

Mamografi görüntülerinin sınıflandırılması için yeni bir özellik çıkarımı yaklaşımı
A new feature extraction approach for the classification of mammographic images

Nebi Gedik

Sağlık Bilimleri Üniversitesi Sağlık Bilimleri Enstitüsü, Üsküdar, İstanbul.
e-mail: nebi.gedik@sbu.edu.tr

Özet

Bu çalışmada mamografi görüntülerinin sınıflandırılması için çok çözünürlüklü analiz yöntemiyle elde edilen özellik verisini seçerek iyileştiren bir özellik çıkarma yöntemi sunulmaktadır. Özellik seçme işlemi sınıflar arasındaki ayrımı en çok ortaya çıkaran özelliklerin belirlenmesine dayanmaktadır. Öncelikle, görüntüler dalga atom dönüşümü kullanılarak ayrıştırılmakta ve elde edilen dalga atom katsayılarından özellik vektörü oluşturulmaktadır. Matrisin satırları görüntülere, sütunları özellik verisine karşılık gelmektedir. Yöntem, her bir sütunu ayrı ayrı ele alarak eşik değerleri yardımıyla sınıf ayrımını en üst düzeyde temsil eden sütunlar (optimum özellikler) araştırılmaktadır. Elde edilen optimum özelliklerin genelleştirilebilmesi için sınıflandırma işlemi 5-katlı çapraz doğrulama ile yeniden gerçekleştirilmektedir. Sonuçlar, önerilen yöntemle elde edilen özellik kümesinin mamografi görüntülerini sınıflandırmada yeterli kabiliyete sahip olduğunu göstermektedir.

Anahtar kelimeler: Mamogram, Sınıflandırma, Özellik çıkarımı, Özellik seçimi, Dalga atom dönüşümü, SVM.

Abstract

In this study, a feature extraction method is proposed, which is optimizes selecting the feature data obtained by the multi-resolution analysis method for the classification of mammographic images. The feature selection process is based on identifying the features that mostly uncover the distinction between classes. Firstly, images are distinguished by using wave atom transform and the feature vector is generated from the wave atom coefficients. While the rows of the matrix correspond to the images, the columns are features. The method, tackling the each column individually, explores the columns that represent the class distinction at the highest level using tresholding. For generalization of the obtained optimum features, the classification process is performed again with 5-fold cross-validation. The results show that the features obtained by the proposed method have sufficient ability to classify mammographic images.

Keywords: Mammogram, Classification, Feature extraction, Feature selection, Wave atom transform, SVM.

Giriş

Meme kanseri dünyada kadınlar arasındaki en yaygın kanser olarak güncelliğini korumaktadır. Kanser nedeniyle ölümlerin önüne geçmek için en etkin yol erken teşhis ve tanıdır. Meme kanserinin erken evrede tespiti için yaygınca kullanılan ve etkili yöntem mamografi görüntülerinin incelenmesidir [1]. Ancak bu inceleme, uzmanlar için bile, meme dokusunun sahip olduğu farklı yoğunluk türleri nedeniyle zor bir iş haline gelmektedir [2]. Yapılacak yanlış bir teşhis ya kanser olmayan bir hastaya gereksiz biyopsi yapılmasına neden olur (yanlış pozitif) ya da gözden kaçan bir anormallik nedeniyle hasta birine sağlıklı teşhisi konulabilir (yanlış negatif). Araştırmalar biyopsiye gönderilen vakaların sadece %20-30'nun kanserli olduğunu ortaya koymaktadır [3,4]. Öte yandan yine araştırmalar, kanser vakalarının %10-30'nun tespit edilemediğini göstermektedir [5]. Bu olumsuzlukların önüne geçmek ve radyologlara yardımcı olmak amacıyla otomatik sistemlerin geliştirilmesine ihtiyaç vardır [6]. Bu otomatik sistemlere Bilgisayar Destekli Teşhis (BDT) sistemi adı verilmektedir [7]. Bir BDT sisteminde temel aşamalardan biri özellik çıkarımı ve seçimidir. Çünkü doğrudan sınıflandırma sonucuna etki etmektedir. Sistemler, anormallikleri tespit etmek için özellik çıkarır ve daha sonra bu özellikleri kullanarak anormallikleri iyi huylu- kötü huylu olarak ayırır. İyi huylu- kötü huylu ayrımı araştırmacılar için hala üzerinde çalışılması gereken bir problemdir[8]. Otomatik sistem çalışmalarında özellik çıkarımı için farklı yaklaşımlar bulunmaktadır [9, 10, 11]. Özellik verisi doğrudan uzaysal veriden elde edilebileceği gibi dönüşüm algoritmaları kullanılarak farklı bir alandan da elde edilebilir [12,13].

Gedik [14] mamografi görüntülerinin sınıflandırılması için shearlet dönüşümü tabanlı bir özellik çıkarımı yöntemi sunmaktadır. Yöntem mamografi görüntülerinin hızlı kesikli shearlet dönüşümü ile ayrıştırılmasıyla başlar ve elde edilen dönüşüm katsayıları kullanılarak özellik vektörü oluşturulur. Elde edilen özelliklerden en etkin olanlarının belirlenmesi için dinamik eşikleme ve t-test istatistiği kullanılmaktadır. Amaç mümkün olan en az sayıda özelliklerle en yüksek sınıflandırma başarısına sahip (optimum) eşik değerini ve karşılık gelen özellik verisini belirlemektir. Optimum değer elde edilince sonucun genelleştirilebilmesi için, optimum özellik verisiyle sınıflandırma işlemi, 5-kat çapraz doğrulama kullanılarak yeniden gerçekleştirilmektedir. Eltoukhy ve arkadaşları [15] mamografi görüntülerinin sınıflandırılmasında dalgacık ve eğricik dönüşümlerini karşılaştırmalı olarak kullanmaktadır. Yöntemde, dalgacık ve eğricik dönüşümleri görüntülere uygulanmakta ve elde edilen katsayılar kullanılarak özellik matrisi oluşturulmaktadır. Elde edilen özellikler t-test istatistiği kullanılarak, sınıfları birbirinden ayırt etme yeteneğine göre sıralanarak, sınıflandırmada en yüksek performansa sahip özellik verisi aranmaktadır. **Mohsin Jadoon ve arkadaşları [16] ayrık eğricik dönüşümü ve çok katmanlı algılayıcıdan oluşan bir mamografi sınıflandırma sistemi sunmaktadırlar. Mamografi görüntüleri filtrelendikten sonra eğricik dönüşümü uygulanmakta daha sonra eğricik alt bantlarına yoğun ölçekli değişmez özellik dönüşümü uygulanmaktadır. Elde edilen özellikler kullanılarak çok katmanlı algılayıcı sınıflandırıcısıyla sınıflandırma gerçekleştirilmektedir.** Chen ve arkadaşları [17] meme kanseri tespiti için mamografi görüntülerinin sınıflandırılmasında dalgacık enerji entropisi ve lineer regresyon sınıflandırıcı kullanan bir sistem sunmaktadırlar. Yöntemde görüntüler bölütlenerek ilgi alanları elde edilmekte ve bu ilgi alanlarından dalgacık enerji entropisi hesaplanmaktadır. Dalgacık enerji entropisi verisi özellikler olarak kullanılmakta ve sınıflandırma işlemi lineer regresyon sınıflandırıcı ile gerçekleştirilmektedir.

Sehrawat ve arkadaşlarının [18] tümör tespiti için önerdikleri yöntem dalgacık dönüşümü ve destek vektör makinalarını içermektedir. Mamografi görüntüleri Gaussian filtresi kullanılarak ön işleme tabi tutulmakta daha sonra dalgacık dönüşümü uygulanarak özellik verisi elde edilmektedir. Sınıflandırma destek vektör makinaları ile gerçekleştirilmektedir. Eltoukhy ve arkadaşı [19] diğer bir çalışmalarında yine karşılaştırmalı olarak dalgacık ve eğricik dönüşümlerini özellik çıkarımı için kullanmaktadırlar. Yöntemde elde edilen özellikler sınıfları ayırt etme kabiliyetine göre sıralanmakta ve daha sonra eşikleme kullanılarak en yüksek performansa sahip özellik verisi elde edilmeye çalışılmaktadır. Farklı olarak, özelliklerin sınıfları ayırt etme kabiliyetlerini belirlerken sınıf ortalamalarının farkını kullanmaktadırlar. Sistemde sınıflandırıcı olarak destek vektör makinaları algoritması kullanılmaktadır.

Bu çalışmada dalga atom dönüşümü kullanılarak mamografi görüntülerinin sınıflandırılması için alternatif bir özellik çıkarımı ve seçimi yöntemi sunulmaktadır. Görüntüler dalga atom dönüşümü ile ayrıştırılıp katsayılar haline getirildikten sonra bu katsayılar kullanılarak özellik atrisi (MxN) oluşturulmaktadır. Daha sonra, oluşturulan bu özellik verisinden en etkili olanlarını tespit etmek için, her sınıfın özellik verisinin kendi içerisinde ortalaması alınarak ortalama vektörleri oluşturulmaktadır. Oluşturulan bu ortalama vektörlerin farkı alınarak sınıf ortalaması farkı vektörü elde edilmekte ve bu vektör üzerinden yapılan dinamik eşikleme ile en etkin özellik verisi aranmaktadır. Sınıflandırma performansı en yüksek olan ve en az sayıya sahip özellik verisi optimum özellikler olarak alınmakta ve bu özellikler kullanılarak sınıflandırma işlemi 5-kat çapraz doğrulama kullanılarak genelleştirilmektedir. Çalışmada MIAS veri tabanına ait mamografi görüntüleri kullanılmaktadır. Sonuçlar önerilen yöntemin mamografi görüntülerinin sınıflandırılmasında başarılı olduğunu göstermektedir.

Dalga atom dönüşümü

Dalga atom dönüşümü 2007 yılında Demanet tarafından sunulan çok ölçekli ve çok çözünürlüklü analiz yöntemidir [20]. Yöntem, parabolik ölçekleme yasalarını sağlayan iki boyutlu (2B) dalgacık paketlerinin bir türevi olarak düşünülebilir. Dalga atom dönüşümü bir örüntüdeki rastsal yerel yönler uyum sağlama kabiliyetine ve diğer dalga paketlerinden daha keskin frekans lokalizasyonuna sahiptir.

Dalga atomları $\varphi_{\mu}(x)$ ile ifade edilmektedir. Burada $\mu = (j, m, n) = (j, m_1, m_2, n_1, n_2)$ faz uzayında bir noktayı (x_{μ}, ω_{μ}) belirtmektedir. x_{μ} pozisyon vektörüdür ve $x_{\mu} = 2^{-j}n$ dir ve $\varphi_{\mu}(x)$ 'nin merkezini temsil etmektedir. ω_{μ} dalga vektörüdür ve $\hat{\varphi}_{\mu}(\omega)$ 'nin her iki tepesinin merkezini belirlemektedir. Pratikte dalga atomları bir boyutlu (1B) dalga paketlerinin tensör çarpımlarından türetilmektedir. 1B dalga paketi $\psi_{m,n}^j(x)$ ile temsil edilmektedir. Burada $j, m \geq 0, n \in Z$ dir ve uzayda $x_{j,n} = 2^{-j}n$ etrafında, frekans düzleminde $\pm\omega_{j,m} = \pm\pi 2^j m$ etrafında merkezlenmektedir. Temel fonksiyon, $\hat{\psi}_m^0$ 'nin frekans ekseninde öteleme ve diydak dilatasyon kombinasyonu ile elde edilmektedir [18].

$$\psi_{m,n}^j(x) = \psi_m^j(x - 2^{-j}n) = 2^{j/2} \psi_m^0(2^j x - n) \quad (1)$$

$$\psi_m^0(\omega) = e^{-j\omega/2} [e^{j\alpha m} g(\varepsilon_m(\omega - \pi(m + 1/2))) + e^{-j\alpha m} g(\varepsilon_{m+1}(\omega + \pi(m + 1/2)))] \quad (2)$$

Burada $\alpha_m = \pi/2 (m + 1/2)$ ve $\varepsilon_m = (-1)^m$ dir. g uygun gerçel değerli C^∞ tepe fonksiyonudur.

2B ortonormal temel fonksiyonları ise 1B dalga paketlerinin frekans düzleminde bireysel çarpımlarıyla biçimlendirilir. $\mu = (j, m, n) = (j, m_1, m_2, n_1, n_2)$ ve H Hilbert dönüşümünü temsil etmek üzere 2B dalga atomları aşağıdaki gibi tanımlanır;

$$\varphi_\mu^+(x_1, x_2) = \psi_{m_1}^j(x_1 - 2^{-j} n_1) \psi_{m_2}^j(x_2 - 2^{-j} n_2), \quad (3)$$

$$\varphi_\mu^-(x_1, x_2) = H\psi_{m_1}^j(x_1 - 2^{-j} n_1) H\psi_{m_2}^j(x_2 - 2^{-j} n_2), \quad (4)$$

Bu iki denklemin birleştirilmesiyle kompakt arayüz aşağıdaki gibi oluşur;

$$\varphi_\mu^{(1)} = \frac{\varphi_\mu^+ + \varphi_\mu^-}{2}, \quad \varphi_\mu^{(2)} = \frac{\varphi_\mu^+ - \varphi_\mu^-}{2} \quad (5)$$

$\varphi_\mu^{(1)}$ ve $\varphi_\mu^{(2)}$ dalga atom arayüzünü biçimlendirir ve birlikte φ_μ olarak ifade edilir [18].

Önerilen yöntem

Yöntem, mamografi görüntülerinin normal-anormal ve iyi huylu-kötü huylu sınıflandırılmasında her bir sınıfı temsil eden özelliklerin farklılığını maksimum yapmayı amaçlamaktadır. Bunu sağlamak için öncelikle her bir sınıfı temsil eden özellikler için farklılık vektörü oluşturulur. Daha sonra bu vektör üzerinden dinamik eşikleme ile en iyi sınıflandırma sonucunu veren en farklı (optimum) özellik verisi aranır. Elde edilen optimum özellik verisi ile sınıflandırma işlemi 5-kat çapraz doğrulama tekrarlanarak sonucun genelleştirilmesi sağlanır.

Başlangıçta mamografi görüntüleri dalga atom dönüşümü kullanılarak ayrıştırılır ve $M \times N$ özellik matrisi dalga atom katsayılarından oluşturulur. Burada M (satırlar) görüntüleme karşılık gelmektedir ve N (sütunlar) dalga atom katsayılarına yani özelliklere karşılık gelmektedir. Her bir sınıfın özellik değerlerinin ortalaması alınarak o sınıfa ait sınıf ortalama vektörü μ_A ve μ_B elde edilmektedir. Sınıf ortalama vektörleri aşağıdaki gibi hesaplanmaktadır;

$$\mu_A = \frac{1}{n_A} \sum_{i=1}^{n_A} C_{Ai} \quad (6)$$

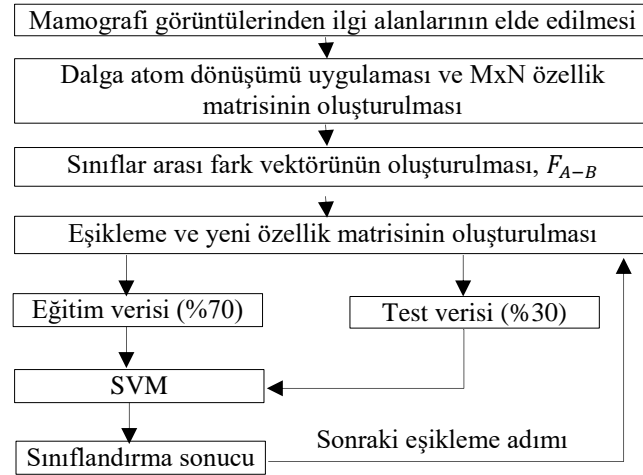
$$\mu_B = \frac{1}{n_B} \sum_{i=1}^{n_B} C_{Bi} \quad (7)$$

Elde edilen sınıf ortalama vektörlerinin farkı alınarak sınıflar arası farklılık vektörü, F_{A-B} , elde edilmektedir.

$$F_{A-B} = |\mu_A - \mu_B| \quad (8)$$

Her bir F_{A-B} değeri özelliklerin sınıfları ayırma oranını belirlemektedir. Özellik seçimi F_{A-B} değerleri üzerinde dinamik eşikleme ile gerçekleştirilmektedir. Eşik değerinin üzerindeki F_{A-B} değerlerine karşılık gelen özellik matrisi ($M \times N$) değerlerinden yeni bir özellik matrisi oluşturulmaktadır. Yeni özellik matrisiyle sınıflandırma işlemi gerçekleştirilmektedir. Daha sonra bir sonraki eşik değerine geçilmekte ve işlemler

tekrarlanmaktadır. Elde edilen sınıflandırma değerleri arasından en iyi sınıflandırma sonucunu minimum özellikle sağlayan eşik değeri ve karşılık gelen özellik matrisi optimum değerler olarak ayrılmaktadır. Uygulamada veri seti eğitim (%70) ve test(%30) verisi olarak ikiye ayrılmaktadır. Eğitim verisi ile sınıflandırıcı (SVM) eğitilmekte ve test verisiyle de sistem performansı değerlendirilmektedir. Sisteme ait akış şeması Şekil 1’de gösterilmektedir.



Şekil 1 Önerilen yöntemin akış şeması

Uygulama


Önerilen yöntemin değerlendirilmesinde MIAS [21] veri setine ait mamografi görüntüleri kullanılmıştır. Veri seti görüntüleri uzman radyologlar tarafından incelenmiş ve etiketlenmiştir. Veri seti 161 hastadan elde edilen 322 görüntüden oluşmaktadır. Bu görüntülerde 207 normal, 64 iyi huylu ve 51 kötü huylu vaka bulunmaktadır. Görüntüler 1024x1024 piksel boyutunda olup yaklaşık %50 si arka plan ve gürültüden oluşmaktadır. Görüntülerdeki istenmeyen bu bölümler kırpma işlemiyle elimine edilmiş ve ilgi alanları (ROIs) görüntü seti oluşturulmuştur. ROIs görüntüleri 128x128 piksel boyutundadır ve anormal görüntülerde anormallik merkezi merkez alınarak kırpma işlemi gerçekleştirilmiştir. Normal görüntülerde rastgele kırpma işlemi yapılmıştır. 114 anormal ve 114 normal olmak üzere toplamda 228 ilgi alanı görüntüsü oluşturulmuştur. İlgi alanlarına ait görüntü dağılımı tablo 1 de gösterilmektedir.

Tablo 1 İlgi alanı görüntülerinin sayısal dağılımı.

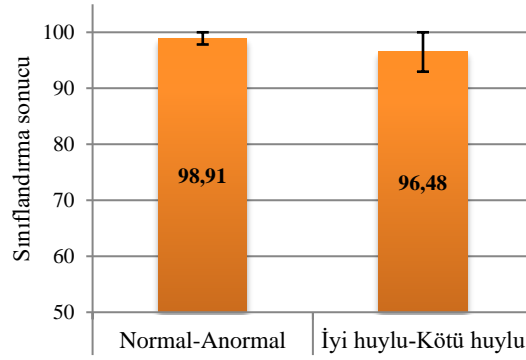
Doku tipi	İyi huylu	Kötü huylu	Toplam
Anormal	64	50	114
Normal	–	–	114
Toplam	64	50	228

Sınıflandırma, görüntülerin önce normal-anormal olarak ayrıştırılması için daha sonra anormal görüntülerin iyi huylu-kötü huylu olarak ayrıştırılması için yapılmıştır. Şekil 2a normal-anormal sınıflandırması için, Şekil 2b iyi huylu-kötü huylu sınıflandırması için eşik değerlerine karşılık özellik sayısı ve sınıflandırma sonucunu vermektedir. En yüksek sınıflandırma değeri normal-anormal sınıflandırma için %100 olurken iyi huylu – kötü huylu sınıflandırması için %97,36 dır. Normal-anormal sınıflandırmasında özellik sayısı, en iyi performans için 32768 den 7 ye düşmekteyken, iyi huylu-kötü huylu

sınıflandırması için 5487 ye düşmektedir. Bu iki değer optimum sınıflandırma değerleri olarak alınmış ve sınıflandırma 5-katlı çapraz doğrulama kullanılarak yeniden gerçekleştirilmiştir. Şekil 3 5-katlı çapraz doğrulama sonucunu farklı katlardaki standart sapmayı hata bariyle göstererek sunmaktadır.



Şekil 2 Sınıflandırma sonuçları a) normal-anormal b)iyi huylu-kötü huylu



Şekil 3 5-katlı çapraz doğrulamaya göre sınıflandırma sonuçları

Önerilen yöntemin daha önce yapılan çalışmalarla olan karşılaştırması Tablo 2 de gösterilmektedir. En az sayıda özelliklerle en yüksek sınıflandırma performansına göre değerlendirme yapılacak olursa, önerilen yöntem Kabul edilebilir bir başarıya sahiptir.

Tablo 2 Önerilen yöntemin yapılmış yakın çalışmalarla yapılan karşılaştırması.

	Veri Seti	ROIs	Yöntem	Özellik sayısı	Sınıflandırma	Doğruluk değeri	Sınıflandırıcı
Eltoukhy ve ark. [15]	MIAS	322 görüntü (207 normal, 115 anormal, 128x128 piksel)	Eğricik	5663	N-A	95,98%	SVM
				333	İH-KH	97,30%	
			Dalgacık	1238	N-A	95,84%	
				150	İH-KH	96,56%	
Gedik [14]	MIAS	228 görüntü (114 normal, 114 anormal, 128x128 piksel)	FFST	8776	N-A	98,29%	SVM
				66	İH-KH	97,39%	
	DDSM	228 görüntü (114 normal, 114 anormal, 128x128 piksel)	FFST	35857	N-A	96,89%	
				272	İH-KH	98,08%	
Eltoukhy ve ark. [19]	MIAS	322 görüntü (207 normal, 115 anormal, 128x128 piksel)	Eğricik	Ulaşılamadı	N-A	91,19%	SVM
				Ulaşılamadı	İH-KH	91,18%	
			Dalgacık	Ulaşılamadı	N-A	89,51%	
				Ulaşılamadı	İH-KH	89,58%	
Önerilen yöntem	MIAS	228 görüntü (114 normal, 114 anormal, 128x128 piksel)	Dalga atom	7	N-A	98,91%	SVM
				5487	İH-KH	96,48%	

Sonuç

Bu çalışmada özellik çıkarımı ve seçimi için alternatif bir yöntem tanıtılmış ve uygulaması gerçekleştirilmiştir. Yöntem çok çözünürlüklü analiz yöntemlerinin avantajlarını da içermektedir. Temel amaç başarılı bir sınıflandırma için en çok katkı sağlayacak özelliklerin değersiz özelliklerden ayırt edilmesini sağlamaktır. Bu doğrultuda özelliklerin ayırt edilmesi için sınıf ortalamaları farkı oluşturulmuş ve dinamik eşikleme ile mümkün olan en az sayıda özellikte en yüksek sınıflandırma başarısını sağlayan özellik seti elde edilmiştir. Ulaşılan en iyi sınıflandırma sonuçları normal-anormal için %98,91 ve iyi huylu kötü huylu için %96,48 dir.

Referanslar

- 1- Banaem, H.Y., Dehnavi, A.M., Shahnazi, M., 2015, "Ensemble supervised classification method using the regions of interest and grey level co-occurrence matrices features for mammograms data", *Iranian Journal of Radiology*, Vol. 12, No. 3, pp. 1-8.
- 2- Verma, B., Zhang, P., 2007, "A novel neural-genetic algorithm to find the most significant combination of features in digital mammograms", *Applied soft computing*, Vol. 7, pp. 612-625.
- 3- Mousa, R., Munib, Q., Moussa, A., 2005, "Breast cancer diagnosis system based on wavelet analysis and fuzzy-neural", *Expert systems with applications*, Vol. 28, pp. 713-723.

- 4- Zadeh, H.S., Rad, F.R., Nejad, S.P., 2004, "Comparison of multiwavelet, wavelet, Haralick, and shape features for microcalcification classification in mammograms", *Pattern recognition*, Vol. 37, pp. 1973-1986.
- 5- Cheng, H.D., Shi, X.J., Min, R., Hu, L.M., Cai, X.P., Du, H.N., 2006, "Approaches for automated detection and classification of masses in mammograms", *Pattern Recognition*, Vol. 39, No. 4, pp. 646-668.
- 6- Christoyianni, I., Koutras, A., Dermatas, E., Kokkinakis, G., 2002, "Computer aided diagnosis of breast cancer in digitized mammograms", *Computerized medical imaging and graphics*, Vol. 26, pp. 309-319.
- 7- Cheng, H.D., Cai, X., Chen, X., Hu, L., Lou, X., 2003, "Computer aided detection and classification of microcalcification in mammograms: a survey", *Pattern recognition*, Vol. 36, pp. 2967-2991.
- 8- Verma, B., McLeod, P., Klevansky, A., 2010, "Classification of benign and malignant patterns in digital mammograms for the diagnosis of breast cancer", *Expert systems with applications*, Vol. 37, pp. 3344-3351.
- 9- Sayed, U., Mofaddel, M.A., Abd-Elhafiez, W.M., Abdel-Gawad, M.M., 2013, "Image object extraction based on curvelet transform", *An international journal of applied mathematics & information sciences*, Vol. 7, pp. 133-138.
- 10- Gedik, N., 2015, "Breast cancer diagnosis system via contourlet transform with sharp frequency localization and LS-SVM", *Journal of medical imaging and health informatics*, Vol. 5, pp. 1-9.
- 11- Gedik, N., Atasoy, A., 2014, "Performance evaluation of the wave atom algorithm to classify mammographic images", *Turk. J. Elec. Eng. & Comp. Sci.*, Vol. 22, pp. 957-969.
- 12- Liu, S., Babbs, C.F., Delp, E., 2001, "Multiresolution detection of spiculated lesions in digital mammograms", *IEEE Transactions on Image Processing*, Vol. 10, pp. 874-884.
- 13- Moayedi, F., Azimifar, Z., Boostani, R., Katebi, S., 2010, "Contourlet-based mammography mass classification using the SVM family", *Computers in biology and medicine*, Vol. 40, pp. 373-383.
- 14- Gedik, N., 2016, "A new feature extraction method based on multi-resolution representations of mammograms", *Applied Soft Computing*, Vol. 44, No. 1, pp. 128-133.
- 15- Eltokhy, M.M., Faye, I., Samir, B.B., 2012 "A statistical based feature extraction method for breast cancer diagnosis in digital mammogram using multiresolution representation", *Computers in biology and medicine*, Vol. 42, No. 1, pp. 123-128.
- 16- Jadoon, M.M., Zhang, Q., Haq, I.U., Jadoon, A., Basit, A., Butt, S., 2017, "Classification of mammograms for breast cancer detection based on curvelet transform and multi-layer perceptron", *Biomedical Research*, Vol. 28, No. 10, pp. 4311-4315.

- 17- Chen, Y., Zhang, Y., Lu, H.M., Chen, X.Q., Li, J.W., Wang, S.H., 2018, “Wavelet energy entropy and linear regression classifier for detecting abnormal breasts”, *Multimed Tools Appl.*, Vol. 77, pp. 3813–3832.
- 18- Sehrawat, D., Sehrawat, A., Jaiswal, D., Sen, A., 2017, “Detection and classification of tumor in mammograms using discrete wavelet transform and support vector machine”, *International Research Journal of Engineering and Technology (IRJET)*, Vol. 4, No. 5, pp. 1328-1334.
- 19- Eltoukhy, M.M., Faye, I., 2014, “An optimized feature selection method for breast cancer diagnosis in digital mammogram using multiresolution representation”, *Applied Mathematics & Information Sciences*, Vol. 8, No. 6, pp. 2921-2928.
- 20- Demanet, L., Ying, L.X., 2007, “Wave atoms and sparsity of oscillatory patterns”, *Applied and Computational Harmonic Analysis*, Vol. 23, pp. 368-387.
- 21- <http://peipa.essex.ac.uk/info/mias.html> (erişim tarihi: kasım 2018)