

Şekile Dayalı Yaprak Tanıma Shape Based Leaf Recognition

Cihan Sari¹, Ceyhun Burak Akgül², Bülent Sankur²

Boğaziçi Üniversitesi Sistem ve Kontrol Mühendisliği Bölümü¹, İstanbul
Boğaziçi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü², İstanbul

(cihan.sari, ceyhun.akgul, bulent.sankur)@boun.edu.tr

ÖZETÇE

İnsanlar için gündelik karşılaşılan şekilleri tanımak çok temel bir işlemdir. Ancak bir şekil ile ilişkili detaylı bilgileri bilmek çoğu zaman mümkün değildir. Bu sebepten, şekillerin tanınması ve bu tanımlar aracılığı ile bilgi çıkarımı yaygın bir araştırma konusudur. Bu çalışmada, yapay görme teknikleri kullanılarak yaprakların tanınması için farklı öznelik ve veri kümeleri kullanılarak başarı testleri yaptık. Genel biçim öznelikleri, Fourier tanımlayıcı öznelikleri ve MDM-A özneliklerinin bu problemin çözümündeki etkisini inceledik. Daha sonra bu özneliklerin birleşiminin performans etkilerini gözlemledik. Sonuç olarak, benzer çalışmalarla kıyas edilebilecek performanslar elde ettik.

ABSTRACT

Humans carry out object recognition as a very primitive task. However, knowing all the detailed information regarding an object is mostly not possible. Therefore, object recognition and linking the object to associated data is a popular research area. In this study, we have measured leaf recognition performances of different feature and data sets using image processing techniques. We have studied the effects of general shape features, Fourier descriptors and MDM-A feature sets for the solution of this problem. We have also measured performance evaluation by fusing these features. Eventually, we have observed a compatible performance with similar studies.

1. GİRİŞ

Bulunan yaprakların hangi bitkiye, aileye ait olduğunun bulunması günlük hayatta yapılması çok zor bir iş. Çoğunlukla bitki bilimciler tarafından yapılır. Bu işlem özellikle yeni bir yaprakta hem zaman alıcı, hem de yorucudur. Bu sebepten günlük hayatta karşılaştığımız bir yaprağın besin ya da alternatif bir ilaç olarak kullanılması da zordur. Hem uzmanların harcadığı süreyi kısaltmak, hem de günlük hayatta yaprak tanıyabilmek amaçlı, bilgisayarlı görü alanında, son 10 sene içerisinde yaprak tanıma üzerine pek çok çalışma yapılmıştır.

Bu alanda yapılan ilk çalışmalardan biri Im vd. [1] tarafından 1988'de gerçekleştirilmiştir. Bu projede yaprakları sınıflarına ayırmak için, genel şeklin poligonal yaklaşımının benzerlik ölçümünü kullanmışlardır. Eğer ki bu ayırım yeterli değilse, yaprağın kuzey-orta kısımları karşılaştırılmıştır. Bu deneysel çalışma küçük bir veri tabanı üzerinde çalışılmış ve

sınıflar içerisinde %62 ile %90 arası benzerlik bulunmuştur. Wang vd. [2] 2003 yılında yaptıkları çalışmada, kontur merkez uzaklığı (CCD), dışmerkezlik ve kodlanmış açılı histogramı (ACH) gibi basit şekil özneliklerini kullanmışlardır. 140 tane Çin bitki türünden, her türden 10 tane örnekle edinilmiş 1400 adet renkli yaprak imgesinden oluşan bir veri tabanı kullanmışlardır. Basit şekil özneliklerini kullanarak, bu veri tabanında %75.6 geri bildirim oranına (doğru dönen imge sayısının, sorgulanan imge sayısına oranı olarak hesaplanır) ulaşmışlardır. Wu vd. [3] 2007 yılında çap, yaprak alanı, yaprak çevresi ve benzerleri gibi basit geometrik öznelikler ve yumuşaklık etkeni, en-boy oranı, biçim katsayısı, dikdörtgensellik ve benzeri basit biçimbilimsel öznelikler kullanmışlardır. 1920 tane renkli yaprak imgesinden oluşan Flavia [3] veri tabanında, bu öznelikler ve olasılıksal sinir ağı sınıflandırıcısı ile %90.31'lik bir doğruluk oranına ulaşmışlardır. Hu vd. [4] 2012 yılında Çok Boyutlu Mesafe Matrisi (MDM) isminde yeni bir kontur tabanlı biçim öznelikleyici önerdiler. MDM dönmeden, ötelemeden ve iki yönlü simetriden bağımsız bir öznelikleyici yöntemidir. Elde edilen matrisin ortalama değere (MDM-A) veya en yüksek değere (MDM-M) bölünmesiyle, aynı zamanda ölçklemeden de bağımsız bir hale gelir. Bu öznelik uzayını kullanarak, SLID (İsveç yaprak imgesi veri tabanı) [5] ve ICL yaprak veri tabanında, sırasıyla, %93.60 ve %98.20 doğruluk oranına ulaşmışlardır.

Bu çalışmanın amacı, geçmiş çalışmalarda kullanılan farklı öznelik kümelerini birlikte kullanarak, ulaşılan yaprak tanıma performansını yükseltmek veya doğrulamaktır. Ancak diğer çalışmalarda kullanılan veri tabanlarının hangi örnekleriyle eğitim, hangileri ile test edildiği bilinmediği için aynı sonuçların çıkartılması çok zordur. Bu sebepten, eğitim ve test amaçlı seçilen imgeler, tekrarlanabilirlik amacıyla kayıt edilmiştir. Böylece, talep edildiği takdirde yapılmış olan testler, sonraki çalışmalarda da yinelenebilir.

Bölüm 2'de yaprak tanıma sistemi genel olarak açıklanmıştır. Bu bölümün içerisinde, bölüm 2.2'de yaprağın bölütlenmesi ve hizalanması, bölüm 2.3'de öznelik çıkarımları ve bölüm 2.4'te kullanılan sınıflandırıcılar anlatılmıştır. 3. bölümde yapılan deneyler, deneylerde kullanılan veri tabanları ve sonuçlardan bahsedilmiştir. Son olarak, 4. bölümde varyasyonlar anlatılmıştır.

2. YAPRAK TANIMA SİSTEMİ

Bu bölümde yaprak tanıma sisteminin genel akışı verilmiştir ve kullanılan yöntemler açıklanmıştır.

2.1. Sistem Akışı

3 kanallı yaprak imgesinin mavi ve renk doygunluğu kanalları kullanılarak yaprağın şekli tespit edilir. Bu bölge içerisinde genel biçim öznitelikleri, sınır koordinatlarından çıkartılan Fourier öznitelikleri ve MDM-A öznitelikleri hesaplanır. Eğitim kümesinden çıkartılan öznitelik kümeleri ile sınıflandırıcılar eğitilir. Test kümesindeki örnekler, bu sınıflandırıcıların sonuçları çapraz doğrulama performanslarıyla ağırlandırılarak, yaprak sınıfına atanır.

2.2. Önışleme

Öznitelikler çıkartılmadan önce bazı önışleme adımları atılması gereklidir. Önışleme iki adımdan oluşur, yaprak bölütlemesi ve hizalanması.

2.2.1. Bölütleme

Bölütleme, yaprak veri tabanına göre değişiklik gösterebilir. Ancak hem Flavia [3], hem de SLID [5] veri tabanlarındaki yaprak imgeleri 3 kanallı ve beyaz arkaplanlı oldukları için, aynı yöntemler kullanılmıştır. Yaprak imgeleri,

- RGB renk uzayından HSV renk uzayına geçirilir.
- Renk doygunluğu ve mavi kanalları kullanılarak yaprak bölgesi bölütlenir.

$$I(i, j) = \frac{255 - S(i, j) + B(i, j)}{2} \quad (1)$$


$S(i, j)$ ve $B(i, j)$, (i, j) koordinatlarındaki, sırasıyla, renk doygunluğu ve mavi kanallarındaki gri değerleri gösterir. Yaprak $I(2)$ imgesi eşiklenerek bölütlenir.

$$R(i, j) = \begin{cases} I(i, j) < 210 & ise\ 1 \\ & değilse\ 0 \end{cases} \quad (2)$$


Yapılan denemelerde en iyi eşik değeri olarak 210 bulunmuştur.

2.2.2. Yaprak Hizalanması

Yaprağın ötelemesi ve ölçeği bölütlemenin sonunda elde edilen şekilden kolay bir şekilde hesaplanabilir. Dönme hizalanılması için Temel Bileşen Analizi (PCA) kullanılmıştır. Bu yöntem, hem hızlı olduğu için, hem de şekil 1'de görüldüğü gibi, görece basit şekillerde iyi çalıştığı için seçilmiştir. Ancak aynı sınıfa ait farklı yaprakların yapıları değişkenlik gösterdiğinden, daha karmaşık şekillerde ilk önce biçimbilim işlemleri yapılmazsa PCA hizalanması şekil 2'de görüldüğü gibi çok güvenilir çalışmamaktadır. Veri tabanları incelendiğinde yaprakların hizalanması için en güvenilir yöntem yaprağın ana damarlarının bulunmasıdır. Ana damarlar yaprağın genel yapısını çok iyi bir şekilde tanımladığı, doğrusal bir şekil olduğu ve kopma, yırtılma gibi dış etkenlerden daha az etkilendiği için, hizalama için yeterli olacaktır. Ancak, şekil 3'de görüldüğü gibi birkaç başarısız bölütleme denemesinden sonra yaprakların çoğunluğunu hizalamak amaçlı bütün şekil üzerinde PCA uygulanmıştır.



Şekil 1: Basit şekillerde PCA ile dönme hizalama



Şekil 2: Karmaşık şekillerde PCA ile dönme hizalama

2.3. Öznitelik Çıkarımı

Bu çalışmada üç farklı öznitelik kümesi kullanılmıştır. Bunlar, genel biçim öznitelikleri, Fourier tanımlayıcı öznitelikleri ve MDM-A öznitelikleridir. Bu özniteliklerin çıkartılması için yapılan önışlemeler 2.2. bölümde anlatılmıştır.

2.3.1. Genel Biçim Öznitelikleri

Genel biçim öznitelikleri, dikdörtgensellik, en-boy oranı, ortalama renk özü, dışmerkezlilik ve dışbükeylikten oluşur. Bu öznitelikler şöyledir:

- Dikdörtgensellik, bölge alanının, bölgeyi içerisine alabilecek en küçük dikdörtgenin alanına oranı ile hesaplanır. Yani, dikdörtgensellik, dış kontur alanına ve şekil çevresini kullanır. Bu sebepten, benzer yapraklarda fazla değişiklik göstermemesi beklenir.
- En-boy oranı, bölgeyi içerisine alabilecek en küçük dikdörtgenin, büyük kenarının, küçük kenarına olan oranı olarak hesaplanır. Bu öznitelik farklı bitki türleri için değişkenlik gösterir ve hesaplaması kolaydır.
- Ortalama renk özü, yaprak bölgesinin renk özü değerlerinin ortalaması alınarak hesaplanır. Renk özü kanalı, teorik olarak aydınlatma koşullarından bağımsızdır. Bu öznitelik, şeklen benzerliği düşük, ancak tansal benzerliği yüksek yaprak sınıflarını ayırması




Şekil 3: Yaprak ana damarının bölütlenmesi denemeleri

açısından çok önemlidir.

- Dışmerkezlik, ikinci momentleri bölge ile aynı olan bir elipsten hesaplanır. Dışmerkezlik, bu elipsin en-boy oranı gibi düşünülebilir, çünkü elipsin içerisindeki en büyük ve en küçük kirişlerin oranı olarak hesaplanır.
- Dışbükeylik, bölge alanının, bölgeyi tamamen içerisine alan en küçük dışbükeyin alanına oranı olarak hesaplanır. Birçok açıdan dikdörtgenselliğe benzer görünse de, şekle tam olarak oturduğu için, yerel farklılıkları daha iyi ifade eder.

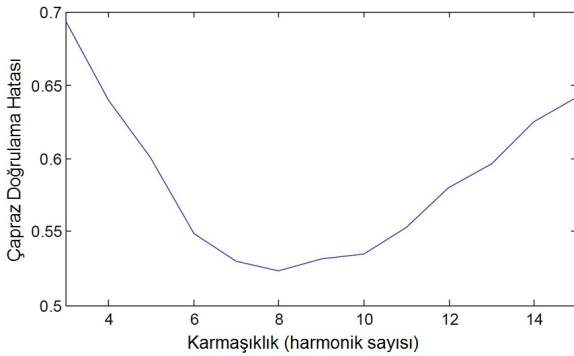
2.3.2. Fourier Tanımlayıcı Öznitelikleri

Fourier öznitelikleri, yaprak bölgesinin çevre noktalarının koordinatlarından çıkartılır. Bölgenin çevre noktalarından (x,y), eşit adımlarla 1000 örnek alınır. Bu örneklerin tam koordinatlarını hesaplayabilmek için çift doğrusal aradeğerleme kullanılır. Koordinatlar, iki düzlemde de 0 ile 1 arasına düzgelendikten sonra ayrı ayrı Fourier dönüşümleri hesaplanır. Sıfır frekansı atılır ve bunu takiben N tane faz açısı alınır (2xN öznitelik). Kullanılan



Şekil 4: N tane harmonik kullanılarak geri çatılmış bölgeler

harmonik sayısı arttırıldıkça öznitelik karmaşıklığı arttığı için, fazla öğrenme sonucu doğurabilir. Şekil 5'te bunu gözlemleyebilmek amaçlı, kullanılan harmonik sayısının çapraz doğrulama performansına etkisi ölçülmüştür. Sonuçlar incelenerek, en iyi performansı verdiği için, ilk 8 harmonik kullanılmıştır.



Şekil 5: Karmaşıklık (harmonik sayısı) ve hata (çapraz doğrulama hatası) eğrisi


2.3.3. MDM-A Öznitelikleri

MDM-A öznitelikleri şeklin çevre noktaları kullanılarak çıkartılır. Öznitelik kümesinin boyutu kullanılacak çevre nokta sayısı ile değiştiği için, ilk önce şekil sınırlarından eş uzaklıkta 50 örnek alınır (şekil 6). Bu noktaların birbirleri arasındaki



Şekil 6: Sınır noktaları örneklenmiş ve geri çatılmış yaprak şekli

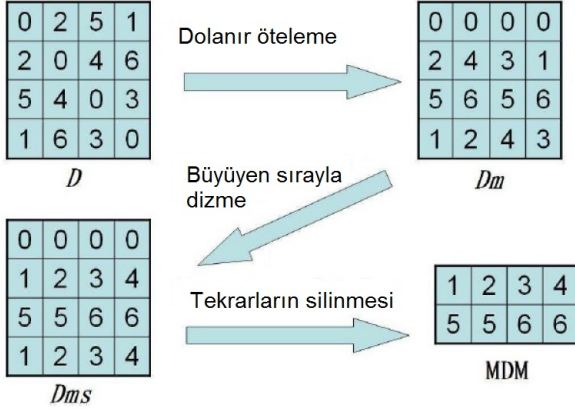
uzunluklarla, bir mesafe matrisi oluşturulur. Bu matrisin sütunları şekil 8'deki gibi döndürülerek her noktanın kendisi ile olan mesafesi birinci satıra getirilir. Böylece noktaların başlangıç ve bitiş noktaları önemini kaybeder. Matrisin bütün satırları da, soldan sağa artacak şekilde sıralanır. Böylece noktaların alınış sırası önemini kaybeder. Yani, aynı şekli tanımlamak için seçilecek başlangıç noktasının veya noktaların sırasının önemi kalmaz. Matrisin ilk satırı (sıfır satırı) ve satırların ikinci yarısı (ilk yarısı ile aynı) gereksiz olduğu için atılır. Elde edilen MDM'i (şekil 7) şekil boyutundan bağımsız hale getirmek için son olarak matris, ortalama değerine bölünür. Böylece aynı şeklin farklı boyutları ile aynı matris elde edilebilir.



Şekil 7: Yaprak şeklinden çıkartılan MDM

2.4. Sınıflandırma

Sınıflandırma için QDA ve k-NN kullanılmıştır. Genel biçim özniteliklerinin ve Fourier özniteliklerinin Gauss şekline benzer bir şekilde dağılacığı varsayılmıştır. MDM-A özniteliklerinde ise, k-NN sınıflandırıcı kullanılarak, öznitelikleri arasındaki öklid mesafesi en düşük olan 5 örnek alınmıştır.



Şekil 8: MDM hesaplanması [4]

3. DENEYLER

Bu çalışmada, iki veri tabanında dört performans testi yapılmıştır. Bu testler şöyledir.

1. Flavia [3] veri tabanı eğitim kümesinden 3 öznitelik kümesi çıkartılıp, ayrı ayrı test kümesindeki performansları,
2. Aynı öznitelik kümeleri kullanılarak, test kümesindeki birleşik performansları,
3. SLID [5] veri tabanı eğitim kümesinden 3 öznitelik kümesi çıkartılıp, ayrı ayrı test kümesindeki performansları,
4. Aynı öznitelik kümeleri kullanılarak, test kümesindeki birleşik performansları çıkartılmıştır.

Deneylerde eğitim kümesi ve test kümesi ayrımı bir defaya mahsus rastgele yapılmıştır. Bunu takiben bütün testlerde aynı eğitim kümesi ve test kümesi kullanılmıştır. Böylece seçilmiş olan örneklerin performansa etkileri sabitlenmiştir. Öznitelik sınıflarının tekil performansları ve birleşik performansları ayrı ayrı verilmiştir. Böylece, birleşimin etkisi direkt görülebilir.

3.1. Veri Tabanları

Flavia [3] veri tabanı 32 yaprak sınıfından oluşur. Her sınıfta 50 ile 77 arası yaprak örneği bulunur. 32 sınıftan toplam örnek sayısı 1907'dir. Örnek imgeler 1600x1200 çözünürlüğünde ve 3 kanallıdır.

SLID [5] veri tabanı 15 yaprak sınıfından oluşur. Her sınıfta 75 adet yaprak örneği bulunur. Yani toplam 15 sınıftan 1125 örnek vardır. Çözünürlük yaklaşık 1,5 Mpx olup, örnekler arasında küçük değişiklikler gösterir.

3.2. Sonuçlar

İki veri tabanından da rastgele bir şekilde örneklerin %90'ı eğitim kümesi olarak, kalan %10'u ise test kümesi olarak ayrılmıştır. Böylece, farklı öznitelik kümelerinin tekil ve birlikte daha önce görmedikleri örnekler üzerindeki başarıları ölçülmüştür.

Tablo 1: Flavia veri tabanındaki sonuçlar

Öznitelik Kümesi	Eğitim	Test
Genel Biçim	%82,07	%80,70
Fourier	%78,77	%49,95
MDM-A	%88,18	%82,99
Tümü	%89,52	%88,51

Tablo 2: SLID veritabanındaki sonuçlar

Öznitelik Kümesi	Eğitim	Test
Genel Biçim	%89,65	%86,67
Fourier	%84,88	%75,00
MDM-A	%94,83	%94,17
Tümü	%96,02	%95,00

4. VARGILAR

Bu çalışmada basit genel biçim öznitelikler kullanarak kabul edilebilir performanslar elde ettiğimizi gözlemledik. Fourier tanımlayıcıları ise beklenenin altında performans gösterirken, MDM-A ise beklenenin üzerinde bir performans çıkardı. Üç farklı öznitelik kümesinin sonuçları sınıfları tanımlama güçleriyle ağırlandırdıktan sonra birleştirildiğinde, birbirlerinin eksiklerini kapatarak, toplam performansın yükseltilebileceğini gösterdik.

5. KAYNAKÇA

- [1] T.L. KUNII C. IM, H. NISHIDA, "Recognizing plant species by leaf shapes-a case study of the acer family," *Proceedings of IEEE International Conference on Pattern recognition*, p. 1171, 1998.
- [2] Z Wang, Z Chi, and D Feng, "Shape based leaf image retrieval," 2003.
- [3] Stephen Gang Wu, Forrest Sheng Bao, Eric You Xu, Yuxuan Wang, Yi-fan Chang, and Qiao-liang Xiang, "A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network," pp. 1-6, 2007.
- [4] R. Hu, W. Jia, H. Ling, and D. Huang, "Multiscale distance matrix for fast plant leaf recognition," *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*, 2012.
- [5] O. Söderkvist, *Computer vision classification of leaves from swedish trees*, Ph.D. thesis, Linköping, 2001.