



Ultrasonografide iyi huylu lenf düğümlerini metastazik lenf düğümlerinden doku özellikleriyle ayırt etme

Texture features in discriminating metastatic from benign lymph nodes in ultrasonography

Ömer Kayaaltı¹, Seyhan Karaçavuş², Bülent Yılmaz³, Tuğba Şengezer⁴, Seyfettin İlgan⁴, Musa Hakan Asyalı⁵

¹ Develi Hüseyin Şahin MYO
Erciyes Üniversitesi
kayaalti@erciyes.edu.tr

² Nükleer Tıp, Tıp Fakültesi
Bozok Üniversitesi
seyhankaracavus@hotmail.com

³ Elektrik-Elektronik Müh., Mühendislik Fakültesi
Abdullah Gül Üniversitesi
bulent.yilmaz@agu.edu.tr

⁴ Nükleer Tıp
Ankara Güven Hastanesi
guven@guven.com.tr

⁵ Elektrik-Elektronik Müh., Mühendislik Fakültesi
Uluslararası Antalya Üniversitesi
musahakan.asyali@antalya.edu.tr

Özetçe

Benin (iyi huylu ya da reaktif) ve metastazik (malin) lenf düğümleri arasındaki farklar Ultrasonda (USG) çeşitli tanı kriterleri bazında raporlanır. Ancak, USG üzerindeki görünüm değerlendirilmesi gözlemci etkisi dolayısıyla subjektiftir. Subjektifliği önlemek için doku analizi ve USG görüntülerin sınıflandırılması bu alanda önemli bir araç haline gelebilir. Bu çalışmada biyopsi sırasında hedef seçim için reaktif lenf düğümlerinin metastazik lenf düğümlerinin ayırımında doku analizi araçlarının (birinci dereceden istatistik, FOS, ve gri seviye eş oluşum matrisi, GLCM) kullanımının fizibilitesi değerlendirildi. 23'ünde metastazik lenf düğümleri, 14'ünde reaktif lenf düğümleri bulunan toplam 37 USG görüntüsünü kullandık. İlgili bölgelerinin (ROI) belirlenmesinde USG görüntü üzerinde elle noktalar seçildikten sonra içbükey kabuk algoritması kullanıldı. Lenf düğümünün seçilen görüntüsü üzerinden altı birinci derece istatistiksel özellik ve GLCM'den türetilen dört özellik hesaplanmıştır ve bu özellikler sınıflandırma aşamasında kullanılmıştır. Bu özellikler, k en yakın komşuluk (k-NN) sınıflandırma yaklaşımında kullanılmıştır. Sınıflandırma başarısı %97.30 olmuştur.

Abstract

Benign and malignant lymph nodes are discriminated on the basis of various diagnostic criteria in gray scale ultrasonography (USG). However, the observers induce subjectivity in the evaluation of USG. Fr overcoming the subjectivity the texture analysis and classification of images has a potential to become a feasible tool. In this study we evaluated the usability of texture analysis approaches (first order statistics, FOS, and gray-level co-occurrence matrix, GLCM) in the discrimination of metastatic lymph nodes from the reactive ones for target selection during biopsy. We employed 37 USG images 23 of which contained metastatic lymph nodes and 14 were reactive lymph nodes. In the region of interest (ROI) determination we used concave hull algorithm which combined selected points on the USG image. On the ROI of the lymph node six FOS and four GLCM features were computed and used in the classification step. These features were used in the k-nearest neighbors (k-NN) classification approach. The classification accuracy was 97.30%.

1. Giriş

Yüzeysel lenf düğümlerinin değerlendirilmesinde ultrasonografinin (USG) rolü iyi bilinmektedir. [1, 2]. Bu yöntem, diğer görüntüleme yöntemlerine göre daha az maliyetli, kullanımı kolay, yaygın olarak mevcuttur ve iyonlaşmayan radyasyon yararına sahiptir. Doğru lenf düğümü tanımlama, kanser, lenfoma, ya da iltihaplı düğümlerin

Tıbbi Görüntüleme 1


2. Gün 26 Eylül 2014 Cuma (09.00-10.00)

tanısının ötesinde prognoz tahmini, tedaviyi seçme ve izleme dahil birçok klinik durum için önemlidir [3-6]. Bu düğüm içyapısı da dahil olmak üzere düğümlerin ayrıntılı değerlendirilmesine izin verir. Benin ve malin düğümler arasındaki farklar şekil, sınır, ekojenite, kalsifikasyon, nekroz veya damarlanma (vaskülerizasyon) deseni gibi çeşitli tanı kıstasları temelinde raporlanmaktadır. Ancak, USG üzerindeki görünüm değerlendirilmesi gözlemci etkisi dolayısıyla subjektiftir.

Günümüzde, çeşitli tıbbi görüntülerin doku analizi ve sınıflandırılması, tüm dünyada önemli bir araştırma konusu haline gelmiştir. Birçok araştırmacı, karaciğer [7], göğüs [8], karotid plak [9] ve yumurtalık kitleleri [10] gibi çeşitli organlarda kanserin ya da diğer hastalıkların teşhisi için görüntülerin doku analizini kullanmaktadır. Ultrasonografik doku analizi histopatolojik bileşenleri ve bunların metastazik ve yaygın benin lenf düğümlerindeki farklılıklarını yansıtabilir. Bu yaklaşım çoklu lenf düğümü biyopsisi hedef seçimi için metastazik ve benin lenf düğümü lezyonlarının ayırımında yararlı olabilir.

2. Materyal ve Yöntem

Bu retrospektif çalışmada tiroid kanserli otuz hasta incelendi. 23 metastazik geri kalan reaktif (enflamasyon nedeniyle büyümüş) olmak üzere toplam 37 lenf düğümü çalışıldı. Reaktif lenf düğümlerini metastazik lenf düğümleri ayırmak için altın standart olarak USG altında ince iğne aspirasyon biyopsisi ve tiroglobulin yıkama yapılır. Çalışma grubumuzdaki klinik araştırmacılar, Ankara Güven Hastanesi Nükleer Tıp bölümünde 13 MHz prob kullanarak görüntüleri aldılar. USG filminden hedef lenf düğümlerini içeren görüntüler seçildi. Seçilen bu görüntüyü işlemek için MATLAB (MathWorks MA, ABD) ortamında bir program geliştirildi.



Şekil 1: Çalışmada kullanılan işlem adımlarının özeti.

İlk adım olarak alınan görüntüden ilgi alanı (region of interest, ROI) seçildi. Lenf düğümlerinin sınırlarından birkaç nokta elle seçildikten sonra içbükey kabuk (concave hull) algoritması [11] kullanıldı. Seçilen noktaların oluşturduğu sınır içindeki noktalar alınarak, ROI seçiminde yarı otomatik bir yaklaşım kullanıldı. İçbükey kabuk yöntemi düzlem üzerinde nokta kümesinin sınırlarını hesaplamak için kullanılan bir yöntemdir. ROI belirlendikten sonra, 2 farklı doku (texture) analizi yöntemi kullanarak 10 özellik çıkarıldı. Bu yaklaşımlar birinci dereceden istatistik (first order statistics, FOS) ve gri seviye eş oluşum matrisi (gray level co-occurrence matrix, GLCM) yaklaşımlarıdır [12, 13]. FOS doku özellikleri ROI'deki piksel değerleri kullanılarak hesaplandı. Bu yaklaşım piksel değerlerinin komşuluklarını hesaba katmaz. Piksel yoğunluk değerlerini kullanarak

ortalama, standart sapma, yatıklık, sivrilik, enerji ve entropi [12] parametreleri/özellikleri hesaplandı.

Kullanılan ikinci özellik çıkarımı yaklaşımı gri seviye eş oluşum matrisidir (GLCM). GLCM görüntü üzerinde komşu pikseller arasındaki ilişkiyi açıklar ve piksel çiftlerinin sabit bir mesafe ve yöndeki parlaklık düzeylerinin oluşum sayısını gösterir. Bu aşamada daha etkili doku analizi için lenf düğümü içeren ROI'lerde ölçkleme işlemi yapılmıştır. Ölçeklemeyle görüntü geniş yoğunluk değerleri 1 ile 32 arasındaki yoğunluk seviyelerine lineer olarak indirgenmiştir. Bu yaklaşım ROI piksel komşulukları arasındaki ilişkinin tanımlanması için kullanılmıştır. Ölçekleme işleminden sonra doku analizi yapılmıştır. Bu aşamada 1 mesafesinde 0, 45, 90 ve 135 açılı için gri seviye eş oluşum matrisleri hesaplanmıştır. Ardından GLCM matrisleri normalize edilerek, eş oluşumların olasılıkları, $p(i,j)$, bulunmuştur. Bu olasılıklardan kontrast, enerji, korelasyon ve homojenite gibi doku özellikleri çıkarılır. Bu özelliklerin formülleri referans [13]'te verilmiştir.

İstatistiksel analiz SPSS 18.0 programı kullanılarak yapılmıştır. Benin ve malin lenf düğümü grupları arasındaki farklar normal dağılımlı parametreler için Student's t-testi, normal olmayan dağılımlar için Mann-Whitney U testi ile değerlendirildi. İstatistiksel anlamlılık düzeyi $p < 0,05$ olarak atandı.

Her ROI'den 10 özellik elde edildikten sonra benin lenf düğümlerinden metastazik lenf düğümleri ayırt etmek için 5 kat çapraz doğrulama ile k en yakın komşuluk [14] ($k=3$) sınıflandırma yaklaşımı kullanılmıştır.

3. Sonuçlar ve Tartışma

Öncelikle, metastazik ROI'den elde edilen her bir doku özelliği değeri, benin düğümlerden elde edilen doku özellikleriyle istatistiksel olarak karşılaştırıldı. Tablo 1'de bu karşılaştırmaların sonuçları gösterilmektedir. Bu gruplar arasında GLCM'den elde edilen kontrast, homojenite ve korelasyon ve FOS kullanılarak elde edilen ortalama, entropi ve enerji özelliklerinde önemli ölçüde farklılık olduğu ($p < 0,05$) tespit edildi.

Çalışmanın ikinci aşamasında elde edilen her bir özellik sınıflandırıcıya girdi olarak verilerek sınıflandırma başarıları elde edilmiştir. Sınıflandırma başarıları 59.46 ve % 97.30% arasında elde edilmiştir. Tablo 2 her bir özellik için, elde edilen doğru sınıflandırma yüzdesini göstermektedir. Soldan sağa ilk dört özellik GLCM, sonraki 6 özellik FOS kullanılarak elde edilen özelliklerdir.

Bu çalışmada multidisipliner bir ekip olarak, metastazik ve benin lenf düğümlerinin ayırımında yararlı olacak bir veya daha fazla doku özelliği bulmayı amaçladık. Yapılan analizlerde 37 USG görüntüsü kullanıldı. İki gruptan gelen özelliklerin ikili istatistiksel karşılaştırmaları 10 özellikten 6'sının önemli ölçüde farklı olduğunu gösterdi. Çalışmanın sınıflandırma aşamasında, özellikle iki özellik, GLCM yaklaşımdan elde edilen kontrast ve enerji, çok iyi performans sergiledi.

Chen ve ark. [15] yapmış olduğu kapsamlı bir çalışmada USG kullanılarak metastazik ve benin lenf düğümlerini ayırmak için doku analizi yaklaşımı olarak GLCM ve NGLDM (komşu gri seviye bağımlılık matrisi, neighborhood gray level dependence matrix) ve sınıflandırma yöntemi olarak destek vektör makineleri (DVM) kullandılar. Çalışmalarında GLCM ve NGLDM'den hesaplanan entropiyi en iyi özellik olarak buldular.



Tıbbi Görüntüleme 1

2. Gün 26 Eylül 2014 Cuma (09.00-10.00)

Bu çalışma USG görüntülerinden elde edilen doku özelliklerinin sübjektif görüntü yorumlamadan daha yararlı

olabileceğini ve biyopsi hedef seçimi için metastazik ve benin lenf düğümlerini ayırmada kullanılabilirliğini göstermiştir.

Tablo 1: Sınama istatistiğinin özeti

	Kontrast	Homojenite	Enerji	Korelasyon	Ortalama	Standart Sapma	Yatıklık	Sivrilik	Enerji	Entropi
Mann-Whitney U	9.0	21.0	143.0	62.0	68.0	152.0	113.0	130.0	35.0	34.0
Wilcoxon W	285.0	126.0	419.0	167.0	173.0	257.0	389.0	406.0	140.0	139.0
Z	-4.760	-4.384	-5.564	-3.100	-2.912	-0.282	-1.503	-0.971	-3.946	-3.977
Asimp. Sig. (2-kuyruklu)	0.000	0.000	0.573	0.002	0.004	0.778	0.133	0.332	0.000	0.000
Tam Sig. [2*(1-kuyruklu Sig.)]	0.00a	0.00a	0.58a	0.001a	0.003a	0.793a	0.138a	0.344a	0.00a	0.00a

Tablo 2: Doku özelliklerinin sınıflandırma başarıları (%)

Kontrast	Enerji	Korelasyon	Homojenite	Ortalama	Standart Sapma	Yatıklık	Sivrilik	Enerji	Entropi
97.30	89.20	83.80	83.80	78.40	73.00	73.00	59.50	70.30	75.70

4. Kaynakça

- [1] Ying M. ve Ahuja A., "Sonography of neck lymph nodes. Part I: normal lymph nodes," Clin Radiol., 58: 351-358, 2003.
- [2] Ahuja A. ve Ying M., "Sonography of neck lymph nodes. Part II: abnormal lymph nodes," Clin Radiol., 58:359-366, 2003.
- [3] Vassallo P., Wernecke K., Roos N., and Peters P.E., "Differentiation of benign from malignant superficial lymphadenopathy: the role of high-resolution," US. Radiology, 183:215-220, 1992.
- [4] Van den Brekel M.W., Stel H.V., Castelijns J.A., et al. "Cervical lymph node metastasis: assessment of radiologic criteria," Radiology, 177:379-384, 1990.
- [5] Ducea S.M., Lenghel M., Botar-Jid C., Vasilescu D., ve Duma M., "Ultrasonography of superficial lymph nodes: benign vs. malignant," Med Ultrason, 4:294-306, 2012.
- [6] Ahuja A., Ying M., HO S.Y., et al. "Ultrasound of malignant cervical lymph nodes," Cancer Imaging, 8:48-56, 2008.
- [7] Gao S., Peng Y., Guo H., Liu W., Gao T., Xu Y., ve Tang X., "Texture analysis and classification of ultrasound liver images," Biomed Mater Eng., 24(1):1209-16, 2014.
- [8] Sivaramakrishna R., Powella K.A., Lieberb M.A., Chilcote W.A., ve Shekhara R., "Texture analysis of lesions in breast ultrasound images," Computerized Medical Imaging and Graphics, 26(5):303-307, 2002.
- [9] Loizou C.P., Pantziaris M., Theofilou M., Kasparis T., ve Kyriakou E., "Texture analysis in ultrasound images of carotid plaque components of asymptomatic and symptomatic subjects," Artificial Intelligence Applications and Innovations IFIP Advances in Information and Communication Technology, 412:282-291, 2013.
- [10] Faschingbauer F., Dammer U., Beckmann M.W., Kehl S., Wittenberg T., ve Münzenmayer C., "Automatic texture-based analysis in ultrasound imaging of ovarian masses," Ultraschall in Med., 34, 2013.
- [11] <http://www.concavehull.org>
- [12] Selvarajah, S. Ve Kodituwakku S.R., "Analysis and Comparison of Texture Features for Content Based Image

Retrieval," International Journal of Latest Trends in Computing, 108(2):108-113, 2011.

- [13] Haralick, R.M., Shanmugam K., and Dinstein I., "Textural Features for Image Classification," IEEE Transactions on Systems, Man, and Cybernetics, 3(6):610-621, 1973.
- [14] Yilmaz, B., Asyali M.H., Arikan E., Yetkin S., ve Ozgen F., "Sleep stage and obstructive apneic epoch classification using single-lead ECG," BioMedical Engineering Online, 9:39, 2010.
- [15] Chen, S.J., Lin C. H., Chang C.Y., Chang K.Y., Ho H.C., Hsiao S.H., Lin C.W., Tzeng J.E., Chen Y.T., ve Tsai H.M., "Characterizing the major sonographic textural difference between metastatic and common benign lymph nodes using support vector machine with histopathologic correlation," Clinical Imaging, 36:353-359.e2, 2012.