

Bagging-Karar Ağacı Sınıflandırıcıları ile Pulmoner Nodüllerin Malign-Benign Sınıflandırması

Malignant-Benign Classification of Pulmonary Nodules by Bagging-Decision Trees

Ahmet Tartar¹, Aydin AKAN²

¹ Biyomedikal Mühendisliği Anabilim Dalı

² Elektrik-Elektronik Mühendisliği Bölümü

İstanbul Üniversitesi

atartar34@gmail.com, akan@istanbul.edu.tr

Özetçe

Günümüzde birçok klinik uygulamada, Bilgisayar Destekli Teşhis (BDT) sistemlerinin kullanımına büyük gereksinim duyulmaktadır. Bu çalışmada, pulmoner nodüllerin malign benign sınıflandırması için yeni bir Bilgisayar Destekli Teşhis (BDT) sistemi önerilmiştir. Çalışmada bagging destekli karar ağacı sınıflandırıcıları kullanılmıştır. Malign ve benign huylu nodüllerin sınıflandırması için önerilen sistemde, % 86.8 sınıflandırma doğruluğu olmak üzere benign sınıf için % 94.7 duyarlılık ve 0.950 AUROC; malign sınıf için % 80.0 duyarlılık ve 0.888 AUROC; takibi gereken belirsiz sınıf için % 77.8 duyarlılık ve 0.935 AUROC olarak performans değerleri hesaplanmıştır.

Anahtar Kelimeler — Bilgisayar destekli teşhis sistemi; Malign-benign ayrımı; yapay zeka uygulaması.

Abstract

Today, computer-aided detection systems have been highly needed in many clinical applications. In this study, a new Computer-aided Diagnosis system (CAD) was proposed for classifying pulmonary nodules as malignant and benign. The classifiers of the Bagging-decision trees were utilized. On the classifying of malignant and benign nodule patterns, classification performance values are calculated as 94.7 % sensitivity and 0.950 AUROC for benign class; 80.0 % sensitivity and 0.888 AUROC for malignant class; 77.8 % sensitivity and 0.935 AUROC for uncertain class by 86.8 % accuracy of the classifier.

Keywords — Computer-aided diagnosis system; Malignant-Benign classification; artificial intelligence application.

1. Giriş

Tüm dünyada olduğu gibi ülkemizde de akciğer kanseri kanser ölümlerinin başlıca nedenleri arasında sayılmaktadır [1, 2]. Bilhassa Amerika, Japonya gibi gelişmiş endüstriyel ülkelerde son yıllarda akciğer kanseri vakaları hızlı bir şekilde artış göstermekte ve bu konular üzerine yapılan araştırmaların desteklenmesi bir hükümet politikası haline geldiği görülmektedir [3]. Ancak şimdiye kadar yapılan çalışmalar dikkate alındığında henüz kanser vakalarının erken teşhisine yönelik istenilen seviyeye gelinmemiştir. Bu açıdan kanserin erken teşhisinde önemli katkı sağlayacak, olası hekim hatalarını minimize edecek

olan ve hastalıklarının teşhis ve tedavisinde hekimlere yardımcı olacak sistemlerin geliştirilmesi son derece önemlidir.

Pulmoner nodüllerin erken teşhisi, şüphesiz akciğer kanserinde hastanın hayatta kalma şansını artırmaktadır. Günümüzde bilgisayar tomografi (BT), manyetik rezonans ve pozitron emisyon tomografi gibi gelişmiş görüntüleme sistemleri ile hastalığın erken teşhisi sağlanabilmektedir. Özellikle bilgisayar tomografi ile küçük boyuta sahip pulmoner nodüllerin akciğer grafilerinde görüntülenmesi erken teşhise önemli katkı sağlamaktadır. Ancak bu gelişmiş sistemler, birçok karmaşıklıkla beraberinde getirmektedir. Her hasta için yüzlerce kesite sahip olan BT görüntülerinin hekimler tarafından incelenmesi, uzun ve yorucu bir süreçtir. Hatta bir uzman hekimin aynı hastaya yaptığı değerlendirme ile başka bir uzman hekimin değerlendirmesi arasında farklılıklar görülebilmektedir. Bu açıdan teşhis ve tedavide hızlı karar veren sistemlerin geliştirilmesi ve insan hatasının teşhisteki rolünü azaltmak için bilgisayar destekli tespit ve teşhis sistemlerinin geliştirilmesi son derece önemlidir. Bu açıdan bilgisayar destekli tespit/teşhis (BDT) sistemleri, hastalığın teşhisine ait karar verme sürecinde hekime ikinci bir gözden geçirme olanağı sunmaktadır [4].

Literatürdeki çalışmalarda sıklıkla, pulmoner nodüllerin bilgisayar destekli tespitine yönelik olarak nodül ve nodül olmayan örüntülerin tespiti üzerine olduğu görülmektedir [5]. Literatürde pulmoner nodülleri sınıflandırmak için yapay sinir ağı yaklaşımları [6], Fisher Lineer Ayırıştırma [7], rastgele orman (random forest) karar ağacı sınıflandırıcıları [8], tek yapılı destek vektör makineleri (DVM) ve topluluk öğrenme algoritmaları (bagging, adaboost gibi) [9] kullanılmıştır.

Pulmoner nodül örüntülerinin teşhis açısından malign-benign huylu olduklarının tespitine yönelik bu çalışma, Literatürde bir ilk ve yeni bir çalışma sahası açması noktasında oldukça önemlidir.

2. Malzeme ve Yöntem

2.1 Veri Seti ve Görüntüleme Protokolü

Bu seviyede verilerin elde edilmesi oldukça zor bir işlemi beraberinde getirmektedir. Pulmoner nodüllerin malign-benign ayrımı, uzman radyologlar tarafından hastalığın uzun bir takibi neticesinde patoloji ve radyoloji raporları neticesinde yapılabilmektedir. Bu çalışmada akciğer kanseri teşhisi konan 35 farklı hastanın BT görüntüleri kullanılmıştır. Bununla beraber, kullanılan veri seti ile alakalı istatistik bilgiler burada

Tıbbi Görüntüleme 4


2. Gün / 16 Ekim 2015, Cuma

sunulmaktadır. Veri setinde kullanılan hastaların teşhis seviyesinde göre cinsiyet ve örüntü dağılımları Tablo 1'de verilmektedir. Veri seti, yaşları 19 ile 75 arasında değişen 24 erkek ve 11 kadın hastadan olmak üzere toplam 38 pulmoner nodül örüntüsünden oluşmaktadır. Hastaların yaş ortalaması 56.2 ± 15.1 yıl olarak hesap edilmiştir. Şekil-1'de veri setinde hastalardan alınan pulmoner nodüllerin 30 tanesi sağ akciğerde (13 üst kısımda, 9 alt kısımda, 8 akciğer zarına komşu), 8 tanesi sol akciğerde (4 üst kısımda, 3 alt kısımda, 1 akciğer zarına komşu) tespit edilmiştir. Pulmoner nodüllerin malign ve benign huylu örüntü örnekleri Şekil 2'de verilmiştir.


Hastaların BT görüntüleri, İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Radyoloji Bölümü'nde 2010-2013 yılları arasında "Sensation 16" BT tarayıcısı (Siemens Medical Systems) kullanılarak elde edilmiştir. Tüm BT taramaları, 120 kVp tüp potansiyelinde uluslararası görüntüleme protokolleri kullanılarak alınmıştır. Görüntüler 512x512 piksel boyutunda ve BT'den doğrudan DICOM (Digital Imaging and Communications in Medicine) formatlı dosya olarak kaydedilmiştir. Çalışmada malign benign ayrımı için önerilen bilgisayar destekli teşhis sistemi blok diyagramı Şekil 3'te verilmektedir.

Tablo 1: Kullanılan veri seti ve örüntü sayıları.

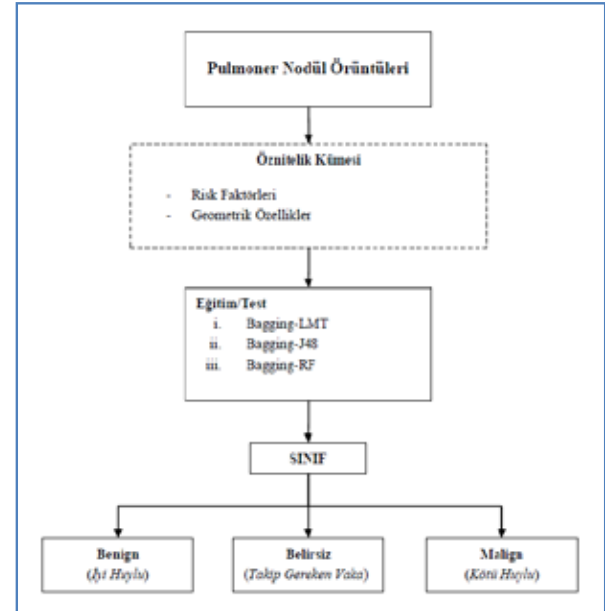
Teşhis	Örüntü Sayısı	Erkek	Kadın
Benign	19	13 Hasta 15 Örüntü	4 Hasta 4 Örüntü
Malign	10	6 Hasta 7 Örüntü	3 Hasta 3 Örüntü
Belirsiz	9	5 Hasta 5 Örüntü	4 Hasta 4 Örüntü



Şekil 1: Pulmoner nodüllerin akciğer parankimindeki dağılımı.



Şekil-2: Malign ve benign huylu tümör örüntüleri.



Şekil 3: Malign benign ayrımı için önerilen BDT sistemi blok diyagramı.

2.2 Öznitelik Çıkarma

Görüntü işleme ile örüntüler üzerinde iki boyutlu bir sınıflandırma yapılabilmesi için her bir örüntüye ait özniteliklerin elde edilmesi gerekmektedir. Çalışmada veri setinde kullanılan iki boyutlu örüntüler için morfolojik özellikler kullanılarak öznitelik değerleri hesap edilmiştir. Sınıflandırma başarımını artırmak için, hastalara ait yaş, cinsiyet gibi demografik bilgilerin yanı sıra görüntüden elde edilen nodül çap, kontrast ve lokalizasyon bilgilerini de içine alan risk faktörleri tanımlanarak her bir örüntü için bir öznitelik vektörü oluşturulmuştur. Kullanılan öznitelikler Tablo 2'de tablo halinde verilmiştir.

Tablo-2'de, bir örüntüye ait P , çevre; A , alan; L , en büyük çap uzunluk değerlerini tanımlamaktadır.

Tıbbi Görüntüleme 4

2. Gün / 16 Ekim 2015, Cuma

Tablo 2: Malign-Benign sınıflandırması için oluşturulan öznelik kümesi.

Sıra	Nicelik	Öznelik	Tanım
1	Risk Faktörleri	Yaş	-
2		Cinsiyet	-
3		Nodül Lokalizasyonu	-
4		Kontrast	-
5		Nodül Çapı	-
6	Morfolojik Özellikler	Eksantriklik	-
7		Kompaktlık	$P^2/4\pi A$
8		Yuvarlaklık	$4A/\pi L^2$
9		Dairesellik	$4\pi A/P^2$
10		Elipsite	$\pi L^2/2A$

2.3 Bagging

Bagging oldukça küçük değişime sahip küçük veri setleri için kullanılan kararsız öğrenme algoritmalarıdır. Sınıflandırıcılarda performansı artırmak için kullanılan Bagging algoritması, Breiman tarafından önerilmiştir [10]. Tek bir sınıflandırıcı daha yüksek test hatasına sahip olabilmektedir. Sınıflandırıcıların çeşitliliği, genellikle tek bir sınıflandırıcının hatalarını telafi ettiğinden dolayı, sınıflandırıcıların kombinasyonu ile daha az test hatası elde edilmektedir [11]. Bu açıdan eğitim veri setindeki küçük değişimlerde bir öğrenme algoritması kombinasyonu, görel bir şekilde sınıflandırıcının doğruluğunda büyük değişimler oluşturmaktadır.

2.3 Karar Ağaçları (Decision Trees)

Lojistik Model Ağacı (LMT): Sınıflandırıcı, ağaç induksiyonu ve lojistik regresyon sinir ağlarının bir kombinasyonu olarak tanımlanmaktadır. LMT, düşük tahmin sınıf ve denetimli numerik öğrenme işlemlerinde kullanılan popüler tekniklerden biridir. LMT algoritması, ikili ve çok-sınıflı değişkenleri, numerik/zayıf büyüklükleri ve kayıp değerleri işleme dahil edebilmektedir [12]. LMT ağaç boyutu, eğitim/test aşamasında 1 olarak alınmıştır.

J48: J48, C4.5 karar ağacı öğreticisinin bir uygulamasıdır. Bir karar ağacı, her iç düğümün olduğu ağaç gibi bir akış şemasını göstermektedir. Dal ve yaprak düğümleri, sırasıyla, test ve sınıfların büyüklüklerini ve sonucunu göstermektedir. Bir bilinmeyen örüntüyü sınıflandırmak için, örüntünün öznelik değerleri, karar ağaçlarına karşı test edilmektedir. Sınıflandırma işlemi, tüm olası bölünmeler gerçekleştirilene kadar devam edilmektedir [13]. J48 ağaç boyutu, eğitim/test aşamasında 3 olarak alınmıştır.

Rastgele Orman (RF): Rastgele orman sınıflandırıcısı, 1999 yılında Leo Breiman tarafından önerilmiştir [14]. Rastgele orman sınıflandırıcısı, makine öğrenme sistemlerinde en önemli algoritmalarından biri olan ağaç tabanlı sınıflandırıcılarda yeni bir gelişme olarak görülmektedir. Ormandaki tüm ağaçlar için aynı

dağılımlı ve bağımsız örneklenen rastgele değişkenlere dayalı olan ağaç belirleyicilerinin bir kombinasyonu olarak tanımlanmaktadır. Rastgele orman, standart veri setlerinde sınıflandırıcıların sağlam ve iyileştirilmiş sonuçlar vermesine katkı sağlamaktadır. Farklı sınıflandırma problemlerinde yapay sinir ağları ve topluluk sınıflandırıcı teknikleri ile karşılaştırıldığında oldukça verimli performans göstermektedir. RF, çok sayıdaki ağaçları büyütme için rastgele bölme ve Bagging metodlarını kullanan topluluk sınıflandırıcıların özel bir türü ile ilişkilidir [14,15]. RF sınıflandırıcısının, sınıflandırmada hangi özneliklerin önemli olduğunu tahmin etmesi ve kayıp verilerin etkili bir şekilde tahmin edilmesi gibi avantajları bulunmaktadır. Eğitim ve test aşamasında ağaç sayısı 10 olarak alınmıştır.

Sınıflandırma işlemleri, Weka veri madenciliği yazılımı (<http://www.cs.waikato.ac.nz/~ml/weka>) kullanılarak gerçekleştirilmiştir.

3. Sonuçlar

Teşhis ve tedavide kullanılan tıbbi görüntülerin sınıflandırılmasında farklı yöntemler kullanılmaktadır. Literatürde sıklıkla, pulmoner nodüllerin tespitine yönelik BDT sistemlerinin geliştirilmesi üzerine birçok çalışma bulunmaktadır [15, 16, 17].

Pulmoner nodüllerin malign ve benign huylu olarak sınıflandırılmasına olanak sağlayan bu çalışma, literatürde *ilklerden* olma özelliğine sahiptir. Bu açıdan söz konusu sınıflandırma probleminin çözümü tıbbi anlamda kayda değer bir nitelik taşımaktadır. Çalışmada, sınıflandırma probleminin çözümünde literatüre ek olarak malign, benign sınıfların yanı sıra hastanın teşhisinin yapılabilmesi için hastalığın takibinin gerektiği *belirsiz* adlı bir sınıf tanımlanmıştır. Belirsiz vakalar, tıbbi anlamda hekimler açısından karar verme aşamasında önemli bir yere sahiptir. Uzun teşhis, gözlem ve rutin tedaviler neticesinde hekimler, tümör hakkında ayrıntılı bir bilgiye ulaşabilmektedir.

Veri setindeki iki boyutlu pulmoner nodül örüntüleri için tanımlanan öznelikler kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma işleminde topluluk sınıflandırıcısı olan Bagging algoritması ile desteklenerek karar ağacı sınıflandırıcıları (LMT, J48, RF) kullanılmıştır. Sınıflandırıcılara ait elde edilen performans sonuçları Tablo 3'de verilmektedir. Tabloda sınıflandırıcıların hata matrisleri, duyarlılık, doğruluk, AUROC ve Kappa istatistiği değerleri verilmektedir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (1)$$

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (2)$$

Burada DP , DN , YP ve YN , sırasıyla, doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif olarak sınıflandırılan örüntü sayılarını göstermektedir. AUROC alıcı çalışma karakteristik eğrisi altındaki alanı göstermektedir. Kappa istatistiği, sınıflandırıcı ve doğru sınıflar arasındaki uyumu göstermektedir.

Sınıflandırıcı algoritmasında 10-katlı çapraz doğrulama kullanılarak performans değerleri elde edilmiştir. Çalışmada nodül örüntülerini sınıflandırmak için Bagging-LMT, Bagging-J48 ve Bagging-RF sınıflandırıcılarının performans ölçümleri elde edilmiştir.

Tablo-3'teki başarımlarını dikkate alındığında pulmoner nodüllerin malign-benign ayrımında topluluk öğrenme algoritması destekli karar ağacı sınıflandırıcıları, yüksek başarımlarını göstermektedir.

Tıbbi Görüntüleme 4

2. Gün / 16 Ekim 2015, Cuma

göstermektedirler. Sınıflandırıcıların doğruluk değerleri ve kapa istatistiği değerleri dikkate alındığında en yüksek başarımlar, Bagging-RF sınıflandırıcısında görülmektedir. Bagging-RF sınıflandırıcısı % 86.8 doğruluk değeri olmak üzere benign sınıf için % 94.7 duyarlılık ve 0.950 AUROC, malign sınıf için % 80.0 duyarlılık ve 0.888 AUROC ve belirsiz sınıf için % 77.8 duyarlılık ve 0.935 AUROC değerleri elde edilmiştir.

Tablo 3: Sınıflandırıcılara göre elde edilen performans değerleri.

	Gerçek Durum	Kestirilen Durum		
		Benign	Malign	Belirsiz
Bagging-LMT	Benign	17	1	1
	Malign	0	6	4
	Belirsiz	0	3	6
	Duyarlılık	89.5 %	60.0 %	66.7 %
	AUROC	0.978	0.825	0.847
	Kappa	0.629		
	Doğruluk	76.3 %		
Bagging-J48	Benign	19	0	0
	Malign	1	1	8
	Belirsiz	0	3	6
	Duyarlılık	100 %	10.0 %	66.7 %
	AUROC	0.974	0.809	0.843
	Kappa	0.492		
	Doğruluk	68.4 %		
Bagging-RF	Benign	18	1	0
	Malign	0	8	2
	Belirsiz	0	2	7
	Duyarlılık	94.7 %	80.0 %	77.8 %
	AUROC	0.950	0.888	0.935
	Kappa	0.791		
	Doğruluk	86.8 %		

Tıbbi teşhis ve tedavide özellikle malign huylu tümörlerin elde edilmesi, benign huylu örüntülerin tespitinden klinik olarak daha ehemmiyet arz etmektedir. Bu açıdan, çalışmada elde edilen

sonuçların teşhis ve tedavide yardımcı olacak nitelikte olması son derece önemlidir.

4. Kaynakça

- [1] Cancer Facts And Figures, "American Cancer Society", Atlanta, 2010.
- [2] Sağlık İstatistikleri Yılığ, Türkiye Cumhuriyeti Sağlık Bakanlığı, Ankara, 2013.
- [3] Kaizoe, T., "Figures on Cancer in Japan, Foundation for Promotion of Cancer Research", 1995.
- [4] Doi K., "Computer-aided diagnosis in medical imaging: historical review, current status and future potential", *Computerized Medical Imaging and Graphics*, 31(4-5):198-211, 2007.
- [5] Marten K., Engelke C., Seyfarth T., Grillhösl A., Obenauer S., "Computer aided detection of pulmonary nodules: Influence of nodule characteristics on detection performance", *Clinical Radiology*, 60, 196-206, 2005.
- [6] Retico, A., Delogu, P., Fantacci, M.E., Gori, I., Martinez, A.P., "Lung nodule detection in low-dose and thin-slice computed tomography", *Computers in Biology and Medicine*, 38, 525-534, 2008.
- [7] Messay T., Hardie R.C., Rogers S.K., "A new computationally efficient CAD system for pulmonary nodule detection in CT imagery", *Medical Image Analysis*, 14:390-406, 2010.
- [8] Lee S.L.A., Kouzani A.Z., Hu E.J., "Random forest based lung nodule classification aided by clustering", *Computerized Medical Imaging and Graphics*, 34, 535-542, 2010.
- [9] Tartar, A., Kılıç, N., Akan, A., "Bagging support vector machine approaches for pulmonary nodule detection", *International Conference on Control, Decision and Information Technologies*, Tunisia, 6-8 May, 2013.
- [10] Breiman, L., "Bagging predictors," *Mach. Learn.*, vol. 24, pp. 123-140, 1996.
- [11] D. Opitz and R. Mach, "Popular Ensemble Methods: An Empirical Study", *Journal of Artificial Intelligence Research*, 11,169-198, 1999.
- [12] Landwehr, N., Hall, M., Frank, E., "Logistic Model Trees", *Machine Learning*, 95(1-2), 161-205, 2005.
- [13] Quinlan, R., "C4.5: Programs for machine learning", *Morgan Kaufmann Publishers*, San Mateo, CA, 1993.
- [14] Breiman, L., "Random forests", *Technical report*, Statistics department, University of California, Berkeley, 1999.
- [15] Breiman, L., "Random forests", *Machine Learning*, 45, 5-32, 2001.
- [16] Tartar A., Kılıç N., Akan A., "A new method for pulmonary nodule detection using decision tress", *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC13)*, s.1-5, Osaka, Japan, 2013.
- [17] Tartar A., Kılıç N., Akan A., "Classification of pulmonary nodules by using hybrid features", *Computational and Mathematical Methods in Medicine*, Volume 2013, s.1-11, doi:10.1155/2013/148363, 2013.