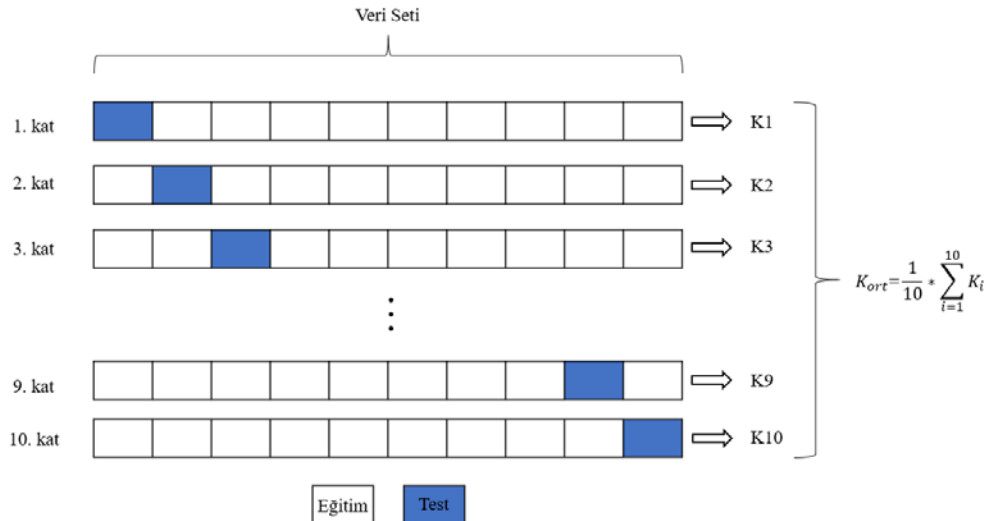
$$z = \frac{x-\mu}{\sigma} \quad (22)$$

Burada x , veriyi, μ , ham verinin sütunlarının ortalamasını ve σ , sütunların standart sapmasını temsil etmektedir [41, 42].

2.6. 10-Kat Çapraz Doğrulama Yöntemi (10-Fold Cross Validation Method)

Veri madenciliği çalışmalarında, uygulanan yöntemin performansını hesaplamak için, veri setini eğitim ve test kümelerine ayrılması gerekmektedir. Bu ayırma işlemi ile ilgili birçok yöntem geliştirilmiştir. Literatürdeki çalışmalarda, genellikle eğitim ve test verilerini ayırmak için belirli bir yüzdelik oranına dayalı rastgele ayırma yaklaşımı kullanılmaktadır. Bu yöntemin dezavantajı, sistemin performansını hesaplarken her zaman birbirinden farklı sonuçlar üretme ihtimalinin bulunmasıdır. Önerilen çalışmada, güvenilirliği yüksek olan 10-kat çapraz-doğrulama yöntemi kullanılmıştır. Böylece, sistem performansının farklı sonuçlar üretme ihtimalini ortadan kaldırılarak sistemin güvenilirliğinin artırılması amaçlanmıştır. 10-kat çapraz doğrulama yönteminde, öznitelik kümesi 10 parçaya bölünür ve her bir adımda parçalardan biri test için, geriye kalan dokuzu eğitim için kullanılır. Bu işlem on kez tekrarlanır ve ortalamaları alınarak sistemin performansı hesaplanmaktadır. 10-kat çapraz doğrulama yönteminin genel çalışma prensibi Şekil 6'da gösterilmiştir.

Şekil 6'da, $i = 1, 2, \dots, 10$ olmak üzere K_i değerleri her kat için sistemin performansını ve K_{ort} ise genel performansı temsil etmektedir.



Şekil 6. 10-kat çapraz doğrulama modeli (10-fold cross validation model)

2.7. Veri Setleri (Datasets)

Önerilen yöntem test etmek için, literatürde yaygın olarak kullanılan ve bitki yaprak görüntülerinden oluşan ICL, Flavia, Foliage ve Swedish veri setleri kullanılmıştır. Bu veri setleri devam eden alt bölümlerde detaylandırılmıştır.

2.7.1. Flavia yaprak veri seti (Flavia leaf dataset)

Flavia yaprak veri seti [4], her bir türden 50 ile 77 arası yaprak örneği olmak üzere 32 bitki türüne ait toplam 1907 yaprak görüntüsünden oluşmaktadır. Bu veri setindeki her bir görüntü; 1600×1200 çözünürlüklü, arka zemini beyaz ve 3 kanallı (RGB) renkli görüntülerden oluşmaktadır. Deneysel çalışmalar gerçekleştirilirken bu veri setinin tüm görüntüleri kullanılmıştır. Şekil 7'de, Flavia yaprak veri setindeki bazı yaprak örnekleri gösterilmektedir.



Şekil 7. Flavia veri setindeki yapraklar (Leaves in Flavia dataset)

2.7.2. Swedish yaprak veri seti (Swedish leaf dataset)

Swedish yaprak veri seti [5], her bir türden 75 adet olmak üzere 15 bitki türüne ait toplam 1125 yaprak görüntüsünden oluşmaktadır. Bu veri setindeki her bir görüntü değişik çözünürlükte, arka zemini beyaz ve 3 kanallı renkli görüntülerden oluşmaktadır. Deneysel çalışmalar gerçekleştirilirken bu veri setinin tüm görüntüleri

kullanılmıştır. Şekil 8’de, Swedish yaprak veri setindeki bazı yaprak örneklerini gösterilmektedir.



Şekil 8. Swedish veri setindeki yapraklar
(Leaves in Swedish dataset)

2.7.3. ICL yaprak veri seti (ICL leaf dataset)

ICL yaprak veri seti [6], her bir türden 8 ile 16 arası yaprak örneği olmak üzere 40 bitki türüne ait toplam 443 yaprak görüntüsü bulunmaktadır. Bu veri setindeki her bir görüntü; 960×720 çözünürlüklü, arka zemini renkli ve 3 kanallı renkli görüntülerden oluşmaktadır. Literatürde yapılan çalışmalarda 31 tür ve toplam 350 resim kullanılmıştır. Bu sebepten dolayı önerilen yöntem, yapılmış çalışmalar ile karşılaştırılabilmesi için aynı veri seti kullanılmıştır. Şekil 9’da, ICL yaprak veri setindeki bazı yaprak örnekleri gösterilmektedir.



Şekil 9. ICL veri setindeki yapraklar (Leaves in ICL dataset)

2.7.4. Foliage yaprak veri seti (Foliage leaf dataset)

Foliage yaprak veri seti [7], her bir türden 120 adet olmak üzere 60 bitki türüne ait toplam 7200 yaprak görüntüsü bulunmaktadır. Bu veri setindeki her bir görüntü farklı çözünürlükte, arka zemini beyaz ve 3 kanallı renkli görüntülerden oluşmaktadır. Deneysel çalışmalar gerçekleştirilirken bu veri setinin tüm görüntüleri kullanılmıştır. Şekil 10’da, Foliage yaprak veri setindeki bazı yaprak örneklerini gösterilmektedir.

3. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL WORKS)

Bu çalışmada, yaprağın sınır eğrileri ve geometrik şekilleri arasındaki farklılıkları ortaya çıkarmak için yeni bir yaklaşım önerilmiştir. KA olarak adlandırılan bu yaklaşım; açı, merkez-kenar uzunluğu ve kenar mesafe özelliklerine dayalı değişkenlerden oluşmaktadır. Bununla birlikte, doku tanımada iyi hassasiyet göstermesi, hızlı hesaplama yapması

ve yön bağımsızlığına sahip olması gibi özelliklere de sahip olan Shearlet Dönüşüm yöntemi uygulanmıştır. Bu yöntem kullanılarak görüntünün büyüklüğüne bağlı olarak farklı sayılarda öznetelik elde edilmektedir. Örneğin; 1200×1600 çözünürlüklü bir görüntüde 250 öznetelik iken 960×720 çözünürlüğe sahip bir görüntü de ise 122 öznetelik elde edilir. Shearlet Dönüşüm yöntemi ile birlikte Temel Birleşen Analizi (TBA) yöntemi kullanılarak yüksek sayıdaki öznetelik kümesi içinden ayırt etme gücü yüksek öznetelikler seçilerek başarı oranının yükseltilmesi amaçlanmıştır. Ayrıca önerilen sistemin güvenilirliğinin ve performansının daha yüksek olması için renk özellikleri ile GSEM yöntemi kullanılmıştır. Daha sonra, elde edilen bu öznetelikler sınıflandırma ve test işlemlerinden önce z-skor normalizasyon işlemine tabi tutulmuştur. Önerilen sistemin doğruluğunu test etmek için 10-kat çapraz doğrulama yöntemi kullanılmıştır. Son olarak, AÖM yöntemi kullanılarak bireysel ve genel sınıflandırma performansları hesaplanmıştır. Önerilen sistemi test etmek için literatürde yaygın olarak kullanılan 4 veri setleri üzerinde kapsamlı deneyler yapılmıştır. Bu deneysel çalışmalar yapılırken, Flavia, ICL, Swedish ve Foliage veri setlerindeki yaprak görüntülerinin boyutları sırasıyla 600×800 , 960×720 , 896×512 ve 250×200 olarak ayarlanmıştır.

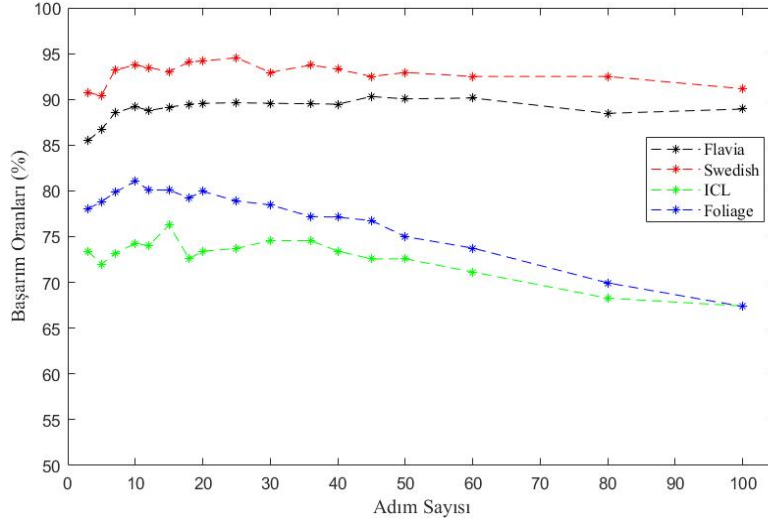


Şekil 10. Foliage veri setindeki yapraklar
(Leaves in Swedish dataset)

3.1. Benzetim Sonuçları (Simulation Results)

Bitki sınıflandırılması için geometrik özelliklere dayalı geliştirilen KA yönteminin performansı, adım sayısı ardışık olarak 1 ile 500 arasındaki değerler kullanılarak hesaplanmıştır. Gerçekleştirilen deneysel çalışmalarda, adım sayısı 100’den sonra önerilen yaklaşımın performansı büyük ölçüde düştüğü görülmüştür. Şekil 11’de, ICL, Flavia, Foliage ve Swedish veri setleri için 3, 5, 7, 10, 12, 15, 18, 20, 25, 30, 36, 40, 45, 50, 60, 80 ve 100 gibi 20 farklı adım değerleri kullanılarak her bir adıma ait başarı oranları verilmiştir.

Şekil 11’de, KA yönteminin başarı oranlarına göre, Flavia veri setinde 45 adım aralığında %90,31, ICL veri setinde 15 adım aralığında %76,28, Swedish veri setinde 25 adım aralığında %94,55 ve Foliage veri setinde 10 adım aralığında %81,04 olarak en yüksek başarı oranları tespit edilmiştir. Buna ek olarak, Şekil 11’de gösterilen bilgiler Tablo 3’de verilmiştir.



Şekil 11. KA Yönteminin Sınıflandırma Performansları (Classification Performances of ES Method)

Tablo 3. KA yönteminin farklı adımlara karşı sınıflandırma doğrulukları (%)
(Classification accuracies (%) against different steps of ES method)

	Adım Değerleri																
	3	5	7	10	12	15	18	20	25	30	36	40	45	50	60	80	100
Flavia	85,47	86,73	88,52	89,21	88,78	89,15	89,47	89,57	89,63	89,57	89,52	89,47	90,31	90,05	90,15	88,47	88,94
ICL	73,42	72,00	73,14	74,28	74,00	76,28	72,57	73,42	73,71	74,57	74,57	73,42	72,57	72,57	71,14	68,28	67,42
Swedish	90,71	90,44	93,21	93,75	93,48	93,03	94,10	94,19	94,55	92,94	93,75	93,30	92,50	92,94	92,50	92,50	91,16
Foliage	78,05	78,81	79,84	81,04	80,11	80,08	79,25	79,94	78,90	78,47	77,20	77,13	76,75	75,00	73,75	69,95	67,37

Daha sonra öznelik çıkarım yöntemlerinden bir diğeri olan Shearlet Dönüşüm yöntemi uygulanmıştır. Bu yöntem kullanılarak ICL, Swedish ve Foliage veri setleri kullanılarak 122 öznelik elde edilirken, Flavia veri seti için ise 250 öznelik elde edilmiştir. Bu parametreler ayrı ayrı sınıflandırılarak Tablo 4'de başarımları verilmiştir.

Tablo 4. Shearlet dönüşüm yöntemi kullanılarak sınıflandırma performansı
(Classification performance by using shearlet transform method)

Flavia	ICL	Swedish	Foliage
%59,47	%34,57	%75	%30,38


Shearlet Dönüşüm yönteminden elde edilen özneliklere Temel Birleşen Analizi (TBA) yöntemi uygulanmıştır. Böylece yüksek sayıdaki öznelik kümesi içinden ayırt etme gücü yüksek öznelikler seçilerek başarımlarının yükseltilmesi amaçlanmıştır. Bu çalışmada, Shearlet Dönüşüm yönteminden elde edilen parametreler TBA yöntemi kullanılarak 10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 70, 80, 90 ve 100 gibi öznelik sayılarına indirgenikten sonra başarımları hesaplanmış ve Şekil 12'de verilmiştir.

Şekil 12'de görüleceği üzere, Flavia veri setine ait başarımlarına göre, öznelik sayısı 45 sayısına düşürüldüğünde, %84,63 olarak en yüksek başarımları elde edilmiştir. Ayrıca TBA yöntemi uygulanmaksızın Shearlet Dönüşüm

yöntemi tek başına kullanılarak %59,47 olarak başarımları hesaplanmıştır. Bu sonuçlara göre TBA yöntemi kullanılarak başarımları %25,16 artış sağlanmıştır. ICL veri setine ait başarımlarına göre, öznelik sayısı 20 sayısına düşürüldüğünde %56,28 olarak en yüksek başarımları elde edilmiş ve %21,71 artış sağlanmıştır. Swedish veri setine ait başarımlarına göre, öznelik sayısı 35 sayısına düşürüldüğünde %90,98 olarak en yüksek başarımları elde edilmiş ve %15,98 artış sağlanmıştır. Foliage veri setine ait başarımlarına göre, öznelik sayısı 35 sayısına düşürüldüğünde %58,93 olarak en yüksek başarımları elde edilmiş ve %28,55 artış sağlanmıştır. Sonuç olarak, yüksek sayıdaki özneliklerden daha az sayıda ve daha anlamlı öznelikler elde edilerek daha yüksek performans elde edildiği gözlemlenmiştir.

Bu çalışmada, Kenar Adım ve Shearlet Dönüşüm yöntemlerine ek olarak, yaprak görüntülerinden doku ve renk özelliklerini çıkarmak için GSEM yöntemi ve Renk özellikleri kullanılmıştır. Bu yöntemler bir arada kullanılarak önerilen sistemin genel başarımları hesaplanmıştır. Bu çalışmaların performans sonuçları ve öznelik sayıları Tablo 5'de verilmiştir.

Tablo 5'de görüldüğü gibi, önerilen sistem (hibrit özellikler) kullanılarak Flavia, ICL, Swedish ve Foliage veri setleri için sırasıyla %98,31, %93,71, %99,46 ve %96,62 doğrulukları elde edilmiştir. Bu performansların ROC diyagramları Şekil



Şekil 12. Shearlet Dönüşüm - TBA Yönteminin Sınıflandırma Performansları
(Classification Performances of Shearlet Transform - PCA Method)

Tablo 5. Önerilen çalışmanın bireysel-genel başarımlar ve öznitelik sayıları
(The individual-overall success rates and the attributes number of the proposed study)

Yöntemler	Flavia		ICL		Swedish		Foliage	
	Doğruluk (%)	Öznitelik Sayısı	Doğruluk (%)	Öznitelik Sayısı	Doğruluk (%)	Öznitelik Sayısı	Doğruluk (%)	Öznitelik Sayısı
GSEM	63,21	5	37,71	5	75,98	5	53,51	5
Renk Özellikleri	85,31	12	68,28	12	84,91	12	82,88	12
Hibrit Özellikler	98,31	42	93,71	42	99,46	57	96,62	42


13'de verilmiştir. Ayrıca, Flavia, ICL ve Foliage veri setlerinde Shearlet Dönüşüm yöntemi ile TBA kullanılarak tek başına en yüksek performansı sırasıyla 45, 20 ve 35 öznitelikte sağlar iken diğer öznitelik çıkarım yöntemleri ile beraber kullanıldığında en yüksek performans 10 öznitelikte elde edilmiştir. Swedish veri setinde ise Shearlet Dönüşüm yöntemi ile TBA kullanılarak tek başına en yüksek performansı 35 öznitelikte sağlar iken diğer öznitelik çıkarım yöntemleri ile beraber kullanıldığında en yüksek performans 25 öznitelikte elde edilmiştir.

Bu çalışmada, hızlı ve yüksek performansa sahip bir sistem önerilmiştir. Bu sistemi gerçekleştirmek için MATLAB 2018a programı kullanılmıştır. Deneysel çalışmaların gerçekleştirildiği bilgisayar 16 GB RAM ve Intel i7-6700 2,60 GHz işlemciye ve Windows 10.1 işletim sistemine sahiptir. Önerilen özellik çıkarma yönteminin çalışma zamanı tüm aşamalarıyla birlikte Tablo 6'da verilmiştir ve bu süreler bir imge için hesaplanmıştır. Bununla birlikte, kullanılan veri setlerindeki imgelerin boyutları farklı olduğu için her birinin çalışma süreleri verilmiştir.

3.2. MKU-KA Yöntemlerinin Karşılaştırılması (Comparison of CCD-ES Methods)

Kenar Adım (KA) yöntemi, MKU yönteminin geliştirilmiş versiyonudur. Bitki yaprak görüntüleri için, MKU yönteminde açığa bağımlı olarak özellikler elde edilirken, KA yönteminde ise açıdan bağımsız olarak şeklin sınır eğrilerindeki kenar noktalarına dayalı özellikler elde edilir. MKU ve KA yöntemlerinin bireysel performansları ile Shearlet Dönüşüm, Renk Özellikleri ve GSEM yöntemi ile beraber kullanılarak genel performansları ve öznitelik sayıları Tablo 7'de verilmiştir.

Tablo 7'de, MKU ile KA yöntemlerinin bireysel ve genel performansları karşılaştırılmıştır. KA yöntemi MKU yöntemine göre, Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla yaklaşık olarak %8, %16, %12 ve %10'luk performans artışı sağlamıştır. Sonuç olarak, KA yöntemi MKU yöntemine göre, dört farklı veri setinde de en yüksek başarımlarına sahip olduğu tespit edilmiştir. Buna ek olarak, KA yöntemi diğer yöntemler ile kombinasyonunda,



Şekil 13. Önerilen sistemin sınıflandırma performanslarının ROC diyagramları a) Flavia veri seti b) ICL veri seti c) Foliage veri seti d) Swedish veri seti (ROC diagrams of the classification performance of the proposed system a) Flavia dataset α) ICL dataset c) Foliage dataset d) Swedish dataset)

Tablo 6. Önerilen sistemin gerçekleştirme zamanı (saniye/sn) (Execution time of the proposed system(second/sec))

	Flavia	ICL	Swedish	Foliage
Ön-İşlem	0,1256	0,0773	0,0763	0,0217
KA	0,0755	0,0976	0,0718	0,0178
Shearlet + TBA	2,4669	2,1916	2,1978	0,2523
GSEM	0,0586	0,7996	0,0552	0,0051
Renk Özellikleri	0,1485	0,1105	0,1057	0,0153
Özellik birleştirme	0,0001	0,0001	0,0001	0,0001
Toplam	2,9099	2,5314	2,5123	0,3183

MKU yöntemine göre performansı dört veri setinde de daha yüksek olduğu gözlenmiştir. KA yöntemi kullanılarak her bir veri seti için 15 öznitelik elde edilirken, MKU yöntemi kullanılarak ise Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla 20, 36, 30 ve 20 öznitelik elde edilmiştir. Tablo 7'den de anlaşılacağı üzere, KA yöntemi bir görüntüye ait daha az sayıda öznitelik elde etmekle beraber MKU yönteminden daha yüksek performansa sahip olduğu kanıtlanmıştır.

3.3. Önerilen Yöntem ile Mevcut Yöntemlerin Karşılaştırma Analizleri

(Comparative Analysis of Existing Methods With Proposed Method)

Flavia, ICL, Swedish ve Foliage veri setleri kullanılarak yapılan literatürdeki çalışmalar ile önerilen çalışmanın performansları Tablo 8'de verilmiştir. Şekil, renk ve doku özelliklerine dayalı çalışmalar referans alınmıştır. Önerilen sistemde, GSEM ve Renk özellikleri ile Kenar Adım ve

Tablo 7. MKU-KA yöntemlerinin başarımlarının karşılaştırılması
(Comparison of accuracy rates of CCD-ES methods)

YÖNTEMLER	Flavia		Swedish		ICL		Foliage	
	Doğruluk (%)	Öznitelik Sayısı	Doğruluk (%)	Öznitelik Sayısı	Doğruluk (%)	Öznitelik Sayısı	Doğruluk (%)	Öznitelik Sayısı
MKU yöntemi	82,31	20	78,92	36	64,00	30	71,18	20
KA yöntemi	90,31	15	94,55	15	76,28	15	81,04	15
MKU + Shearlet Dönüşüm + GSEM + Renk Özellikleri	97,57	47	98,12	68	87,42	57	94,51	47
KA + Shearlet Dönüşüm + GSEM + Renk Özellikleri	98,31	42	99,46	57	93,71	42	96,62	42

Tablo 8. Önerilen sistemin mevcut yöntemler ile doğruluk oranlarının (%) karşılaştırılması
(comparison of accuracy rates (%) of proposed system with existing methods)

	VERİ SETLERİ				
	Flavia	ICL	Swedish	Foliage	
Önceki yöntemlerin ortalama sınıflandırma performansları			94,13 [44]		
		82,05 [8]	95,47 [45]		
		92,37 [43]	95,97 [46]		
		94,50 [16]	96,31 [47]		
		94,62 [12]	87,00 [6]	96,53 [48]	90,80 [14]
		94,68 [7]	92,00 [9]	97,33 [49]	93,08 [7]
		95,00 [18]	92,65 [15]	98,13 [17]	93,33 [11]
		97,18 [17]		98,40 [50]	95,75 [18]
		97,19 [10]		99,18 [43]	
		97,55 [13]		99,25 [19]	
Önerilen sistem	98,31	93,71	99,46	96,62	

Shearlet Dönüşüm yöntemleri bir arada kullanılarak sistemin genel başarımları hesaplanmıştır.

Tablo 8’de, literatürde dört veri seti için aynı sayıda tür ve yaprak resimleri kullanılarak yapılan çalışmalar ile önerilen sistemin sınıflandırma performansları kıyaslanmıştır. Önerilen sistem kullanılarak Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla %98,31, %99,46, %93,71 ve %96,62 doğrulukları elde edilmiştir. Gerçekleştirilen çalışmada, sınıflandırma performansının önceki çalışmalardan daha yüksek olması, bitki yapraklarının ayırt edici özelliklerini daha iyi yansıtması için şekil, doku ve renk özelliklerini kullanarak aynı türe ait farklı yapraklar arasındaki benzerliğin artışı ile sağlanmıştır.

4. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, yaprak görüntüleri kullanarak bitki sınıflandırılması için açıya bağımlı Merkez Kenar Uzunluk (MKU) yönteminden esinlenerek geometrik özelliklere dayalı yeni bir yaklaşım önerilmiştir. Kenar Adım (KA) olarak adlandırılan bu yöntem; açı, merkez-kenar uzunluğu ve kenar mesafe özelliklerine dayalı yaprağın sınır eğrileri ve geometrik şekilleri arasındaki farklılıkları incelemektedir. Gerçekleştirilen deneysel çalışmalarda, KA yöntemi, MKU

yöntemine göre Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla yaklaşık olarak %8, %16, %12 ve %10’luk performans artışı sağlamıştır. Buna ek olarak, KA yönteminde dört veri seti için her bir görüntüye ait 15 öznitelik elde edilirken, MKU yönteminde ise Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla 20, 36, 30 ve 20 öznitelik elde edilmiştir. Bu çalışmalar neticesinde, KA yöntemi bir görüntüye ait daha az sayıda öznitelik elde etmekle beraber MKU yönteminden daha yüksek performansa sahip olduğu kanıtlanmıştır. Önerilen çalışmada, doku tanımadaki iyi hassasiyet göstermesi, hızlı hesaplama yapması ve yön bağımsızlığına sahip olması gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi de kullanılmıştır. Bu yöntem kullanılarak görüntünün büyüklüğüne bağlı farklı sayıda öznitelikler elde edilmiştir. Bu özniteliklere Temel Birleşen Analizi (TBA) yöntemi uygulanarak öznitelik sayısı azaltılmıştır. Önerilen Shearlet Dönüşüm ve TBA tekniğinin, temel Shearlet Dönüşüm tekniğine kıyasla daha yüksek performans sağladığı deneysel çalışmalar sonucunda gözlemlenmiştir. Bu yöntemlere ek olarak, bitki yapraklarındaki farklı dokuları ortaya çıkarmak için GSEM yöntemi ile yaprak görüntülerinden istatistiksel momentlere dayalı renk özellikleri kullanılmıştır. Elde edilen bu öznitelikleri sınıflandırabilmek için 10-kat çapraz-doğrulama yöntemi kullanılarak eğitim ve test verilerini

ayırma işlemi uygulanmıştır. Son olarak, AÖM yöntemi kullanılarak öznelik çıkarım yöntemlerinin tekil ve bileşik sınıflandırma performansları hesaplanmıştır.

Önerilen sistemin etkinliğini doğrulamak için, Flavia, Swedish, ICL ve Foliage bitki yaprak veri setleri üzerinde kapsamlı deneysel çalışmalar yapılmıştır. Bu sonuçlara göre, Flavia, ICL, Swedish ve Foliage veri setleri için sırasıyla %98,31, %93,71, %99,46 ve %96,62 doğrulukları elde edilmiştir. Elde edilen sonuçlar, önerilen yöntemin daha etkili, uygulaması daha kolay ve daha az sayıda öznelik kullanılarak önceki çalışmalara kıyasla daha yüksek performansla sahip olduğunu göstermektedir.

KAYNAKLAR (REFERENCES)

- Zhang, H., TAO, X., Leaf image recognition based on wavelet and fractal dimension, *Journal of Computational System* 11.1, 141-148, 2015.
- Turkoglu, M., Hanbay, D., Recognition of plant leaves: An approach with hybrid features produced by dividing leaf images into two and four parts, *Applied Mathematics and Computation*, 352, 1-14, 2019.
- Shabanzade, M., Zahedi, M., Aghvami, S. A., Combination of local descriptors and global features for leaf recognition, *Signal & Image Processing*, 2.3: 23, 2011.
- Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y. X., Chang, Y. F., Xiang, Q. L., A leaf recognition algorithm for plant classification using probabilistic neural network, *Signal Processing and Information Technology*, 2007 IEEE International Symposium on. IEEE, 2007.
- Söderkvist, O., Computer vision classification of leaves from swedish trees, 2001.
- Silva, P. F., Marcal, A. R., da Silva, R. M. A., Evaluation of features for leaf discrimination, *International Conference Image Analysis and Recognition*. Springer, Berlin, Heidelberg, 2013.
- Kadir, A., Nugroho, L. E., Susanto, A., Santosa, P. I., Neural network application on foliage plant identification, arXiv preprint arXiv:1311.5829, 2013.
- Mahdikhanlou, K., Ebrahimnezhad, H., Plant leaf classification using centroid distance and axis of least inertia method, In *Electrical Engineering (ICEE)*, 2014 22nd Iranian Conference on. IEEE, 1690-1694, 2014.
- Yasar, A., Saritas, I., Sahman, M. A., Dundar, A. O., Classification of Leaf Type Using Artificial Neural Networks, *International Journal of Intelligent Systems and Applications in Engineering* 3.4, 136-139, 2015.
- Lee, K. B., Hong, K. S., An implementation of leaf recognition system using leaf vein and shape, *International Journal of Bio-Science and Bio-Technology*, 5.2: 57-66, 2013.
- Kadir, A., Nugroho, L. E., Susanto, A., Santosa, P. I., Experiments of Zernike moments for leaf identification, *Journal of Theoretical and Applied Information Technology (JATIT)* 41.1: 82-93, 2012.
- C. Sari, C. B. Akgul, B. Sankur, Combination of gross shape features, fourier descriptors and multiscale distance matrix for leaf recognition, In *AÖMAR*, 2013 55th International Symposium. IEEE, 23-26, 2013.
- Naresh, Y. G., Nagendraswamy, H. S., Classification of medicinal plants: an approach using modified LBP with symbolic representation, *Neurocomputing*, 173: 1789-1797, 2016.
- Kadir, A., Nugroho, L. E., Susanto, A., Santosa, P. I., Foliage plant retrieval using polar fourier Dönüşüm, color moments and vein features, arXiv preprint arXiv:1110.1513, 2011.
- Elhariri, E., El-Bendary, N., Hassanien, A. E., Plant classification system based on leaf features, *Computer engineering & systems (icces)*, 2014 9th international conference on. IEEE, 2014.
- Priya, C. A., Balasaravanan, T., Thanamani, A. S., An efficient leaf recognition algorithm for plant classification using support vector machine, In *Pattern Recognition, Informatics and Medical Engineering (PRIME)*, 2012 International Conference on. IEEE, p. 428-432, 2012.
- Tsolakidis, D. G., Kosmopoulos, D. I., Papadourakis, G., Plant leaf recognition using Zernike moments and histogram of oriented gradients, *Hellenic Conference on Artificial Intelligence*. Springer, Cham, 2014.
- Kadir, A., Nugroho, L. E., Susanto, A., Santosa, P. I., Performance improvement of leaf identification system using principal component analysis, *International Journal of Advanced Science and Technology* 44, 113-124, 2012.
- Wang, X., Liang, J., Guo, F., Feature extraction algorithm based on dual-scale decomposition and local binary descriptors for plant leaf recognition, *Digital Signal Processing* 34, 101-107, 2014.
- Hong, A., Chi, Z., Chen, G., Wang, Z., Region-of-Interest based flower images retrieval, *Acoustics, Speech, and Signal Processing*, 2003. Proceedings. (ICASSP'03). 2003 IEEE International Conference on. Vol. 3. IEEE, 2003.
- Çalışkan, A., Acar, E., Kaya, Y., GSEM Tabanlı KNN Sınıflandırıcı Modeli İle Avuç İçi Tanıma Sistemi. *Batman University, Journal of Life Sciences Volume 1*, Number 2, 2012.
- Hudec, R., Benco, M., Novel method for color textures features extraction based on GSEM, *Radioengineering*, 2007.
- Wang, X., Georganas, N. D., GLCM texture based fractal method for evaluating fabric surface roughness, *Electrical and Computer Engineering*, 2009. CCECE'09. Canadian Conference on. IEEE, 2009.
- Haralick, R. M., Shanmugam, K., Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics* 6, 610-621, 1973.
- Easley, G., Labate, D., Lim, W. Q., Sparse directional image representations using the discrete shearlet transform, *Applied and Computational Harmonic Analysis*, 25 (1), 25-46, 2008.
- Guo, K., Labate, D., Optimally sparse multidimensional representation using shearlets, *SIAM journal on mathematical analysis*, 39(1), 298-318, 2007.

27. Yaşar, H., and Ceylan, M., Investigation of image representation and denoising performances of real and complex valued fast finite shearlet transform, Signal Processing and Communications Applications Conference (SIU), 2015 23th. IEEE, 2015.
28. Hanbay, K., Yuvarlak örgü makineleri için görüntü işleme tabanlı kumaş hatası tespit sistemi, İnönü Üniversitesi, 2016.
29. Guo, K., Gitta, K. Demetrio, L., Sparse multidimensional representations using anisotropic dilation and shear operators, International Conference on the Interaction between Wavelets and Splines, 189-201, 2005.
30. Hauser, S. Steidl, G., Fast finite shearlet transform: a tutorial, preprint, Access: <http://arxiv.org/pdf/1202.1773.pdf>, 2015.
31. Belhumuer, P.N., Hespanha, J.P. Kriegman, D.J., Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, 711-720, 1997.
32. Chatterjee, C., Roychowdhury, V. P., Chong, E. K., On relative convergence properties of principal component analysis algorithms, IEEE Transactions on Neural Networks, 9 (2), 319-329, 1998.
33. Yildiz, E., Sevim, Y., Comparison of linear dimensionality reduction methods on classification methods, Electrical, Electronics and Biomedical Engineering (ELECO), 2016 National Conference on. IEEE, 2016.
34. Karabatak, M., Ince, M. C., Avci, E., An expert system for diagnosis breast cancer based on Principal Component Analysis method, Signal Processing, Communication and Applications Conference, 2008. SIU 2008. IEEE 16th. IEEE, 2008.
35. Huang, G. B., Zhu, Q. Y. Siew, C. K., Extreme learning machine: theory and applications, Neurocomputing 70.1, 489-501, 2006.
36. Alçin Ö.F., Şengür A., İnce M.C., Forward-backward pursuit based sparse extreme learning machine, Journal of the Faculty of Engineering and Architecture of Gazi University, 30 (1), 111-118, 2015.
37. Huang, G. B., Zhu, Q. Y., Siew, C. K., Extreme learning machine: a new learning scheme of feedforward neural networks, Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on, IEEE, 2, 2004.
38. Luo, M., and Zhang, K., A hybrid approach combining extreme learning machine and sparse representation for image classification, Engineering Applications of Artificial Intelligence, Cilt 27, 228-235, 2014.
39. Alcin, O. F., Sengur, A., Qian, J. Ince, M. C., OMP-AÖM: orthogonal matching pursuit-based extreme learning machine for regression, Journal of Intelligent Systems 24.1, 135-143, 2015.
40. Turkoglu, M., Hanbay, D., Leaf recognition system based on geometric features, Turkish Journal of Nature and Science, 5.2, 26-31, 2016.
41. Jain, A., Nandakumar, K., Ross, A., Score normalization in multimodal biometric systems, Pattern recognition, 38.12: 2270-2285, 2005.
42. Larose, D.T., Discovering Knowledge in Data: An Introduction to Data Mining, New Jersey: John Wiley and Sons Inc., 2014.
43. Laga, H., Kurtek, S., Srivastava, A., Miklavcic, S. J., Landmark-free statistical analysis of the shape of plant leaves, Journal of theoretical biology 363, 41-52, 2014.
44. Ling, H., Jacobs, D.W., Shape classification using the inner-distance, IEEE Trans. Pattern Anal. Mach. Intell. 29, 286-299, 2007.
45. Daliri, M.R., Torre, V., Robust symbolic representation for shape recognition and retrieval, Pattern Recogn. 41, 1782-1798, 2008.
46. Alajlan, N., El Rube, I., Kamel, M. S., Freeman, G., Shape retrieval using triangle-area representation and dynamic space warping, Pattern recognition, 40(7), 1911-1920, 2007.
47. Yang, C., Wei, H., and Yu, Q., Multiscale Triangular Centroid Distance for Shape-Based Plant Leaf Recognition, ECAI. 2016.
48. Mouine, S., Yahiaoui, I., Verroust-Blondet, A., A shape-based approach for leaf classification using multiscale triangular representation, in: Proceedings of the 3rd ACM International Conference on International Conference on Multimedia Retrieval, pp. 127-134, 2013.
49. Wang, B., Brown, D., Gao, Y., La Salle, J., MARCH: Multiscale-arch-height description for mobile retrieval of leaf images, Information Sciences 302, 132-148, 2015.
50. Huang, C., Han, T. X., He, Z., Multi-scale embedded descriptor for shape classification. Journal of Visual Communication and Image Representation 25.7, 1640-1646, 2014.
51. Qi, X., Xiao, R., Li, C. G., Qiao, Y., Guo, J., Tang, X., Pairwise rotation invariant co-occurrence local binary pattern, IEEE transactions on pattern analysis and machine intelligence 36.11, 2199-2213, 2014.