

## Göğüs Kanseri Teşhisinde Bir Öznitelik Seçim Analizi

### A Feature Selection Analysis in Breast Cancer Diagnosis

İdil İŞIKLI ESENER<sup>1</sup>, Semih ERGİN<sup>2</sup>, Tolga YÜKSEL<sup>1</sup>

<sup>1</sup> Elektrik-Elektronik Mühendisliği  
Bilecik Şeyh Edebali Üniversitesi  
{idil.isikli,tolga.yuksel}@bilecik.edu.tr

<sup>2</sup> Elektrik-Elektronik Mühendisliği  
Eskişehir Osmangazi Üniversitesi  
sergin@ogu.edu.tr

#### Özetçe

Bu çalışmada meme kanseri teşhisi yapabilen bir bilgisayar destekli teşhis sisteminin tasarlanması amaçlanmış ve sistemin doğrulanmasında Image Retrieval in Medical Applications (IRMA) projesi kapsamında hazırlanmış mamografi veritabanı kullanılmıştır. Bu amaç doğrultusunda, histogram eşitleme sonrası Yerel-Olmayan Ortalama Filtreleme işlemlerine tabi tutulmuş mamografi imgelerinden Yerel Konfigürasyon Örüntüsü algoritması kullanılarak öznitelik çıkartımı gerçekleştirilmiştir. Bu özniteliklere ek olarak, bazı istatistiksel ve frekans-düzlemi öznitelikleri ile vektör uzayı genişletilmiştir. Ayrıca, elde edilen özniteliklere Ardışık İleri Yönde Seçim (SFS) algoritması uygulanarak öznitelik seçimi gerçekleştirilmiştir. Son olarak, seçilen öznitelikler, doğrusal ayırtaç sınıflandırıcısı, Fisher doğrusal ayırtaç analizi, lojistik doğrusal sınıflandırıcı, k-en yakın komşu sınıflandırıcısı, Naive Bayes ve karar ağacı sınıflandırıcılarında kullanılarak 2-aşamalı bir süreçte 3 farklı kategoriye (normal, iyi huylu kanser, kötü huylu kanser) ayrılmıştır. Öznitelik seçimi yapıldığı ve yapılmadığı durumlarda elde edilen sonuçlar karşılaştırılmış ve her iki durumda da en yüksek yaklaşık % 88 başarı oranı ile sınıflandırmanın gerçekleştirildiği sonucuna varılmıştır. Bu orana, SFS algoritması yardımı ile 108 adet öznitelikten 15 adedi seçildiğinde lojistik doğrusal sınıflandırıcısı kullanılarak ulaşılmıştır. Tüm sınıflandırıcıların her iki durumda başarı performansları incelendiğinde, veri depolama, hafıza işgali ve hesaplama zamanı açısından öznitelik seçiminin uygun olduğu görülmüştür.

**Anahtar Kelimeler** — meme kanseri; öznitelik çıkartımı; sayısal mamografi; bilgisayar destekli teşhis.

#### Abstract

In this paper, it is aimed to design a computer aided diagnosis system for breast cancer diagnosis and a mamogram dataset prepared during the Image Retrieval in Medical Applications (IRMA) project is used for the verification of the system. In accordance with this purpose, feature extraction is realized using Local Configuration Pattern algorithm on the pre-processed mamogram images by histogram equalization followed by Non-Local Means Filtering. In addition to these features, vector space is extended by some statistical and

frequency-domain features. Besides, feature selection is performed by applying Sequential Forward Feature Selection (SFS) algorithm on the obtained features. Finally, selected features are classified in a 2-stage scheme into 3 different categories (normal, benign, malignant) using linear discriminant classifier, Fisher's linear discriminant analysis, logistic linear classifier, k-nearest neighbor classifier, Naive Bayes and decision tree classifiers. The results attained at the cases, in which feature selection is performed and not, are compared and it is concluded with approximately 88 % maximum success rate is accomplished in both cases. This success rate is achieved using logistic linear classifier when 15 features are selected among 108 features via SFS algorithm. Analyzing the success performance of all classifiers in both cases, appropriateness of feature selection is decided by means of data storage, memory occupation, and computational time.

**Keywords** — breast cancer; feature extraction; digital mammography; computer aided diagnosis.

#### 1. Giriş

Kadın ölümlerinin başlıca sebeplerinden olan meme kanserinin erken teşhisi sayesinde ölüm oranı azaltılabilmektedir [1]. Mamografi, meme kanserinin erken teşhisinde kullanılan en yaygın yöntem olduğu halde, meme dokusundaki normal bölgeler ile lezyonlu bölgelerin benzer X-ışını geçirgenliği ve meme doku yoğunluğu arttıkça oluşan bilgi kaybı, radyoloji uzmanları açısından teşhis sürecini zorlaştırmaktadır. Mamografi imgelerinin analiz süresini kısaltmak, radyologların mamogram analizine katkı sağlamak ve insan hatasının teşhisteki rolünü azaltmak maksatlarıyla Bilgisayar Destekli Teşhis (Computer Aided Diagnosis – CAD) sistemlerinin geliştirilmesi önem arz etmektedir.

Bu çalışmada, meme kanseri teşhisi yapabilen bir CAD sistemin tasarlanması amaçlanmış ve bu sistem Image Retrieval in Medical Applications (IRMA) projesi kapsamında hazırlanmış mamografi veritabanı kullanılarak doğrulanmıştır. Bu amaç doğrultusunda, mamografi imgeleri öncelikle, histogram eşitleme ve akabinde Yerel-Olmayan Ortalama (Non-Local Means – NLM) filtreleme [2] ön işlemlerine tabi tutulmuştur. Sonrasında, Yerel Konfigürasyon Örüntüsü (Local Configuration Pattern – LCP) algoritması [3] kullanılarak öznitelik çıkartımı gerçekleştirilmiş; oluşturulan

## Tıbbi Görüntüleme 5

2. Gün / 16 Ekim 2015, Cuma

öznitelik vektör uzayı bazı istatistiksel öznitelikler ve mamogramların frekans-düzlemi özniteliklerinin eklenmesi ile genişletilmiştir. Elde edilen özniteliklerden mamografi imgelerini en iyi temsil edenlerin belirlenmesi amacı ile Ardışık İleri Yönde Seçim (Sequential Forward Selection - SFS) algoritması [4] kullanılarak öznitelik seçimi gerçekleştirilmiştir. Son olarak, seçilen öznitelikler Doğrusal Ayırtaç Sınıflandırıcısı (Linear Discriminant Classifier - LDC), Fisher Doğrusal Ayırtaç Analizi (Fisher's Linear Discriminant Analysis - FLDA), Lojistik Doğrusal Sınıflandırıcı (Logistic Linear Classifier - LLC),  $k$ -En Yakın Komşu Sınıflandırıcısı ( $k$ -Nearest Neighbor Classifier -  $k$ -NN), Naive Bayes ve Karar Ağacı sınıflandırıcıları kullanılarak 2-aşamalı bir süreçte sınıflandırılmıştır. Sınıflandırma sürecinin 1. aşamasında, mamografi imgeleri meme doku tiplerine göre yağlı, yağlı-glandüler, heterojen-yoğun ve çok yoğun olarak sınıflandırılmıştır. İkinci aşamada ise, doku tipine göre ayrılmış imgeler sağlık durumlarına göre normal (sağlıklı), iyi huylu kanser ve kötü huylu kanser olarak sınıflandırılmıştır.

## 2. Mamografi İmgelerinin Ön İşlenmesi

Mamogram imgelerinin incelenmesinde radyoloji uzmanlarının yorumlama sürecini zorlaştıran temel olarak iki sorun bulunmaktadır. Bu sorunlardan ilki, kemik, pektoral kas gibi diğer dokuların şüpheli bölge üzerindeki düşük kontrastlı piksellerin görülmesini engellemesidir. Bu sorunun aşılması için mamografi imgelerine öncelikle histogram eşitleme uygulanmıştır.

Bir diğer sorun ise, görüntüleme sırasında veya etiketleme sonucu imgelerde gürültü oluşmasıdır. Gürültüler, genellikle imgelerde yüksek frekanslı bileşenler olarak ortaya çıktığından, gürültü giderimi için imgelere bir yumuşatma filtresinin uygulanması gerekmektedir. Yumuşatma filtreleri, yüksek frekans bileşeni olan gürültüyü giderirken yine yüksek frekans bileşeni olan kenar ve detay bilgilerinin de kaybına neden olmaktadır. Bu durumda, gürültüyü giderirken detay bilgisini de koruyabilen adaptif filtrelerin kullanımı önem arz etmektedir. Bu sebeple, imge iyileştirme aşamasında histogramı eşitlenerek kontrastı artırılmış mamogram imgelerine Yerel-Olmayan Ortalama Filtresi (Non-Local Means Filter - NLM) uygulanmıştır.

NLM filtresi, herhangi iki pikselin komşuluklarının birbirine olan benzerliğine göre pencere boyutunu değiştirirken, arama penceresinde türevleri dikkate alarak kenar bilgisini koruyacak ağırlıklandırma fonksiyonunu oluşturmaktadır [2]. NLM filtresi, sadece yeğinlik (intensity) değerlerini değil komşuluktaki geometrik konfigürasyonları da karşılaştırmaktadır. Bu durum, NLM filtresinin, komşuluk filtrelerine göre daha iyi çalışmasını sağlamaktadır.

## 3. Öznitelik Çıkarımı ve Seçimi

Öznitelik vektörlerinin normal ve lezyonlu bölgeleri ne kadar iyi temsil edebildiği CAD sistemlerinin başarısını doğrudan etkileyen en önemli unsurdur. Bu yüzden, sınıf içi değişimi en az sınıflar arası değişimi en fazla tutan, en az sayıda öznitelik çıkarmak öznitelik çıkartımında esas alınmaktadır. Bu çalışmada, öznitelik çıkartımı için Yerel Konfigürasyon Örüntüsü (Local Configuration Pattern - LCP) algoritması kullanılmıştır. Bununla birlikte, LCP-tabanlı özniteliklere bazı istatistiksel ve frekans-düzlemi özniteliklerinin eklenmesi ile vektör uzayı genişletilmiştir. Ayrıca, elde edilen özniteliklerden mamografi imgelerini en iyi temsil edenlerin

belirlenmesi amacı ile Ardışık İleri Yönde Seçim (Sequential Forward Selection - SFS) algoritması kullanılarak öznitelik seçimi gerçekleştirilmiştir.

### 3.1. Yerel Konfigürasyon Örüntüsü (Local Configuration Pattern - LCP)

LCP, iki boyutlu bir imgenin yerel bölge bilgisi ile piksel sıklıklarının harmanlayan bir algoritma kullanarak öznitelik vektörü oluşturmaktadır [3].

LCP algoritmasında yerel bölge bilgisi, Yerel İkili Örüntü (Local Binary Pattern - LBP) algoritması ile elde edilmektedir. Herhangi bir  $I$  görüntüsünün LBP öznitelik vektörü, Eş. (1)'te gösterildiği şekilde  $I$  görüntüsünün her bir pikselini,  $R$  yarıçaplı dairesel komşuluğundaki  $P$  tane piksel ile karşılaştırılması sonucu elde edilmektedir. Eşitlikteki  $g_i$  ve  $g_c$  ifadeleri sırası ile,  $i$ . komşuluk pikselinin ve komşuluktaki merkez pikselin yeğinlik değerleri olarak tanımlanmaktadır. Burada  $u(x)$  birim basamak fonksiyonudur.

$$LBP(P, R) = \sum_{i=0}^{P-1} u(g_i - g_c) \cdot 2^i \quad (1)$$

Dairesel ikili gösterimde en fazla iki bit değişimi olan örüntüler bir biçimli (uniform) olarak tanımlanmaktadır. Dönme açısından bağımsız örüntüler, her bir bitin dairesel olarak, en büyük değer son eleman olacak şekilde, minimum değere döndürülmesi ile elde edilmektedir. Bu bilgiler doğrultusunda,  $I$  görüntüsünden LBP algoritması kullanılarak elde edilen dönme açısından bağımsız uniform iki boyutlu ikili örüntüler Eş. (2) ile hesaplanmaktadır. Eşitlikteki  $U$  ifadesi bir biçimlilik ölçütünü belirtmektedir.

$$LBP^{riu2}(P, R) = \sum_{i=0}^{P-1} u(g_i - g_c), \quad U(LBP(P, R)) \leq 2 \quad (2)$$
$$P+1, \quad U(LBP(P, R)) \leq 2$$

LBP-tabanlı yöntemler ile imge gösterimi yeğinlik değişimlerine karşı başarı gösterdikleri halde, gri-seviye yeğinlik değerlerini ikili seviyeye kuantalama aşamasında imge görünümü ve piksel ilişkilerini kodlama kapasitesi azalmaktadır. Bu durumu ortadan kaldırmak amacı ile Eş. (3) kullanılarak komşu piksellerinin ortalaması  $\mu$  olan her bir örüntünün yerel varyansı hesaplanmaktadır. Sonuç olarak  $I$  görüntüsünün dönme açısından bağımsız bir biçimli yerel öznitelikleri ( $O$ ) Eş. (4) ile elde edilmektedir.

$$VAR = \frac{1}{P} \sum_{i=0}^{P-1} (g_i - \mu)^2 \quad (3)$$

$$O = \frac{LBP^{riu2}}{VAR} \quad (4)$$

LBP vektörleri aynı çıkmış örüntülerin varyanslarının da eşit olması durumunda, örüntülerden, dokusal özelliklerine bağlı olarak farklı konfigürasyonda olsa da, aynı öznitelik vektörleri elde edilmektedir. Bu durumu ortadan kaldırmak amacı ile örüntülerin mikroskobik konfigürasyonu modellenmektedir. Bu amaçla, öncelikle, komşu piksel

## Tıbbi Görüntüleme 5

2. Gün / 16 Ekim 2015, Cuma

yeğlilik değerleri ağırlıklandırılarak her bir örüntünün merkez pikselini tanımlayacak doğrusal modeller oluşturulmuştur. Modelleme hatasını en aza indirgeyen en uygun ağırlık vektörü ( $A_L$ ) en küçük kareler yöntemi ile hesaplanmaktadır. Ağırlık vektörünü dönme açısından bağımsız kılmak için 1-boyutlu Fourier dönüşümü ( $H_L$ ) alınmakta ve dönüşümün büyüklüğü ( $|H_L|$ ) mikroskobik öznelik vektörü olarak hesaplanmaktadır. Sonuç olarak,  $q$  tane örüntüye sahip  $I$  imgesinin LCP öznelik vektörü Eş. (5)'te gösterildiği şekilde yerel öznelikler ve mikroskobik öznelikler birleştirilerek elde edilmektedir.

$$LCP = \left[ \left[ H_0; O_0 \right]; \left[ H_1; O_1 \right]; \dots; \left[ H_{q-1}; O_{q-1} \right] \right] \quad (5)$$

Bu şekilde imgeler hem doku özelliklerine hem de piksel sıklıklarına göre değerlendirilmekte ve öznelik vektörü çıkartılmaktadır.

### 3.2. İstatistiksel Öznelikler

Doğrudan imgelerden elde edilen istatistiksel özneliklerin sınıflandırma başarısındaki olumlu etkisi bilinmektedir [5]. Ayrıca, LCP algoritmasının da mamografi imgelerinden ayırt ediciliği yüksek öznelikler çıkarttığı belirtilmiştir [6]. Bu nedenle, doğrudan imgelerden istatistiksel öznelikler çıkarmak yerine, LCP öznelik vektörlerinden enerji, ortalama, varyans, maksimum, minimum, standart sapma, çarpıklık, basıklık, alan-tanımlayıcısı, ortalama enerji, enerji varyansı ve entropi istatistiksel öznelikleri elde edilmiştir. Herhangi bir imgenin alan-tanımlayıcısı değeri, o imgenin standart sapmasının ortalamasına oranı olarak hesaplanmaktadır.

### 3.3. Frekans-Düzlemi Öznelikleri

Bir mamografi imgesinde kanser teşhisi açısından önemli bir öznelik olan parlaklığın imgedeki değişimleri, en iyi şekilde imgenin uzamsal frekansında gözlemlenmektedir. Bu nedenle, frekans-düzlemi özneliklerinin mamografi imgelerini daha iyi temsil edebileceği gerekçesi ile imgeler Daubechies1 (db1) dalgacığı kullanılarak ikinci seviyede 2-boyutlu ayrık dalgacık dönüşümüne tabi tutulmuştur. İmgelerin enerji değerlerinin parlaklık değerleri ile doğrudan ilişkili ve parlaklığın da meme kanseri teşhisinde etkili bir öznelik olduğu gerekçesi ile dalgacık dönüşümü sonucu elde edilen her bir alt bantın enerjisi frekans-düzlemi öznelikleri olarak kullanılmıştır.


### 3.4. Ardışık İleri Yönde Seçim (Sequential Forward Selection) Algoritması

Öznelik seçimi, var olan öznelik kümesi içerisinde veriyi en iyi temsil eden özneliklerin tanımlanan bir ölçüt fonksiyonuna göre tespitini amaçlamaktadır. SFS algoritması sarıcı (wrapper) seçim yaklaşımlarından olup "azdan çoğa" doğru çalışan bir algoritmadır. SFS algoritmasına boş bir seçim kümesi ile başlanmakta ve her adımda ölçüt fonksiyonunu eniyileyen bir adet öznelik seçim kümesine eklenmektedir [4].

## 4. Deneysel Çalışmalar

### 4.1. Veritabanı

Bu çalışma kapsamında hazırlanan CAD sisteminin doğrulanmasında *Image Retrieval in Medical Applications* (IRMA) projesi kapsamında hazırlanmış mamografi veritabanı kullanılmıştır [7]. Bu veritabanı *Breast Imaging Reporting and Data System* (BI-RADS) tarafından tanımlanmış tüm meme doku tiplerine (yağlı, yağlı-glandüler, heterojen-yoğun, çok yoğun) ait 233 normal (sağlıklı), 233 iyi ve 233 kötü huylu lezyon içeren mamografi imgesi olmak üzere toplamda 12 sınıf ve 2796 imge içermektedir. Veritabanındaki imgeler tüm meme bölgesinden normal ve hastalıklı bölgelerin çıkartılmış olduğu imge parçalarıdır. Veritabanında bulunan her bir sınıfa ait birer örnek imge Şekil 1'de gösterilmiştir.



Şekil 1: IRMA veritabanına ait örnek imgeler.

Bu çalışmada, her bir sınıfa ait ilk 200 imge alınarak toplamda 2400 imge kullanılmıştır. Bu imgelerin, her sınıftan 180 adet olmak üzere toplamda 2160 tanesi eğitim aşamasında, her sınıftan kalan 20 tane olmak üzere 240 adedi test aşamasında kullanılacak şekilde 10-katlamalı (10-fold) çapraz-doğrulama (cross-validation) yöntemi ile sınıflandırılmıştır.

### 4.2. Öznelik Vektörlerinin Oluşturulması

Öznelik çıkartımı için ön işleme tabi tutulmuş imgeler öncelikle "db1" dalgacığı kullanılarak birinci seviyede 2-boyutlu ayrık dalgacık dönüşümüne tabi tutulmuştur. Dalgacık dönüşümü sonucu elde edilen her bir alt bantta (Alçak/Alçak-AA, Alçak/Yüksek-AY, Yüksek/Alçak-YA, Yüksek/Yüksek-YY) 8-komşuluk, 2 piksel uzaklık parametreleri ile LCP dönüşümü uygulanarak 81 x 1 boyutlu vektörler elde edilmiştir. LCP dönüşümünde kullanılan parametreler, çeşitli değerlerin denenip en başarılı sonucu sağlayanların seçilmesi ile belirlenmiştir. Elde edilen vektörlerin 81. boyutundaki değerler diğer boyutlardaki değerlerden çok büyük olduğu için 81. boyutlar atılmış ve her bir alt banttan elde edilen vektörler Ergin ve Kılınc'ın çalışmalarında [6] kullandıkları katsayı kümelerinden en başarılı olarak tespit ettikleri {1.4-1-1-0} katsayıları ile ağırlıklandırılarak toplanmıştır. Bu süreç veritabanındaki tüm imgelere uygulanmış ve her bir imgeye ait 80-boyutlu öznelik vektörleri elde edilmiştir. Öznelik vektörlerinin imgeleri temsil edebilirlik kapasitesini yükseltmek amacı ile 80-boyutlu öznelik vektörlerine 12 tane istatistiksel ve 16 tane frekans-düzlemi öznelikleri eklenerek

Tablo 1: Sınıflandırma Sonuçları

Sınıflandırıcılar	Öznitelik Seçimi Yapılmadığında		Öznitelik Seçimi Yapıldığında		
	Ortalama (%)	Standart Sapma	Ortalama Öznitelik Sayısı	Ortalama (%)	Standart Sapma
LLC	80.87	7.48	15	88.20	6.67
FLDA	88.69	4.37	16	86.54	5.76
<i>k</i> -NN ( <i>k</i> =5)	41.94	2.21	8	85.29	4.98
LDC	87.37	5.42	12	84.16	8.02
Naïve Bayes	68.48	5.51	15	78.51	3.71
Karar Ağacı	68.78	2.91	11	67.70	2.43

vektör uzayı 108-boyuta genişletilmiştir.

Elde edilen özniteliklerden mamografi imgelerini en iyi temsil edenlerin belirlenmesi amacı ile SFS algoritması kullanılarak öznitelik seçimi gerçekleştirilmiştir.

### 4.3. 2-Aşamalı Sınıflandırma Süreci

Bu çalışma kapsamında hazırlanan CAD sistemi, meme kanseri teşhisini 2-aşamalı bir sınıflandırma sürecinde gerçekleştirecek şekilde tasarlanmıştır. Sınıflandırma sürecinin 1. aşamasında mamografi imgeleri meme doku tiplerine göre yağlı, yağlı-glandüler, heterojen-yoğun ve çok yoğun olarak ayrılmış; ikinci aşamada ise doku tipine göre ayrılmış imgeler, sağlık durumlarına göre normal, iyi huylu kanser ve kötü huylu kanser olarak sınıflandırılmıştır.

108-boyutlu öznitelik vektörlerinin kullanıldığı ve öznitelik seçiminin yapıldığı durumlarda 10-katlamalı çapraz-doğrulama yöntemi ile elde edilen ortalama başarı oranları, katlamalara ait standart sapma değerleri ve öznitelik seçimi sonucunda sınıflandırıcıların kullandığı ortalama öznitelik sayıları Tablo 1'de gösterilmiştir.

## 5. Sonuçlar

Yapılan çalışmada öznitelik seçimi yapıldığı durumlarda, LLC, *k*-NN ve Naïve Bayes sınıflandırıcılarının tanıma performansının belirgin olarak arttığı, Karar Ağacı, FLDA ve LDC sınıflandırıcılarının ise başarı oranlarının ortalama % 2 oranında düştüğü tespit edilmiştir. Bu sonucun meme kanseri teşhisinin yürütüldüğü bilgisayarlarda daha az miktarda verinin depolanması, daha düşük boyutta hafıza işgali ve bu sayede daha kısa hesaplama zamanı kazanımlarını sağlaması nedeni ile meme kanseri teşhisinde öznitelik seçimi yapılmasının uygun olduğu görülmüştür. Öznitelik seçimi gerçekleştirildiğinde, meme kanseri teşhisi en yüksek %88.20 başarı oranı ile LLC sınıflandırıcısı kullanılarak gerçekleştirilmiştir.

SFS algoritması sonucunda seçilen öznitelikler incelendiğinde, tüm sınıflandırıcılar için genel olarak LCP-tabanlı özniteliklerinin yanında frekans-düzlemi özniteliklerinin seçildiği tespit edilmiştir. Toplam 16 adet frekans-düzlemi özniteliği arasından 4 adedi (AAAA, AYAA, AYAY ve YAYA) öznitelik seçim süreci sonucu ayırt ediciliği en yüksek öznitelikler olarak bulunmuştur. Buradaki kısaltmalar içerisinde örneğin AYAA, 2-seviyeli 2-boyutlu ayrık dalgacık dönüşümünden elde edilen (Alçak-Yüksek)-(Alçak-Alçak) alt bandının enerji değerini ifade etmektedir. Toplam 12 adet istatistiksel öznitelik arasından ortalama, maksimum ve çarpıklık özniteliklerinin sınıflandırıcı başarımına en iyi katkıyı sağladıkları görülmüştür.

Sınıflandırıcı temelinde bir inceleme yapıldığında, tüm sınıflandırıcıların ortalama özniteliklerinin seçimi neticesinde başarılı olduğu görülmüştür. Bu durum ortalama istatistiğinin

ayırt edici gücü en yüksek bilgiyi taşıdığını gözler önüne sermiştir. İstatistikî öznitelikler arasında en çok seçimi yapılan diğer öznitelik ise maksimum öznitelidir. LCP vektörlerindeki en büyük değerler piksel değişimlerinin en az olduğu (varyansın en düşük olduğu) durumlarda hesaplanmış olduğu için LCP vektörlerinden çıkartılan tüm istatistikî öznitelikler arasında maksimum öznitelikinin ayırt edicilik gücü daha yüksektir. Frekans-düzlemi öznitelikleri incelendiğinde, 1.seviye dönüşümden elde edilen (Alçak-Alçak) bandı, zaman-düzlemindeki orijinal mamografi imgesine en yakın ve aynı zamanda istenmeyen bilgilerden en çok arındırılmış alt bandı temsil ettiğinden tüm sınıflandırıcılarda ayırt ediciliği ön plana çıkmıştır.

## Teşekkür

Bu çalışmada kullanılan veritabanına Thomas M. Deserno, Department of Medical Informatics, Division of Image and Data Management, Aachen, Almanya, izni ile erişilmiştir.

## 6. Kaynakça

- [1] Jemal, A., Bray, F., Center, M. M., Ferlay, J., Ward, E. ve Forman, D., "Global Cancer Statistics", *CA: A Cancer Journal for Clinicians*, 61(2), 69-90, 2011.
- [2] Buades, A., Coll, B. ve Morel, J. M., "A Review of Image Denoising Algorithms, with a New One", *Multiscale Modelling and Simulation*, 4(2), 490-530, 2005.
- [3] Guo, Y., Zhao, G. Zhao ve Pietkäinen, M., "Texture Classification Using a Linear Configuration Model Based Descriptor", *British Machine Vision Association*, 119, 1-10, 2011.
- [4] Whitney, A. W., "A Direct Method of Nonparametric Measurement Selection", *IEEE Transactions on Computers*, 20, 1100-1103, 1971.
- [5] Woods, K., Doss, C., Bowyer, K., Solka, J., Priebe, C. ve Philip, W., "Comparative Evaluation of Pattern Recognition Techniques for Detection of Microcalcifications in Mammography", *International Journal of Pattern Recognition and Artificial Intelligence*, 7, 1417-1435, 1993.
- [6] Ergin, S. ve Kılınc, O., "A New Feature Extraction Framework Based on Wavelets for Breast Cancer Diagnosis", *Computers in Biology and Medicine*, 51, 171-182, 2014.
- [7] Deserno, T. M., Oliveira, J. E. E. ve Araujo, A. A., "Towards computer-aided diagnostics of screening mammography using content-based image retrieval", *24. SIBGRAPI Conference on Graphics, Patterns and Images*, 2011, 211-219.