



Örüntü tanıma teknikleri ile agar yüzeyi üzerinde koloni morfoloji sınıflandırması

Pattern recognition techniques on agar surface colony morphology classification

Volkan ALTUNTAŞ^{1*}, Seda ALTUNTAŞ², Murat GÖK³

¹Bilgi İşlem Daire Başkanlığı, Bursa Teknik Üniversitesi, Bursa, Türkiye.

volkan.altuntas@btu.edu.tr

²Gıda Mühendisliği Bölümü, Mühendislik Fakültesi, Bursa Teknik Üniversitesi, Bursa, Türkiye.

seda.altuntas@btu.edu.tr

³Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Yalova Üniversitesi, Yalova, Türkiye.

murat.gok@yalova.edu.tr

Geliş Tarihi/Received: 15.08.2016, Kabul Tarihi/Accepted: 31.05.2017

* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2017.23169

Araştırma Makalesi/Research Article

Öz

Mikroorganizmalar çıplak gözle göremeyeceğimiz kadar küçük canlılardır. Ekolojik dengede rol oynayan mikroorganizmalar temel olarak bakteriler, mantarlar, algler, virüsler ve protozoalardan oluşur. Besiyeri ve petri kabı, mikroorganizmaların ortamdan yalıtılması, geliştirilmesi, tanımlanması, sayımı gibi işlemlerin yerine getirilmesi için agar ve diğer besin maddeleri karıştırılarak, mikroorganizmalara büyüme ortamı sağlamak amacı ile kullanılırlar. Mikroorganizmalar çoğalarak sayıyı milyonlara hatta daha fazlasına ulaşabilir böylece çıplak gözle görülebilen, koloni olarak adlandırılan yapıları oluştururlar. Terminolojide bu yapı, koloni oluşturan birim (kob, cfu) olarak ifade edilir. Peynir, ekmek, meyve veya yoğurtların üzerindeki küfler, çikolata, marmelat gibi şeker içeren gıdalar üzerindeki mayalar, mikroorganizmaların çoğalarak oluşturduğu kolonilerdir. Besiyeri üzerinde oluşan koloniler, mikroorganizma ve üreme ortamına bağlı olarak farklı morfolojik özelliklerde görüntüler oluşturmaktadır. Bu çalışmada koloni görüntülerinden görüntü işleme ve örüntü tanıma teknikleri ile mikroorganizmaların sınıflandırılması yapılmaktadır.

Anahtar kelimeler: Mikrobiyoloji, Koloni oluşturan birim, Taksonomi, Segmentasyon, Öznitelik çıkarımı, Sınıflandırma

Abstract

Microorganisms are small organisms as we cannot see with the naked eye. Microorganisms that play a role in the ecological balance are mainly composed of bacteria, fungi, algae, viruses and protozoa. The medium and petri dish are used in order to provide the growth medium to microorganisms by mixing agar and other nutrients for performing operations such as isolating from the environment, growth, counting of microorganisms. The number of microorganisms may reach the million or even more by reproductively, in this way they form structures called colony which can be seen with the naked eye. In terminology, this structure expressed as colony forming units (cfu). Mold on the cheese, bread, fruit or yogurt, yeast on the sugar-containing foods such as chocolate, marmalade are colonies formed by grown microorganism. Colonies formed on the agar, create images of different morphological characteristics depending on the microorganism and growth media. In this paper, classification of microorganism is performed from the colony images by image processing and pattern recognition techniques.

Keywords: Microbiology, Colony forming unit, Taxonomy, Segmentation, Feature extraction, Classification

1 Giriş

Mikroorganizmalar, atmosferin birçok tabakasında, yer kürenin oldukça derinliklerinde, akarsularda, okyanusların en derin noktalarında, kayaların içlerinde, ekosistemin her bölgesinde yaşayabilmekte ve yaşamlarımızın her alanında varlıklarını sürdürmektedirler.

Katı besiyeri kullanımı mikroorganizmaların tespit edilmesinde kullanılan yöntemlerden biridir. Küf, maya ve bakteriler, bulundukları üreme ortamına (besiyeri) ve mikroorganizma cinsine göre farklı morfolojik özelliklerde koloni görüntüleri oluştururlar. Oluşan bu görüntülerden mikroorganizmanın cinsine karar verilmektedir.

Görüntü işleme ve örüntü tanıma ile imge sınıflandırılması birçok problemin çözümünde önemli rol oynamaktadır. Türkoğlu [1] kan hücrelerinin tanınması ve sınıflandırılması için değişmez moment ve çoklu sınıf destek vektör makinelerine dayalı bir yöntem kullanmıştır. Koçer [2] iris görüntülerinin sınıflandırılmasını canny kenar bulma, gabor dalgacık dönüşümü, ortalama mutlak sapma ve yapay sınır ağları kullanarak gerçekleştirmiştir. Kayaaltı [3] bilgisayarlı


tomografi görüntülerinden karaciğer fibrozisinin evrelendirilmesi için, glcm matrisi, ayrık dalgacık dönüşümü, ayrık fourier dönüşümü, gabor filtreleri, destek vektör makineleri ve k-en yakın komşu tekniklerini kullanmıştır. Chourasiya ve Rani [4] kırmızı kan hücrelerinin otomatik sayımı için işaretçi kontrollü havza segmentasyon tekniğini kullanmıştır. SW. Myint [5] tarafından yürütülen çalışmada; fraktal yaklaşım, yüksek çözünürlüklü görüntü verilerinde şehre ait arazi görüntüsünün yapısal özelliklerini karakterize etmek için kullanılmıştır. Dalal ve diğ. [6] insan tespiti için orijinal MIT yaya veri tabanı üzerinde HOG (Gradyan Oryantasyon Histogram - Histograms Oriented Gradients) yöntemini kullanmışlardır. Eleyan ve diğ. [7] yüz tanımlama için GLCM (Gri Seviyeli Eş-oluşum Matris-Gray-Level Co-occurrence Matrix) ve bu yönteme ait istatistiksel özellikleri yeni bir yaklaşım olarak önermektedirler. Chapelle ve diğ. [8] yaptığı çalışmada, görüntü sınıflandırma için histogram özellikleri ile SVM (Destek Vektör Makineleri - Support Vector Machines) yöntemini kullanmışlardır. Gurpreet Kaur ve Poonam Sethi [9], kontrastı trifeniltetrazolyum klorit ile güçlendirilmiş bakteri koloni görüntüleri üzerinde filtreleme ve eşikleme tekniklerini kullanmışlardır. Er. Monita Goyal, [10]

belirli boyutlardaki ve dairesel özelliklerdeki kolonileri saymak için görüntü süzme, eşikleme ve Heywood dairesel faktör tekniklerini ile birlikte Harris öznitelikli kullanmışlardır. Quentin Geissmann [11] nın yaptığı çalışmada, agar yüzeyindeki dairesel koloniler eşikleme ve morfolojik segmentasyon ile tanımlanarak sayılmıştır. Bae ve diğ. [12] bakteri teşhisi için, elastik ışık saçınımı tarafından üretilen görüntüler üzerinde GLCM (Gri Seviyeli Eş-oluşum Matris - Gray-Level Co-occurrence Matrix) ve şekil bazlı öznitelik uygulamışlardır. Görüntülerin tek bir koloniden mi yoksa daha fazla koloniden mi oluştuğunun tespiti için, Bottigli ve diğ. [13] geometrik şekil özniteliklerini kullanmışlardır. Benzer çalışma Brugger [14] tarafından koloni sayısını doğrulamak amacıyla da yapılmıştır.

Bu çalışmada mevcut örüntü tanıma ve görüntü işleme yöntemlerinden hangilerinin bu probleme uygun olduğunun tespit edilmesi amacı ile sınıflandırma ve öznitelik çıkarımı yöntemlerinin performans kıyaslaması yapılmıştır.

2 Yöntem


Küf, maya ve bakteri sınıflandırması için kullanılan örüntü tanıma sistemi Şekil 1'de görüldüğü gibi Veri Toplama, Ön İşlem, Öznitelik Çıkarımı ve Sınıflandırma adımlarından oluşmaktadır.



Şekil 1: Örüntü tanıma sistemi mimarisi.

2.1 Veri toplama

Örnek numuneler uygun şartlarda, ISO 6611/ IDF 94: 2004 ve IDF 73B:1998 standartları kullanılarak oluşturulmuştur. Veri seti, numunelerden homojen aydınlatma altında 8 MP kamera ile alınan 350 adet imgeyi içermektedir. Şekil 2'de örnek bir petri görüntüsü yer almaktadır.



Şekil 2: Petri görüntüsü.

2.2 Ön işlem

Küf, bakteri ve mayaların imgeden ayrıştırılması için veri seti üzerinde çeşitli segmentasyon teknikleri denenmiştir.

Aşağıdaki segmentasyon teknikleri diğerlerine kıyasla daha yüksek başarı oranlarına sahiptir.

2.2.1 İşaretçi kontrolü havza segmentasyon tekniği (İKHST)

Bir yüzeyi yerel minimumlarından delerek suya batırdığımızı düşünürsek, su adım adım en düşük yükseklikli minimumdan başlayarak farklı havzalara dolacaktır. Farklı havzalardan gelen suların birleşim noktalarına barajlar inşa edilirse batırma işleminin sonunda havzalar tamamen sınırlanacak şekilde barajlar ile çevrilmiş olur. Bu işleme yüzeyin en yüksek tepesine ulaşılan kadar devam edilir. Sonuç olarak, yüzeyi farklı bölgelere ya da havzalara ayıran barajlar havza çizgileri ya da sadece havzalar olarak adlandırılır. Watershed segmentasyon tekniğinin en büyük dezavantajı aşırı bölütlemidir. Bu problemi ortadan kaldırmanın bir yolu işaretçi kullanmaktır. İlk olarak, nesne işaretçileri olarak adlandırılan ve nesneleri işaretlemek için kullanılan gerekli özellikler tanımlanır. Arka plan işaretçileri olarak adlandırılan ve herhangi bir nesneye ait olmadığı bilinen imge parçaları da işaretlenir. Geri kalan adımlar bütün uygulamalar için aynıdır. Gradyan imgesi, işaretçiler arasında yer alan ilgilenilen bölümün sınırları korunacak şekilde değiştirilir. Son işlem olarak değiştirilmiş gradyan imgesi üzerinde watershed dönüşümü uygulanarak son sınır belirlemesi gerçekleştirilir [15],[16].

2.2.2 Gabor filtreleri ile doku segmentasyon tekniği (GBDST)

Bölge tabanlı yöntemlerden olan Gabor filtreleri ile doku segmentasyonu, imgeyi doku özellikleri temelinde bölgelere ayırma işlemidir. Dokuların yorumlanması için insan görme sistemindeki çok kanallı işlemlerin keşfi ile birlikte, doku segmentasyonu üzerine yapılan çalışmalar, farklı doku bölgelerinin tespiti için Gabor filtreleri temelinde çok kanallı yaklaşımlara yönelmiştir. Deneyimler göstermektedir ki Gabor filtreler, memeli görme sistemindeki basit hücrelerin makul bir modelidir, bu nedenle insanların dokuları kolayca ayırt edebilmesinin iyi bir modeli olarak düşünülmektedir. Gabor filtreler ile doku segmentasyonu temel üç aşamadan oluşmaktadır;

- 1) Tasarlanan Gabor filtresinin özgün imgeye uygulanarak, görüntünün gri seviyeye dönüştürülmesi,
- 2) Filtrelenmiş imgeden öznitelik çıkarımı,
- 3) Kümeleme.

İlk olarak Gabor büyüklüklerinin (magnitüde) çıkarılması için gri seviyeye dönüştürülmüş imge, tasarlanan Gabor filtre dizisi ile filtrelenir. İmgenin filtreye yanıtı olan Gabor büyüklüklerinin sınıflandırmada kullanılabilmesi için Gauss yumuşatma, öznitelik kümesine bölgesel bilgi eklenmesi, kümeleme algoritmaları için özniteliklerin yeniden şekillendirilmesi ve normalizasyon gibi işlemler yapılarak Gabor öznitelikleri elde edilir. Son adım olarak pikseller kümeleme ile doku bölgelerini temsil eden bölgeler halinde kümelendir [17]-[19].

2.2.3 Canny kenar belirleme ile segmentasyon tekniği (CKAST)

Kenar tabanlı yöntemlerden olan Canny kenar belirleme algoritması 5 adımda gerçekleştirilmektedir;

1. İmgede bulunan görüntüyü elimine etmek için Gauss filtresi uygulanır,
2. Görüntüden gradyanları ve yönleri hesaplanır,
3. Yapay yanıtlardan kurtulmak için maksimum olmayan piksel değerleri baskılanır,
4. Potansiyel kenarları belirlemek için ikili eşikleme uygulanır,
5. Zayıf ve güçlü kenarlarına bağlı olmayan tüm diğer kenarları baskılayarak kenarların tespiti tamamlanır.

Canny algoritması ile belirlenen kenarlardan objeler oluşturularak segmentasyon işlemi tamamlanır [20].

Yapılan çalışmalar sonucunda, işaretçi kontrollü havza segmentasyon tekniğinin en başarılı sonuçları ürettiği tespit edilmiş ve çalışmada bu teknik kullanılmıştır. Şekil 3'te işaretçi kontrollü havza segmentasyon sonucunda oluşan örnek objeler yer almaktadır.



Şekil 3: Segmentasyon sonuç görüntüsü.

2.3 Öznetelik çıkarımı

Küf maya ve bakteri imgelerinden özneteliklerin oluşturulması için çeşitli yöntemler denenmiştir. Aşağıdaki öznetelik çıkarım yöntemleri diğerlerine kıyasla daha yüksek başarı oranlarına sahiptir.

2.3.1 Histogram

Bir imgenin gri seviye histogramı imgedeki piksellerin gri seviye ölçeğindeki dağılımlarını gösterir. Her piksel renk yoğunluğuna tekabül eden gri seviye kümeye dâhil edilir. Kümelere ait eleman sayıları ilgili gri seviyenin histogram değerine karşılık gelir. Özneteliğin oluşturulması için histogram değerlerinden ortalama, varyans, çarpıklık, basıklık, enerji, entropi değerleri hesaplanarak bir dizide birleştirilir.

2.3.2 HOG

Son yıllarda imge tanıma çalışmaları kapsamında kenar oryantasyon histogramlarının kullanımı büyük bir ivme kazanmıştır. Ancak yoğun ve lokal gradyan oryantasyon histogramlarının (HOG) kullanımı ilk defa Shashua ve Dalal tarafından önerilmiştir. Bu yöntemdeki amaç imgeyi bir grup lokal histogramlar olarak tanımlamaktır. Bu histogramlar, imgenin lokal bir bölgesindeki gradyanların oryantasyonlarının oluşma sayılarını içerir. HOG' tanımlayıcılarının gerçekleştirilmesindeki işlem basamakları şu şekilde sıralanabilir [21]-[24].

1. RGB (Kırmızı Yeşil Mavi-Red Green Blue) imge gri seviyeli imgeye dönüştürülür ve gri seviyeli imgenin yatay ve dikey gradyan değerleri elde edilir,
2. Yatay ve dikey gradyan değerleri kullanılarak gradyan yönelimi ve gradyan büyüklüğü değerleri elde edilir,
3. Gradyan yönelimleri imgesi boyutunda hücrelere bölünür ve her bir hücre içerisindeki gradyan yönelimleri kırk beşer derecelik 8 farklı duruma etiketlenir,

4. Belirlenen her bir blok için gradyan büyüklüğü ve gradyan yönelimleri kullanılarak lokal histogramlar oluşturulur,
5. Oluşturulan lokal histogramlar normalize edilir.

Tüm histogamlar birleştirilerek öznetelik vektörü olarak kullanılır. HOG öznetelik çıkarım için özet şema Şekil 4'te yer almaktadır. HOG için uygun parametrelerin belirlenebilmesi adına 2-2, 3-3, 4-4 blok boyutları ve 8-8, 16-16, 32-32, 64-64, 128-128 ve 256-256 hücre boyutları ile öznetelikler oluşturularak en yüksek sınıflandırma performansına ulaşılan parametreler seçilmiştir.




Şekil 4: HOG genel yapısı.

2.3.3 SURF

SURF (Hızlandırılmış Gürbüz Öznetelikler - Speeded Up Robust Features), nesne tanıma, sınıflandırma, 3D oluşturma gibi işleri yerine getirmek için kullanılan lokal bir öznetelik çıkarım tekniğidir. SIFT (Ölçekten Bağımsız Öznetelik Dönüşümü - Scale-Invariant Feature Transform) den esinlenilerek geliştirilen SURF'ün standart versiyonu SIFT'e göre daha hızlıdır ve görüntü dönüşümlerinden daha az etkilenmektedir. SURF algoritmasındaki hız artışı, her görüntü dizisinden elde edilen farklı ölçeklerde süzgeçlenmiş görüntü piramidi yerine farklı ölçeklerde oluşturulan süzgecin sabit boyuttaki görüntü dizilerine uygulanması ve böylece her görüntü dizisi için ayrı işlem yapılmaması ile gerçekleştirilmiştir. SURF algoritmasında temel olarak Hessian matrisi ve basit Laplace hesaplaması ile tespit edilen ilgi alanlarının, Haar-Wavelet algoritmasına tepkisi bulunur ve tanımlama olarak kullanılır [25]-[28].

2.3.4 BRISK

BRISK (Ölçek Bağımsız Gürbüz İkili Kilit Noktalar-Binary Robust Invariant Scalable Keypoints), elle hazırlanmış örnekleme modellerine sahip olan tanımlayıcılardan farklıdır, örnekleme deseni Şekil 5'te olduğu gibi konsantrik halkalardan oluşur:



Şekil 5: BRISK örnekleme deseni.

BRISK'in ikili tanımlayıcıları üç bölümden oluşmaktadır;

1. Örnekleme deseni: tanımlayıcı etrafındaki bölgenin noktalarını örnekleme için kullanılır.
2. Oryantasyon kompanzasyonu: Anahtar noktasının yönünü ölçmek ve dönüş değişikliklerini telafi etmek için kullanılan mekanizmalardır.
3. Örnekleme çiftleri: Son tanımlayıcıyı oluştururken karşılaştırılacak çiftlerdir.

Her örnekleme noktası için çevresinden küçük bir parça alınır ve Gauss yumuşatması uygulanır. Kırmızı daire, örnekleme noktalarına uygulanan Gauss filtresinin standart sapmasının boyutunu göstermektedir. Kısa çiftler ve uzun çiftler arasında ayırım yapılır. Uzun çiftler yönlendirmeyi belirlemek için, kısa çiftler yoğunluk karşılaştırmaları için kullanılır. BRISK anahtar noktasının yönünü tahmin etmeye ve örnekleme desenini o oryantasyonla döndürmeye çalışarak, dönüşümle değişmez hale gelmiştir. Anahtar noktasının yönünü hesaplamak için, BRISK tarafından tanımlanan örnekleme çiftleri arasındaki yerel eğimler kullanılır. Tanımlayıcılar yoğunluk karşılaştırmaları ile oluşturulur. Tüm tanımlayıcılar birleştirilerek öznitelik vektörü olarak kullanılır [29].

2.3.5 HARRIS

HARRIS kenar tespiti 4 aşamadan oluşmaktadır;

1. x ve y yönündeki görüntü yoğunluk eğimleri hesaplanır,
2. Oluşan çıktı bulanıklaştırılır,
3. Harris yanıtı hesaplanır,
4. 3x3 komşuluktaki maksimum olmayanlar baskılanır ve eşikleme uygulanır.

Harris yöntemi, Moravec'in yönteminde kaydırılmış parçaları kullanmak yerine köşe skorunun doğrudan yön açısından farkı göz önüne alınarak geliştirilmiştir. Köşe skoru hesaplaması için kare farkların toplamı kullanılmaktadır. Bulunan noktalar birleştirilerek öznitelik vektörü olarak kullanılır [30].

2.3.6 MinEigen

Minimum öz değer hesaplamasına dayanmaktadır ve 5 aşamadan oluşmaktadır;

1. Görüntünün her noktasındaki eğim hesaplanır,
2. Eğim değerlerinden H matrisi oluşturulur,
3. Öz değerler hesaplanır,
4. Büyük yanıtı değerler bulunur ($\lambda_{\min}$ eşik değeri),
5. $\lambda_{\min}$ 'un lokal maksimum olduğu noktalar öznitelik olarak seçilir.

Tüm tanımlayıcılar birleştirilerek öznitelik vektörü olarak kullanılır [31].

2.4 Sınıflandırma

Küf, maya ve bakterilerin sınıflandırılması için NaiveBayes, k-NN ve C4.5 Karar Ağacı sınıflandırıcıları kullanılarak "1 Küf", "2 Küf", "3 Küf", "4 Küf", "1 Maya", "2 Maya", "1 Bakteri", "2 Bakteri", "3 Bakteri", "4 Bakteri", "1 Bakteri Koliform", "2 Bakteri Koliform" ve "Sayım Dışı" olmak üzere 13 sınıf etiketinden oluşan tahmin yapılmıştır.

2.4.1 Naive bayes


Adımı matematikçi Thomas Bayes'den alan, Bayes karar teorisine dayanan basit bir olasılıksal sınıflandırıcıdır. Naive Bayes sınıflandırmasında sisteme hangi sınıflara ait oldukları bilinen belirli bir oranda öğretilmiş veri sunulur. Öğretilmiş veriler üzerinde yapılan olasılık hesapları ile sisteme sunulan yeni test verileri, daha önce elde edilmiş olasılık değerlerine göre işletilir ve verilen test verisinin hangi sınıfa ne kadar olasılıkla ait olduğu tespit edilmeye çalışılır [32].

2.4.2 k-NN

k-NN algoritması, sınıflandırma amacıyla sıklıkla kullanılan danışmanlı ve parametrik olmayan algoritmalarından biridir. k-NN hiçbir eğitim süreci içermediğinden,, diğer sınıflandırma teknikleri ile karşılaştırıldığında bu teknik düşük bir hesaplama maliyeti olan basit bir sınıflandırma tekniğidir. Özellikle veri setindeki verilerin dağılımı ile ilgili önceden bir bilgiye sahip olunmadığı durumlarda kullanılır [33]. Sınıflandırma için kullanılan temel yaklaşım, sınıflandırılmak istenen yeni örneğin daha önceden hangi sınıfa ait olduğu bilinen örneklerden k tanesine yakınlığına bakılmasıdır. K sayısının değeri sınıflandırma açısından önemlidir. K değeri çok küçük olursa model çok etkilenir, çok büyük olursa da tek bir sınıf gibi olur. Yani k sayısının sınıflandırma performansına etkisi vardır [34].

2.4.3 C4.5 karar ağacı

Karar ağacı sınıflandırıcıları sinyal sınıflandırma, karakter sınıflandırma, uzaktan algılama, tıbbi teşhis, uzman sistemler ve konuşma sınıflandırma gibi birçok geniş alanda başarılı bir şekilde kullanılmaktadır. Karar ağacı sınıflandırıcılarının en önemli özelliği, karışık karar verme süreçlerini daha basit kararlar topluluğuna dönüştürmektir ve böylece bu yolla alınan sonuç çözümünün istenilen çözüme benzemesi istenir [35]. Örnekler, ağacın kökünden başlayıp yaprağa doğru gezinerek sınıflandırılır. Burada yol, her bir düğümdeki bölünme şartının sonucuna göre belirlenir. Köke karşılık gelen öznitelik ele alınır. Ardından bu özneliğin gözlenen değerinin hangi çıkış dalına karşılık geldiği bulunur. Yol üzerindeki bir sonraki düğüm seçilmiş olan dalın sonunda olan düğümdür. Aynı işlemler bu düğüm içinde tekrarlanır ve yaprağa ulaşıncaya kadar ağaçta gezinilir [36]. Kategorik veriler ile çalışan ID3 algoritmasından farklı olarak C4.5 algoritması sayısal veriler ile çalışma olanağı sağlar. Şekil 6'da örnek bir karar ağacı şeması yer almaktadır.



Şekil 6: Örnek bir karar ağacı.

3 Bulgular

Bakteri küf ve mayaların sınıflandırılmasında 10 kat çapraz doğrulama test tekniği kullanılmıştır. Bu teknikte veri seti 10 eşit kümeye bölünür, 9 küme eğitim için, 1 küme test için kullanılır ve her küme test kümesi olarak kullanılacak şekilde işlem tekrarlanır. Öznitelik vektörlerinin performans ölçümleri için sınıf doğruluğu metrik değeri kullanılmış, öznitelik vektörüne PCA ve LDA boyut azaltma teknikleri uygulanmıştır. Boyut azaltım uygulamasında veri setinin %80 ile temsil edilmesi hedeflenmiştir. İlgili metrik karmaşıklık matrisinde elde edilen doğru artı (DA), doğru eksi (DE), yanlış artı (YA) ve

yanlış eksi (YE) değerleri kullanılarak aşağıdaki formül ile hesaplanmaktadır [37].

$$\text{Doğruluk} = \frac{DA+DE}{DA+YA+DE+YE} \quad (1)$$

Tablo 1’de k-NN algoritmasına göre agar görüntü veri seti üzerinde elde edilen başarımlar görülmektedir. Deneysel sonuçlara göre k-NN sınıflandırıcısı altında %65’lik sınıf doğruluğu, %68’lik sınıf doğruluğu (PCA) ve %62’lik sınıf doğruluğu (LDA) değerleri ile en iyi başarımları HOG tekniği vermiştir. MinEigen tekniği ise en düşük başarımları göstermiştir.

Tablo 2’de Naive Bayes sınıflandırıcısına göre agar görüntü veri seti üzerinde elde edilen başarımlar görülmektedir. Deneysel sonuçlara göre Naive Bayes sınıflandırıcısı altında %68’lik sınıf doğruluğu, %69’luk sınıf doğruluğu (PCA) ve %66’lık sınıf doğruluğu (LDA) değerleri ile en iyi başarımları HOG tekniği vermiştir. MinEigen tekniği ise en düşük başarımları göstermiştir.

Tablo 3’te C4.5 Karar Ağacı sınıflandırıcısına göre agar görüntü veri seti üzerinde elde edilen başarımlar görülmektedir. Deneysel sonuçlara göre C4.5 Karar Ağacı sınıflandırıcısı altında %66’lık sınıf doğruluğu, %68’lik sınıf doğruluğu (PCA) ve %60’lık sınıf doğruluğu (LDA) değerleri ile en iyi başarımları HOG tekniği vermiştir. MinEigen tekniği ise en düşük başarımları göstermiştir. PCA boyut azaltım tekniği ile 1296 niteliğe sahip HOG öznelik vektörü 1037 nitelik ile temsil edilerek sınıflandırma için bilgi içermeyen nitelikler azaltmış ve sınıflandırma başarımları arttırılmıştır.

4 Sonuç

Bu çalışmada; bakteri, küf ve mayalara ait koloni görüntülerinin sınıflandırılması için çeşitli segmentasyon teknikleri, öznelik çıkarım yöntemleri ve sınıflandırma algoritmaları kullanılmıştır. Küf, maya ve bakteri imgelerinin sınıflandırılmasında HOG öznelik çıkarım tekniğinin tüm sınıflandırma algoritmalarında en yüksek doğruluk oranına ve MinEigen öznelik çıkarım tekniğinin de en düşük doğruluk oranına sahip olduğu görülmektedir. En iyi sınıflandırıcı modeli HOG öznelik çıkarımı ve Naive Bayes sınıflandırma algoritması ile elde edilmiştir. Naive Bayes, k-NN ve C4.5 karar ağacı sınıflandırıcılarının aynı öznelikler üzerinde birbirlerine yakın sonuçlar ürettiği gözlemlenmiştir.

Gelecekte yapılacak çalışmalarda problemin çözümü için yeni öznelik tekniği geliştirilmesi planlanmaktadır. İkinci olarak tek sınıflandırıcı yerine sınıflandırıcıların birleşimleri ile problemin çözümü hedeflenmektedir.

5 Teşekkür

Bu çalışma Yalova Üniversitesi ve Bursa Teknik Üniversitesi tarafından desteklenmiştir.

6 Kaynaklar

- [1] Türkoğlu M. Otomatik Kan Hücrelerinin Tanınması ve Sınıflandırılmasında Değişmez Momentlere Dayalı Görüntü İşleme Yöntemlerinin Kullanılması. Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, Türkiye 2013.
- [2] Koçer HE. İris Deseninin Yapay Zeka Yöntemleri ile Tanınması. Doktora Tezi, Selçuk Üniversitesi, Konya, Türkiye, 2007.

Tablo 1: k-NN algoritması başarımları sonuçları.

Öznelik	Doğruluk	Doğruluk (PCA)	Doğruluk (LDA)
HOG	65	68	62
SURF + Histogram	58	63	57
Histogram	36	40	36
Brisk	32	33	32
Harris	22	26	21
MinEigen	20	25	21

Tablo 2: Naive Bayes algoritması başarımları sonuçları.

Öznelik	Doğruluk	Doğruluk (PCA)	Doğruluk (LDA)
HOG	68	69	66
SURF + Histogram	63	68	60
Brisk	40	45	41
Histogram	25	31	20
Harris	19	23	15
MinEigen	15	16	10

Tablo 3: C4.5 algoritması başarımları sonuçları.

Öznelik	Doğruluk	Doğruluk (PCA)	Doğruluk (LDA)
HOG	66	68	60
SURF + Histogram	58	61	45
Histogram	35	35	34
Brisk	34	38	34
Harris	22	25	20
MinEigen	21	25	18

- [3] Kayaaltı Ö. Bilgisayarlı Tomografi Görüntülerinden Tekstür Analizi ve Sınıflandırma Yöntemleri Yardımıyla Karaciğer Fibrozisinin Evrelendirilmesi. Doktora Tezi, Erciyes Üniversitesi, Kayseri, Türkiye, 2014.
- [4] Chourasiya S, Rani RU. "Automatic red blood cell counting using watershed segmentation". *International Journal of Computer Science and Information Technologies*, 5(4), 4834-4838, 2014.
- [5] Myint SW. "Fractal approaches in texture analysis and classification of remotely sensed data: comparisons with spatial autocorrelation techniques and simple descriptive statistics". *International Journal of Remote Sensing*, 24(9), 1925-1947, 2003.
- [6] Dalal N, Triggs B. "Histograms of oriented gradients for human detection". *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Diego, CA, 20-25 June 2005.
- [7] Eleyan A, Demirel H. "Co-occurrence matrix and its statistical features as a new approach for face recognition". *Turkish Journal of Electrical Engineering and Computer Sciences*, 19(1), 97-107, 2011.
- [8] Chapelle O, Haffner P, Vapnik VN. "Support vector machines for histogram-based image classification". *IEEE T Neural Networ*, 10(5), 1055-1064, 1999.
- [9] Gurpreet K, Poonam S. "A novel methodology for automatic bacterial colony counter". *International Journal of Computer Applications*, 49(15), 21-26, 2012.
- [10] Er Monita G. "Machine vision based bacteria colony counter". *IJETAE*, 2(4), 58-64, 2012.
- [11] Quentin G. "OpenCFU a new free and open-source software to count cell colonies and other circular objects". *PLoS ONE*, 8(2), 1-10, 2013.
- [12] Bae E, Ying D, Kramer D, Patsek V, Rajwa B, Holdman C, Sturgis J, Davisson VJ, Robinson JP. "Portable bacterial identification system based on elastic light scatter patterns". *Journal of biological engineering*, 6(1), 1-11, 2012.
- [13] Bottigli U, Carpinelli M, Fiori PL, Golosio B, Marras A, Masala GL, Oliva P. "A new automatic system of cell colony counting". *International Journal of Biological, Biomolecular, Agricultural, Food and Biotechnological Engineering*, 2(3), 78-82, 2008.
- [14] Brugger S D, Baumberger C, Jost M, Jenni W, Brugger U, Mühlemann K. "Automated counting of bacterial colony forming units on agar plates". *PLoS ONE*, 7(3), 1-6, 2012.
- [15] Meyer F, Beucher S. "Morphological segmentation". *Journal of Visual Communication and Representation*, 1(1), 21-46, 1990.
- [16] Soille P, Vincent L. "Determining watersheds in digital pictures via flooding simulations". *Visual Communications and Image Processing*, 1360, 240-250, 1990.
- [17] Jain AK, Farrokhnia F. "Unsupervised texture segmentation using Gabor filters". *Pattern Recognition*, 24(12), 1167-1186, 1991.
- [18] Seo N. "ENEE731 Project: Texture segmentation using gabor filters". The University of Maryland, Maryland, USA, Technical report, 1, 2006.
- [19] Sivalingamaiah M, Reddy BDV. "Texture segmentation using multichannel gabor filtering". *IOSR Journal of Electronics and Communication Engineering*, 2, 22-26, 2012.
- [20] Sharifi M, Fathy M, Mahmoudi MT. "A classified and comparative study of edge detection algorithms". *International Conference on Information Technology: Coding and Computing*. Las Vegas, USA, 8-10 April 2002.
- [21] Karakaya F, Altun H, Ald ÇM. "Gerçek zamanlı nesne tanıma uygulamaları için HOG algoritmasının FPGA tabanlı gömülü sisteme uyarlaması". *The Institute of Electrical and Electronics Engineers* 17, Antalya, Türkiye, 9-11 Nisan 2009.
- [22] Albayrak NB, Oktay AB, Akgül YS. "Bel omurları arası disklerin yerlerinin belirlenmesi". *Signal Processing and Communications Applications Conference*, Muğla, Türkiye, 18-20 Nisan 2012.
- [23] Erhan C, Tazehkandi AA, Yeşilyurt HY, Bayram İ. "Öznitelik betimleyicileri füzyonu ile trafik işaretlerinin tespit edilmesi ve tanınması". *Signal Processing and Communications Applications Conference*, Mersin, Türkiye, 24-26 Nisan 2013.
- [24] Yoldaş M, Şakar MO, Dirlikli M, Kılıncı OES. "Mamografi imgelerinden HOG öznitelikleri çıkartılarak hastaların kanser seviyelerinin belirlenmesi". *TMMOB EMO Ankara Şubesi Haber Bülteni İlk Bildiriler Konferansı*, Ankara, Türkiye, 14-16 Haziran 2013.
- [25] Bay H, Ess A, Tuytelaars T, Gool LV. "Surf: Speeded up robust features". *European Conference on Computer Vision*, Graz, Austria, 7-13 May 2006.
- [26] Juan L, Gwun O. "A coparison of SIFT, PCA-SIFT and SURF". *Internetonial Journal of Image Processing*, 3(4), 143-152, 2009.
- [27] Kocadere G. Video Görüntülerinin Sabitlemesi. Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara, Türkiye, 2010.
- [28] Buruş ME, Kuzu RS, Beyazıt S, Varol G. "Market raflarında dönüşüm ve ölçeklendirmeye dayanıklı nesne tanıma". *Akademik Bilişim*, Mersin, Türkiye, 5-7 Şubat 2014.
- [29] Leutenegger Stefan, Margarita Chli, Roland Y. Siegwart. "BRISK: Binary robust invariant scalable keypoints". *International Conference on Computer Vision*, Barcelona, Spain, 6-13 Nov. 2011.
- [30] Harris C, Stephens M. "A Combined Corner and Edge Detector". *4th Alvey Vision Conference*, Manchester, UK, 31 Aug – 2 Sep 1988.
- [31] Shi J, Tomasi C. "Good features to track". *IEEE Conference on Computer Vision and Pattern Recognition*, Seattle, USA, 21-23 June 1994.
- [32] Usta R. "Naive Bayes Sınıflandırma Algoritması". <http://kodcu.com/2014/05/naive-bayes-siniflandirma-algoritmasi> (04.12.2015).
- [33] Babaoğlu İ, Kiran MS, Ülker E, Gündüz M. "Diagnosis of coronary artery disease using artificial bee colony and K-Nearest Neighbor Algorithms". *International Journal of Computer and Communication Engineering*, 2(1), 56-59, 2013.
- [34] Yorgancılar S. "En Yakın Komşu Bulma Algoritması". <http://www.herturbilgi.com/2013/01/en-yakin-komsu-bulma-algoritmasi-knn> (12.12.2015).
- [35] Safavin SR, Landgrebe DA. "Survey of decision tree classifier methodology". *IEEE Transaction on Systems, Man and Cybernetics*, 21(3), 660-674, 1991.
- [36] Rokach L. *Pattern Classification Using Ensemble Methods*. Singapore, World Scientific Publishing, 2010.
- [37] Soille P, Vincent L. "Determining watersheds in digital pictures via flooding simulations". *Visual Communications and Image Processing*, 1360, 240-251, 1990.