

BT Görüntülerden Akciğerin Tespiti için Süper Piksel ve Yapay Sinir Ağı Tabanlı Bir Yöntem

Çağlar KILIĞIER*, Ersen YILMAZ

Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Bursa,
Türkiye

Geliş / Received: 26/01/2018, Kabul / Accepted: 16/05/2018

Öz

Tıbbi görüntülerden doku veya organların otomatik olarak tespit edilmesi bilgisayarlı görüntü alanının önemli çalışma konularından birisidir. Bu çalışmada bilgisayarlı tomografi (BT) görüntülerinden akciğerin otomatik olarak tespiti için bir yöntem önerilmiştir. Önerilen yöntem süper pikselleri kullanan yapay sinir ağları (YSA) üzerinde temellendirilmiştir ve klinik karar destek sistemleri için ilk aşama olarak kullanılması hedeflenmektedir. Yöntemin başarım incelemesi National Lung Screening Trial (NLST) veri tabanındaki BT görüntülerini üzerinde gerçekleştirılmıştır.

Anahtar Kelimeler: Bölümleme, Süper Piksel, Tıbbi görüntü, YSA

A Method based on Super Pixel and Artificial Neural Network for Lung Detection from CT images

Abstract

Detecting tissues and organs from medical images is an important topic in computer vision. In this work a method is proposed for automatic lung detection from computer tomography (CT) images. The proposed method is based on artificial neural networks (ANN) using super pixels and it is aimed to use as the first stage of a clinical decision support system. The performance of the method is examined on the CT images from the National Lung Screening Trial (NLST) database.

Keywords: ANN, Medical Image, Super Pixel, Segmentation

1. Giriş

Akciğerler ile ilgili çoğu rahatsızlıkta BT görüntülerinin yardımcı ile hastalık tanıları konulabilmektedir. Herhangi bir hasta için yapılan BT tatkikleri yüzden fazla görüntüyü barındırmaktadır, bu nedenle incelenmesi geniş zaman ve yoğun bir dikkat gerektirmektedir. Bulguları incelemek, tespit etmeyi kolaylaştmak ve hızlandırmak için tanı destek sistemlerinden faydalılmaktadır. Tıbbi görüntü temelli tanı destek sistemlerinde organ veya dokuların otomatik olarak tespiti önemli bir çalışma konusudur. Doku veya organların

otomatik tespitinde basit bölümleme işlemleri, benzer özelliklere sahip bölgeler nedeniyle, her zaman başarılı sonuçlar verememektedir. Literatürde tıbbi görüntülerin detaylı bölümlemesinde birden fazla yöntemin bir arada kullanıldığı melez yaklaşımlar bulunmaktadır. Bu yaklaşımların bir grubunda görüntü işleme yöntemleri makine öğrenmesi yöntemleri ile birlikte kullanılmaktadır (Zhou, 2016).

Makine öğrenmesi yöntemlerinden faydalanan çalışmaların bazlarında pikseller sınıflandırılarak görüntü bölümlemeye kullanılmışlardır (Fan vd., 2008; Wang vd.,

2011; Yang vd., 2014). Bu çalışmalarda piksellerden özellikler çıkartılarak piksel tabanlı sınıflandırma yoluyla bölütleme işlemi gerçekleştirilmektedir.

Fan vd. (2008) ortalama, kontrast, yoğunluk, korelasyon, entropi, açısal momentler ve varyans temelli özelliklerini kullanarak Destek Vektör Makineleri (DVM) ile görüntüleri bölütlemiştir. Çalışmalarında, tüm pikseller için sınıflama işlemi gerçekleştirerek farklı özellik grupları ile DVM çekirdeklerinin bölütlemeye etkisini incelemiş, az sayıda örnek ile gürültüden fazla etkilenmeyen bölütlemenin yapılabileceğini göstermiştir.

DVM ile görüntü bölütlemesini pikseller için renk ve doku özellikleri çıkartarak yapan farklı bir yaklaşım Wang vd. (2011)'de sunulmuştur. Bu yaklaşimda, bütün pikseller için özellik çıkartılması ve DVM'de kullanılan eğitim örneklerinin c-ortalamalı öbekleme algoritmasıyla bulunması işlem yükünü artırmaktadır.

Yang vd. (2014) piksellerin yerel özelliklerinden faydalananarak En Küçük Kareler DVM sınıflandırıcısı tabanlı bölütleme yapmışlardır ve örnek seçiminde iki boyutlu arimoto entropisinden yararlanmışlardır.

Tıbbi görüntülerin otomatik olarak incelenmesinde öne çıkan yöntemler arasında süper piksel temelli yaklaşımlardan faydalılmaktadır (Chu vd., 2015; Haas vd., 2012; Lê vd., 2016; Wang vd., 2016; Xu vd., 2011; Zhang vd., 2017; Liao vd., 2016). Süper piksellerden çıkartılan özelliklerin logitboost algoritması ile sınıflandırılarak glokoma tespitinin yapıldığı bir çalışma Xu, vd. (2011)'de sunulmuştur. Lê vd. (2016) tıbbi görüntülerin bölütlenmesinde BDYÖ (Basit Doğrusal Yinelemeli Öbekleme) süper piksellerden faydalılmışlardır.

Mamogramlarda kitle tespiti için morfolojik işlemler ve BDYÖ tabanlı bir yöntem Chu vd. (2015)'de önerilmiştir. Hatalı tespitlerin azaltılması için DVM, kural tabanlı sınıflandırıcı ve Mesafe Düzenlemeli Düzey

Küme Gelişimi yöntemlerinden yararlanılmıştır.

Wang vd. (2016) BDYÖ metodıyla beyin BT görüntülerini bölütlemiştir. Tümörlü bölgeleri gri yoğunluk değerlerine göre komşu süper pikselleri birleştirerek tespit etmiştir.

Zhang vd. (2017) BDYÖ'nün farklı bir varyasyonunu uzaysal yoğunluk tabanlı öbekleme algoritmalarıyla kullanarak akciğer nodüllerini bölütlemiştir.

BDYÖ, genetik algoritma ve öz oluşumlu sinir ormanı yöntemlerini bir arada kullanarak akciğer bölgelerinin tespit edildiği bir çalışma Liao vd. (2016)'da sunulmuştur.

Bir tıbbi görüntü erişim sisteminde ilgi duyulan noktaların tespiti için süper piksel tabanlı bir yöntem Haas vd. (2012)'de önerilmiştir.

Bu çalışmada BT görüntülerden akciğerlerin tespiti için süper pikseller ve YSA'nın birlikte kullanıldığı bir yöntem önerilmiştir. Süper pikseller aracılığı ile akciğer görüntülerini bölütlenmiş ve elde edilen bölütlere öznitelikler çıkarılmıştır. Öznitelikler kullanılarak hangi bölgelerin akciğerlere ait olduğu süper piksellerin YSA ile sınıflandırılmasıyla tespit edilmiştir.

2. Materyal ve Metot

2.1. Görüntü Kümesi

Görüntü kümesi olarak National Cancer Institute (NCI) tarafından "National Lung Screening Trial" için toplanan gri seviyeli 512x512 piksellik BT görüntüler kullanılmıştır.

2.2. Önerilen Yöntem

Süper pikseller, görüntülerde ilgilenilen bölgelerin sınırlarını takip edecek biçimde oluşturmaktadır. 512x512'lik BT görüntülerinde sınırları takip etmek için 1024 adet süper piksel yeterli olmaktadır. Süper piksellerin sınırlarının akciğer bölgesi ile örtüşmesini sağlamak için ilgili süper piksellerin bulunması gereklidir. Bu sebeple birbirine benzer piksel gruplarından oluşan süper

pikselleri makine öğrenmesi yöntemleriyle sınıflandırarak ilgilenilen bölgelerin bulunması amaçlanmıştır. Literatürde piksellerin sınıflandırılmasına dayanan bölütleme çalışmaları bulunmaktadır (Fan vd., 2008; Wang vd., 2011; Yang vd., 2014). Bu çalışmalarda görüntülerdeki tüm pikseller tek tek sınıflandırılmaktadır. İmgedeki pikseller tek tek değerlendirildiğinde, arka plan ile benzer bölgeleri barındıran ve homojen olmayan ön plan nesneleri için sınırların yakalanması her zaman mümkün olamamaktadır.

Önerdiğimiz yöntemde öncelikle görüntüler [0,1] aralığına normalize edilmekte ve pikseller öbeklenerek ilgilenilen bölgelerin sınırlarını içerecek biçimde süper piksellere ayrılmaktadır. Daha sonra süper pikseller YSA yardımıyla sınıflandırılarak akciğerlerin tespiti yapılmaktadır.

2.2.1. Süper Pikseller

Süper pikseller genellikle yüksek kaliteli bölütlemeye önişlem, nesne model tayini, iskelet çıkartma, nesne yer tayini vb. problemlerin çözümünde kullanılmaktadır (Achanta vd., 2010). Tıbbi görüntü analizlerinde ilgilenilen bölgelerin tespiti amacıyla yapılan bölütleme işlemlerinde ve görüntü erişim sistemlerindeki anahtar nokta tespitinde süper piksellerden faydalılmaktadır. Piksellerin birbiriyle olan ilişkilerinden bağımsız ele alınması anlam kaybına yol açmaktadır. Birbirleriyle olan ilişkilerini dikkate almak için seçilen sabit bir pencere aralığındaki komşuluk ilişkilerini kullanan yaklaşım ise her zaman yeterli sonuçlar vermemekte ve ayrıca hesaplama yükünü oldukça artırmaktadır.

Görüntülerde birbirine benzeyen ve tekrar eden bölgelerdeki pikseller birleştirilerek daha az sayıda eleman (süper pikseller) ile çalışılabilmektedir. Genel olarak süper piksellerden beklenen özellikler görüntülerdeki sınırları çıkartabilmeleri, ön işlem olarak hızlı bir şekilde hesaplanarak işlem yükünü azaltmaları ve bölütleme gibi

işlemlerde hızı ve bülütlerin kalitesini artırmalarıdır (Faust vd., 2012). Literatürde, süper piksellerin elde edilmesinde kullanılan farklı yaklaşımlar bulunmaktadır. Sınırların doğru bir şekilde oluşturulmasının öncelikli olduğu durumlarda genellikle çizge temelli yöntemler tercih edilirken, işlem hızının önemli olduğu durumlarda ise öbekleme yöntemleri tercih edilmektedir. Ayrıca, tercih edilen süper piksel yaklaşımına göre süper piksel sayısı, boyutu ve bütünlüğü gibi özelliklerden bazıları parametrik olarak kontrol edilebilmektedir.

Cizge temelli yöntemlerde pikseller arası benzerlik önem kazanmaktadır. Süper pikseller çizge için tanımlanmış bir maliyet fonksiyonunun minimize edilmesini sağlayacak şekilde oluşturulmaktadır. Öbeklemeye dayanan yaklaşımında ise pikseller kabaca öbeklenerek gradyan inişi yöntemleriyle bir yakınsama ölçübüne göre iyileştirilmekte ve oluşan bu öbekler süper piksellere dönüştürülmektedir.

Bu çalışmada gruplama ve öznitelik çıkarmada başarılı sonuçlar veren BDYÖ süper piksel yöntemi normalize edilmiş görüntülerde kullanılmıştır.

BDYÖ Yöntemi

BDYÖ gradyan iniş ve k-ortalamalı öbekleme yöntemleri üzerinde temellendirilmiştir. Öbeklemede gri renk uzayı ve pikseller arasındaki mesafeler kullanılmaktadır. Öbek sayısı k , ön bilgi olarak görüntüye göre seçilmektedir. Küçük k değerleri az sayıda ve büyük boyutta süper piksel oluşmasını sağlamakta ve bu durum nesne sınırlarının doğru bir biçimde belirlenmesini zorlaştırmaktadır. Çok büyük k değerleri için ise nesne sınırlarını çok iyi takip eden çok sayıda süper piksel oluşmakta fakat işlem yükünü artırmaktadır.

BDYÖ, k-ortalamalı öbekleme algoritmasının bir türüdür. Normalde k-ortalamalı öbekleme algoritması $O(k^2 \times \text{Piksel Sayısı})$ işlem yüküne sahiptir. Bu çalışmada

önerilen yaklaşım ise O (Piksel Sayısı) işlem yüküne sahiptir. BDYÖ algoritmasında hafızada sadece piksellerin öbek bilgisi ve bağlı olduğu öbeğe olan mesafe bilgisi saklanır. Başlangıç olarak tüm elemanların öbek bilgisi sıfırlanır ve mesafe bilgisi sonsuz olarak alınır. Öbek temsilcileri için S adım boyutuna sahip bir ızgara oluşturulur. Her yinelemede öbek temsilcilerinin $2S'$ lik çevresindeki elemanlar için mesafe hesaplaması yapılır ve öbek bilgileri güncellenir. Yinelemelerin sonunda öbek temsilcileri öbeklerin aritmetik ortalaması kullanılarak güncellenir. Bu işlemin, öbek temsilcilerinin yer değiştirmesi sonlanana veya yer değişimi mesafesinin belli bir eşiğin altına inene kadar devam etmesi sağlanır.

İmgedeki piksellerin BDYÖ yöntemi ile öbeklenebilmesi için renk ve konum bilgilerinden oluşan 3 boyutlu özellik uzaylarından faydalananmaktadır. Bu çalışmada kullanılan özellik uzayı gri renk uzayının (I) ve x , y düzlemsel koordinat uzayının birleşmesinden oluşur. $[I \ x \ y]$ uzayı kullanılarak hem renk benzerliği hem de piksellerin birbirine olan düzlemsel mesafesi göz önüne alınmış olur. Öbek temsilcisi ile piksellerin arasındaki mesafe, D , hesaplanırken (1) denklemi kullanılmaktadır.

$$D = \sqrt{\left(\frac{\sqrt{(I_j - I_i)^2}}{m}\right)^2 + \left(\frac{\sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}}{S}\right)^2}$$

$$d_c = \sqrt{(I_j - I_i)^2} \quad (1)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}$$

$$D = \sqrt{\left(\frac{d_c}{m}\right)^2 + \left(\frac{d_s}{S}\right)^2}$$

D mesafesi bulunurken i indisli özellikler etiketlenmek istenen piksele ve j indisli özellikler ise öbek temsilcisine aittir. m parametresi ön bilgi olarak verilen ve süper piksellerin bütünlüğünü kontrol etmeye yarayan bir parametredir. S adım boyutu ise denklem (2) yardımıyla hesaplanmaktadır. N

görüntüdeki piksel sayısını ve k ise süper piksel sayısını belirtmektedir.

$$S = \sqrt{\frac{N}{k}} \quad (2)$$

BDYÖ yönteminde süper piksellerin oluşumu iki parametre k , m ile kontrol edilmektedir. k ile istenilen süper piksel sayısı belirlenirken, m ile öbekleme işleminde ağırlığın renge mi yoksa pikseller arası mesafeye mi verileceği belirlenir. Kullanılan m değeri arttırdıkça öbeklemede piksellerin düzlemsel konumları ağırlık kazanmaya başlar ve daha derlitoplus süper pikseller elde edilir.

BDYÖ Algoritması:

$C_k = [I_k \ x_k \ y_k]$ öbek temsilcilerini S adımlı ızgara ile seç.

Öbek temsilcilerinin 3×3 'luk komşuluğundaki minimum gradyanlı pikseli bul ve temsilci olarak güncelle.

E ve d 'nin başlangıç değerlerini çok büyük (yaklaşık sonsuz) al. Yineleme sayısına ulaşana kadar veya $E < \text{esik değer olana kadar}$ sonraki adımları tekrarla.

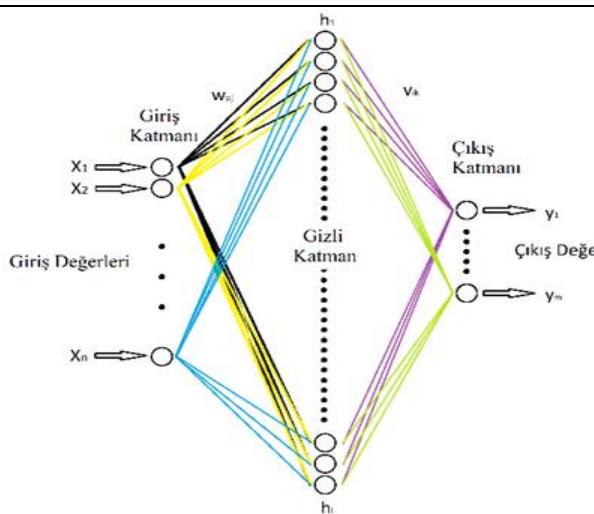
Tüm C_k 'ların $2S \times 2S$ alanı içerisinde yer alan pikseller için D 'yi hesapla ve $D < d$ ise d mesafe bilgisini D olarak al ve etiket bilgisini k olarak güncelle.

C_k öbek temsilcilerini öbeği temsil eden piksellerin düzlemsel ortalamasını alarak güncelle ve E 'yi eski ile yeni C_k arasındaki mesafe olarak güncelle.

2.2.2. Yapay Sinir Ağları

Yapay sinir ağları eğitilme algoritmalarına göre danışmanlı ve danışmansız olmak üzere iki gruba ayrılır (Enderle ve Bronzino, 2011; Rojas, 1996; Yilmaz, 2016). Eğitilme algoritmaları hakkında detaylı bilgi (Haykin, 1998)'de bulunabilir.

Bu çalışmada danışmanlı eğitilmeye sahip çok katmanlı bir yapay sinir ağı modeli kullanılmıştır. Kullanılan model bir gizli katmana sahiptir ve genel bir gösterimi Şekil 1'de verilmiştir.



Şekil 1. Bir gizli katmanlı YSA modeli.

Giriş katmanı nöronları giriş değerlerini gizli katmana aktarır. Gizli katmanda yer alan her bir nöronun çıkışı aşağıdaki biçimde hesaplanır:

$$g_p = f_{gizli\ katman}(\sum_{j=1}^n(w_{pj}x_j)) \quad (3)$$

burada, w_{pj} gizli katman ve giriş katmanı arasındaki ağırlık katsayılarıdır ve $f_{gizli\ katman}()$ ise gizli katman nöronlarında kullanılan aktivasyon fonksiyonudur. (3) ile hesaplanan gizli katman çıkışları çıkış katmanına aktarılır ve YSA'nın çıkışı aşağıdaki biçimde elde edilir:

$$y_i = f_{cikis\ katman}(\sum_{k=1}^l(v_{ik}g_k)) \quad (4)$$

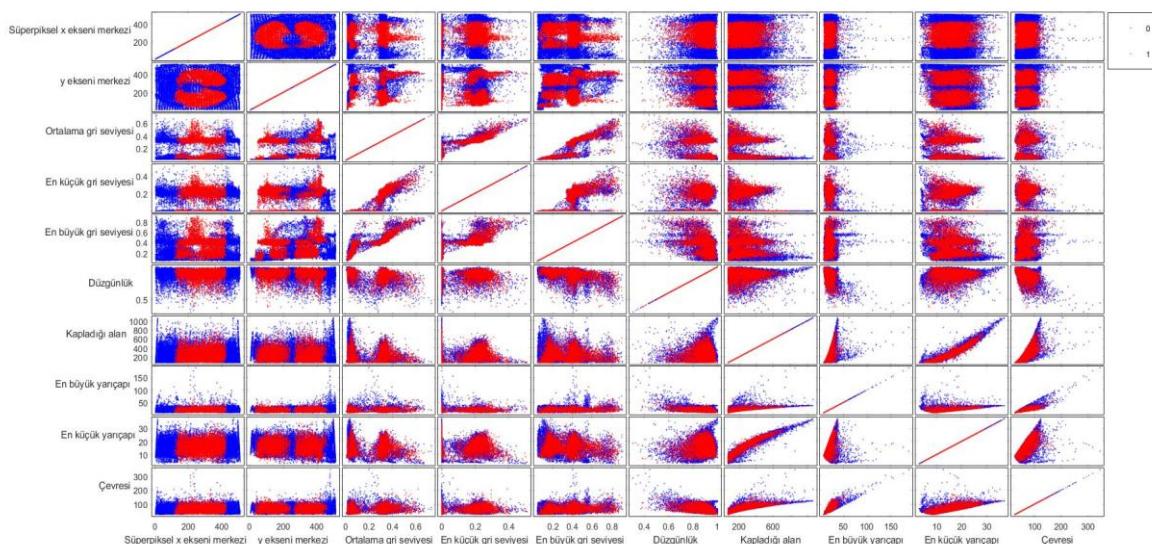
burada, v_{ik} çıkış katmanı ve gizli katman arasındaki ağırlık katsayılarını ve $f_{cikis\ katman}()$ ise çıkış katmanı nöronlarında kullanılan aktivasyon fonksiyonunu gösterir.

YSA'nın eğitimi için ölçeklenmiş eşlenik gradien algoritması kullanılmıştır, detaylı bilgi Møller, (1993)'de bulunabilir.

Önerilen yaklaşım NLST veri tabanından seçilen tıbbi görüntüler üzerinde test edilmiştir. Öncelikle, görüntüler süper piksellerere ayrılmaktadır. Daha sonra, süper piksellerden öznitelikler çıkarılmakta ve bu öznitelikler kullanılarak süper pikseller YSA ile sınıflandırılmaktadır.

Öznitelik olarak, süper piksellerin merkezi, rengi, alanı ve çevresine bağlı özellikler kullanılmıştır. Sınıflandırıcılarla yapılan ön çalışmalarında merkezin konumu, ortalama renk değeri, en küçük renk değeri ve en büyük renk değerinin belirleyici olduğu görülmüştür.

Çalışmamızda YSA ile görüntülerdeki süper pikseller sınıflandırılarak akciğer sınırlarının tespiti yapılmıştır. Kullanılan YSA modelinde giriş katmanında 10 nöron, gizli katmanda 100 nöron ve çıkış katmanında 1 nöron bulunmaktadır. Gizli katman nöronları için tanjant sigmoid aktivasyon fonksiyonu ve çıkış katmanı nöronu için ise logaritmik sigmoid aktivasyon fonksiyonu seçilmiştir

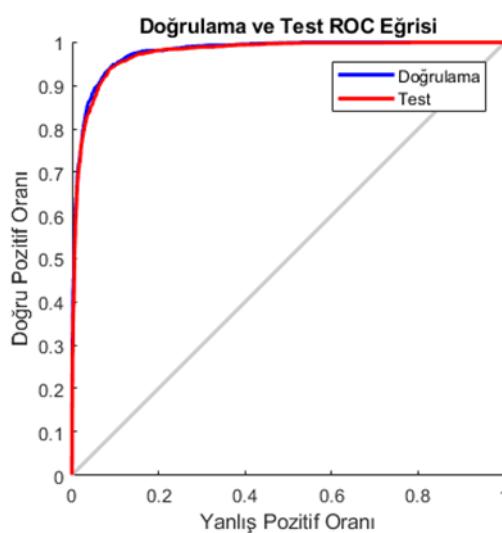


Şekil 2. Süper piksellerin özellik alt uzayları.

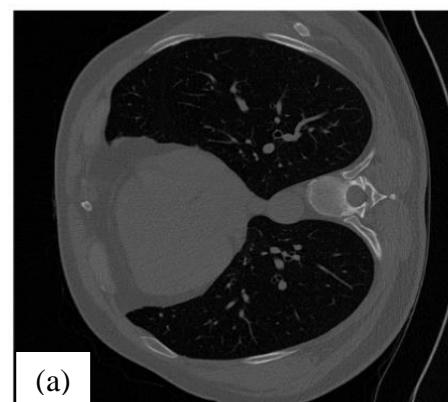
YSA'nın sınıflandırma başarımı 25 BT görüntüsü ile oluşturulan toplam 23751 süper piksel içeren veri kümesi için denenmiştir.

Veri kümesi akciğer bölgesi olup olamamasına göre 2 sınıfa ayrılmıştır. Sınıflandırma için 10 adet özellik kullanılmıştır. Bu özellikler, süper pikselin merkezi, ortalama gri seviyesi değeri, en küçük ve en büyük gri seviyesi değeri, en büyük ve en küçük yarıçapı, çevresi, kapladığı alan ve süper pikselin alanının süper pikseli içeren konveks alana oranından (düzgünlik) oluşmaktadır. Bu özelliklere ait iki boyutlu alt uzaylar Şekil 2'de verilmiştir. Başarım analizi için veri kümesi test, eğitim ve doğrulama olarak 3 parçaaya ayrılmıştır. Test ve doğrulama veri kümeleri 8313'er örnekten, eğitim veri kümesi ise 7125 örnekten oluşmaktadır.

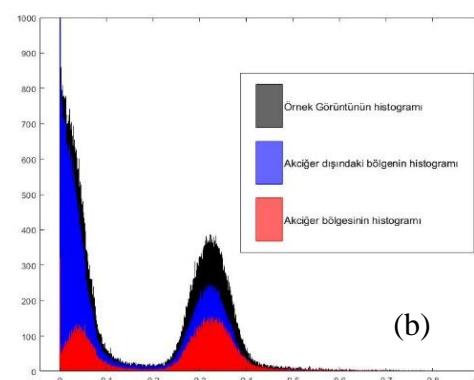
Önerilen yöntemin Alıcı İşletim Karakteristiği (ROC) eğrisi test ve doğrulama kümeleri için Şekil 3'te verilmiştir. ROC eğrisi incelendiğinde YSA'nın doğru pozitif başarısının yüksek olduğu görülmektedir.



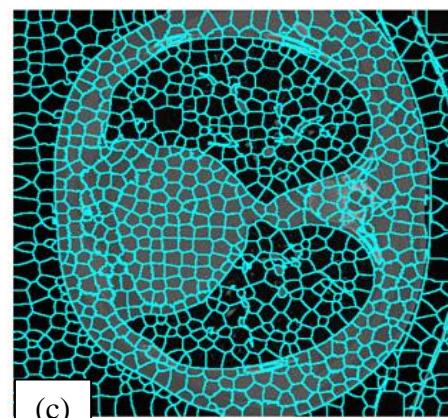
Şekil 3. Doğrulama ve test kümeleri için ROC eğrisi.



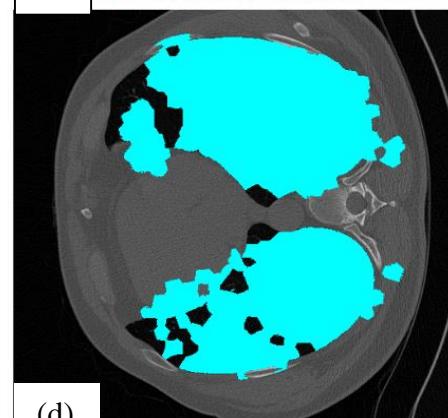
(a)



(b)



(c)



(d)

Şekil 4. (a) Örnek bir görüntü (b) [0-1] arasına normalize edilmiş histogram (c) süper piksellere ayrılmış hali (d) akciğer olarak tespit edilen bölgeler.

Bir görüntü örneğinin, histogramı, süper piksellere ayrılmış hali ve akciğer bölgesinin tespit edilmiş hali Şekil 4'te verilmiştir. Şekil incelendiğinde süper piksellerin sınırları başarılı bir biçimde takip edebildiği, homojen bir yapı oluşturduğu ve akciğerin başarılı bir şekilde tespit edildiği görülmektedir.

4. Sonuçlar ve Tartışma

Bu çalışmada BT görüntülerden akciğerlerin tespiti için süper pikseller ve YSA üzerinde temellendirilmiş bir yöntem önerilmiştir. Önerilen yöntemin başarımı NLST veri tabanında yer alan akciğer görüntülerini üzerinde incelenmiştir. Deneyler sonucunda önerilen yöntemin %92,66 sınıflandırma doğruluğuna sahip olduğu görülmüştür. Ayrıca, hata matrisi aracılığıyla sınıflandırma başarımının detayı sunulmuştur.

Elde edilen sonuçlar ışığında önerilen yöntemin BT görüntülerinde ilgilenilen bölgelerin tespitinde kullanılabileceği sonucuna varılmıştır.

Gelecek çalışmalar kapsamında başarımın artırılması ve üç boyutlu hacimsel görüntülerin elde edilmesi planlanmaktadır.

Teşekkür

Bu çalışma Uludağ Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından KUAP(M)-2013/52 nolu proje kapsamında desteklenmiştir.

"The authors thank the National Cancer Institute for access to NCI's data collected by the National Lung Screening Trial. The statements contained herein are solely those of the authors and do not represent or imply concurrence or endorsement by NCI."

5. Kaynaklar

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Susstrunk, S. 2010. SLIC Superpixels. EPFL Technical Report 149300, (June), 15.
- Chu, J., Min, H., Liu, L., Lu, W. 2015. A novel computer aided breast mass detection scheme based on morphological enhancement and SLIC superpixel segmentation. *Medical Physics*, 42(7), 3859–69.
- Enderle, J.D., Bronzino, J.D. 2011. *Introduction to Biomedical Engineering*. (3rd. ed.). Academic Press.
- Fan, X., Zhang, G., Xia, X. 2008. Performance Evaluation of SVM in Image Segmentation. In 2008 IEEE International Workshop on Semantic Computing and Applications (160–165). IEEE.
- Faust, O., Acharya, U.R., Tamura, T. 2012. Formal design methods for reliable computer-aided diagnosis: A review. *IEEE Reviews in Biomedical Engineering*, 5, 15–28.
- Haas, S., Donner, R., Burner, A., Holzer, M., Langs, G. 2012. Superpixel-Based Interest Points for Effective Bags of Visual Words Medical Image Retrieval (58–68). Springer, Berlin, Heidelberg.
- Haykin, S. 1998. *Neural Networks: A Comprehensive Foundation* (2nd ed.). New Jersey: Prentice Hall.
- Lê, M., Unkelbach, J., Ayache, N., Delingette, H. 2016. Sampling image segmentations for uncertainty quantification. *Medical Image Analysis*, 34, 42–51.
- Liao, X., Zhao, J., Jiao, C., Lei, L., Qiang, Y., Cui, Q. 2016. A segmentation method for lung parenchyma image sequences based on superpixels and a self-generating neural forest. *PLoS ONE*, 11(8).
- Møller, M.F. 1993. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning Supervised Learning. *Neural Networks*, 6(November), 525–533.
- Rojas, R. 1996. Neural networks: a systematic introduction. *Neural Networks*, 502.
- Wang, X.Y., Wang, T., Bu, J. 2011. Color image segmentation using pixel wise support vector machine classification. *Pattern Recognition*, 44(4), 777–787.
- Wang, X., Peng, Ma, Zhao J. 2016. Brain tumor CT image segmentation based on SLIC0 superpixels. In 2016 9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-

- BMEI) (427–431). IEEE.
- Xu, J., Ishikawa, H., Wollstein, G., Schuman, J.S. 2011. 3D optical coherence tomography super pixel with machine classifier analysis for glaucoma detection. In 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (3395–3398). IEEE.
- Yang, H.Y., Zhang, X.J., Wang, X.Y. 2014. LS-SVM-based image segmentation using pixel color-texture descriptors.
- Yilmaz, E. 2016. Fetal State Assessment from Cardiotocogram Data Using Artificial Neural Networks. *Journal of Medical and Biological Engineering*, 36(6), 820–832.
- Zhang, W., Zhang X., Zhao J., Qiang Y., Tian Q., Tang X. 2017. A segmentation method for lung nodule image sequences based on superpixels and density-based spatial clustering of applications with noise. *PLoS ONE*, 12(9).
- Zhou, S.K. 2016. Medical Image Recognition, Segmentation and Parsing. *Medical Image Recognition, Segmentation and Parsing*. USA: Academic Press.