

ÖZÖRGÜTLEMELİ HARİTA AĞLARI VE GRİ DÜZEY EŞ OLUŞUM MATRİSLERİ İLE GÖRÜNTÜ BÖLÜTLEME

Ayşe DEMİRHAN ve İnan GÜLER

Elektronik-Bilgisayar Eğitimi Bölümü, Teknik Eğitim Fakültesi, Gazi Üniversitesi, 06500, Ankara
ayseoguz@gazi.edu.tr, iguler@gazi.edu.tr

(Geliş/Received: 11.03.2009 ; Kabul/Accepted: 05.05.2009)

ÖZET

Görüntü bölütleme bir görüntünün bir ya da daha fazla karakteristiğe veya özelliğe göre sınıf ya da altküme denilen bölgelerine ayrılması, aynı karakteristiğe sahip, ilgilenilen alanların arka plandan ve diğer alanlardan ayrılarak belirgin hale getirilmesidir. Görüntü işlemede gerçekleştirilen en zor adım görüntü bölütlemesidir. Daha sonra yapılacak olan görüntü analizlerinin ve ilgili uygulamaların başarılı olması büyük ölçüde görüntü bölütlemenin başarısına bağlı olmaktadır. Bu çalışmada çeşitli görüntüler özörgütlemeli harita (SOM) ağları ve gri düzey eş oluşum matrisleri (GLCM) kullanılarak bölütlenmiştir. Bu yöntemlerin görüntü bölütleme uygulamalarındaki performansları değerlendirilmiştir. Sonuçta bu yöntemlerin görüntü bölütlenme uygulamalarında %90 başarılı gösterdiği görülmüştür.

Anahtar Kelimeler: Görüntü bölütleme, özörgütlemeli harita ağları, gri düzey eş oluşum matrisleri.

IMAGE SEGMENTATION USING SELF-ORGANIZING MAPS AND GRAY LEVEL CO-OCCURRENCE MATRICES

ABSTRACT

Image segmentation is the separation of an image into segments called classes or subsets, according to one or more characteristics or features, and enhancing areas of interest by separating them from the background and other areas. Image segmentation is the most difficult stage in image processing. The success of subsequent image analysis and related applications depends greatly on the success of image segmentation. In this study images were segmented using self-organizing map (SOM) networks, and gray level co-occurrence matrices (GLCM). The performances of these methods on image segmentation were evaluated. It is seen that these methods showed %90 success on image segmentation applications.

Keywords: Image segmentation, self-organizing maps, gray level co-occurrence matrix.

1. GİRİŞ (INTRODUCTION)

Görüntü bölütlemenin amacı daha sonraki işlemlerde kullanılmak üzere iki boyutlu piksel dizisi şeklinde temsil edilen görüntüdeki bütün piksellerin ortak özellikleri olan kümelere gruplanmasıdır [1].

Görüntülerin bölütlenmesinde kullanılan yöntemler uygulamaya, görüntülemenin türüne ve diğer faktörlere göre değişmektedir. Sınıflama tabanlı görüntü bölütleme algoritmaları doku benzerliği, parlaklık benzerliği, dış hat enerjisi, eğrisel süreklilik vb. kriterlere göre oluşturulabilir. Bu algoritmanın kesinliği seçilen öğrenme parametrelerine bağlıdır. Sınıflama

tabanlı görüntü bölütlemesinde kullanılan en etkin yöntemlerden biri yapay sinir ağlarıdır. Yapay sinir ağları (YSA) sınıflandırma, kümeleme ve özellik çıkartımı gibi desen tanıma problemleri için özellikle uygundur ve yaygın olarak kullanılmaktadır [2, 3]. YSA'lar kendi kendilerine öğrenebilmeleri, hata toleransları ve en uygunu arama yeteneklerinden dolayı her geçen gün daha fazla ilgi çekmektedirler. YSA'lar paralel çalışan, lineer olmayan ve biyolojik sinir ağlarına benzer bir desende düzenlenmiş çok sayıda hesap elemanından oluşurlar. Tepkilerini buldukları ortama göre değiştirirler, deneyimlerden öğrenirler ve daha önceki örneklerden yenilerine genelleme yaparlar. Özörgütlemeli harita (SOM) ağları yarışmacı

öğrenme algoritmasını kullanan danışmansız bir YSA türüdür. SOM ağlarının diğer YSA türlerine göre otomatik olarak benzerlik diyagramları oluşturabilme gibi avantajları vardır [4].

Piksel tabanlı YSA'lar görüntüyü dokulara ya da doku ve yerel şekillerin bileşimine göre sınıflamak üzere eğitilirler. Çoğu piksel-tabanlı bölütleme yaklaşımının yoksun olduğu özellik, dönmelerin ve ölçek değişikliklerinin başarıyla üstesinden gelmektir. Bu eksiklik bölütleme sonuçlarını kötüleştirir [2]. Özellik-tabanlı yaklaşımda YSA'lar görüntüyü bölütlemek için doku ve yerel şekillerin bileşimindeki farkları temel alarak eğitilirler. Özellik-tabanlı bir YSA tarafından gerçekleştirilen bir bölütlemeye en çok dokular arasındaki farkı bulma görevi gerçekleştirilir. Bu işlem için öncelikle görüntüden özellik çıkartılması gerekmektedir. *Özellik çıkartma* görüntü verisine dayalı bilgilendirici değişkenler kümesinin bulunmasıdır. Görüntü verisi doğası gereği çok yüksek boyutlu olduğundan ve pikselin gri-seviyesi değeri her zaman için bölütlemeye yeterli bilgiyi taşımadığından başarılı bir bölütleme yapmak için görüntüden özellik çıkartma gerçekleştirilmesi gereken bir aşamadır [5].

Doğru ve güvenilir bir bölütlemeyi başarabilmek için YSA'larda giriş olarak kullanılacak ve bölütlenecek dokuları en iyi şekilde temsil eden özelliklerin seçilmesi büyük önem arz etmektedir. Görüntü bölütlemeye kullanılan özellikler genellikle yoğunluk, desen, şekil vb.dir. Doku, görüntülerin yorumlanması ve görüntü içindeki objelerin tanımlanmasında kullanılan önemli bir özelliktir [6]. Doku parametreleri bir banttaki tonal değişimin mekansal dağılımı hakkında bilgi vermektedir. Renk düzeyleri arasındaki ilişkiyi ve komşu hücrelerdeki değerler arasındaki ilişkiyi dikkate almaktadır. GLCM, doku analizi için bilinen en iyi araçlardan biridir ve yaygın olarak kullanılmaktadır. Görüntü özelliklerini ikili piksel grupları arasındaki gri seviyesi değişimlerinin farklı kombinasyonları ile ilişkili olarak tahmin eder. GLCM kullanılarak çıkarılan ve ikinci dereceden istatistik özellikler olarak da bilinen enerji, entropi, karşılık gibi özellikler görüntü sınıflama ve bölütleme gibi uygulamalarda kullanılabilir [7-10].

Örneğin, Amornrit ve diğerleri sonar görüntülerindeki boru hatlarını tespit ve takip etmek için GLCM ve SOM yöntemlerini kullanmışlardır. GLCM kullanarak görüntüyü tek düze doku bölgelerine dönüştürmüş ve SOM ile görüntüdeki boru hattı alanlarını belirlemişlerdir [11]. Siqueira ve diğerleri GLCM kullanarak elde ettikleri ikinci dereceden istatistik özellikleri SOM ağında giriş olarak kullandıkları çalışmalarında ekokardiyografik görüntü dizilerini bölütlemişlerdir [12]. Zizzari ve diğerleri ise dijital beyin görüntülerinden GLCM ile çeşitli doku özellikleri çıkarmışlar, bu özellikler içinden önemli olanlarını seçtikten sonra SOM ile doku analizi ve sınıflandırmasını gerçekleştirmişlerdir [13].

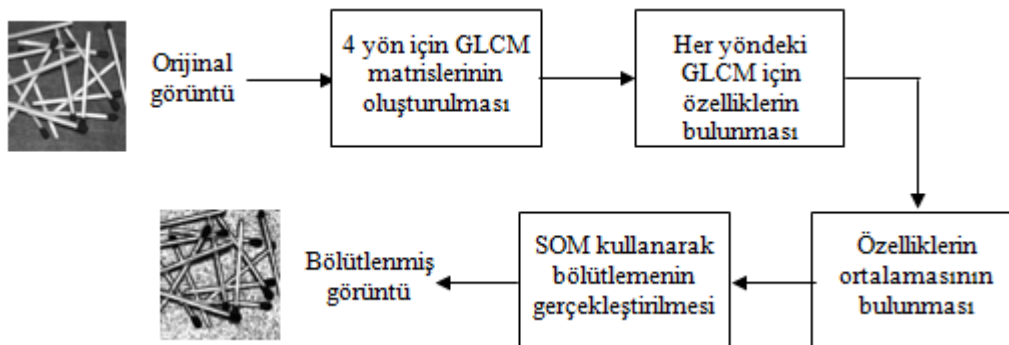
Bu çalışmada görüntü bölütleme işlemini gerçekleştirmek amacıyla geliştirilen sistemin işlem adımları Şekil 1'de gösterilmiştir. Öncelikle görüntüdeki doku özelliklerini ortaya çıkarmak için görüntü üzerinde 5×5 boyutlarında bir pencere gezdirilerek pencerenin merkezindeki her piksel için 0°, 45°, 90° ve 135° yönlerinde 4 adet GLCM hesaplanmıştır. Hesaplanan GLCM'lerden enerji, karşılık, korelasyon, homojenlik ve entropi özellikleri bulunmuştur. Bulunan özelliklerin yönden bağımsız olmasını sağlamak amacıyla 4 farklı yönde bulunan özelliklerin ortalaması alınmıştır. Elde edilen özellikler SOM ağında giriş olarak kullanılmıştır. Görüntülerin bölütlenmesi işlemi SOM tarafından gerçekleştirilmiştir.

2. MATERYAL ve METOT (MATERIAL AND METHOD)

2.1. Gri Düzey Eş Oluşum Matrisleri (Gray Level Co-Occurrence Matrices)

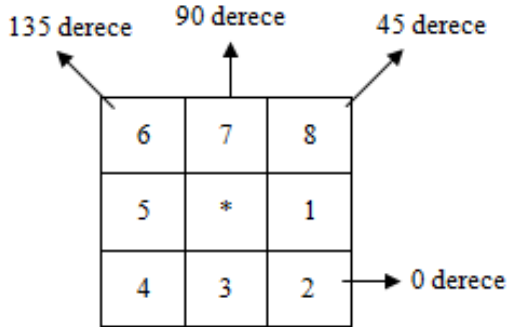
Doku, bir desen ya da desenlerin bir bölge üzerinde tekrarlanmasıdır. Bu desenler nitelik bakımından ince, kaba, pürüzsüz, rasgele ya da çizgili gibi değişik özelliklerde olabilirler. Doku özellikleri ikinci dereceden bir istatistik türüdür. Farklı yerlerdeki iki farklı piksel arasındaki gri seviyesi farklılıkları karşılaştırılır. Farklı dokular, doku özellikleri ortaya çıkarılarak bulunabilir. Doku özellikleri, GLCM, birinci dereceden eğim dağılımları, kenar eş oluşum matrisleri gibi çeşitli yollarla bulunabilir.

Bu çalışmada doku özellikleri Haralick [6] tarafından



Şekil 1. Geliştirilen sistemin akış diyagramı (Flowchart of the developed system)

tanımlanan GLCM kullanılarak ortaya çıkarılmıştır. GLCM ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonunun, $P(i, j | d, \theta)$, tahminine dayanır. Bu matris pikseller arasındaki uzaklık d ve açı θ iken gri seviyesi i 'den gri seviyesi j 'ye geçme olasılığını gösterir. Kare matris kullanılır ve desen özelliklerinin dönme ile değişmediğini garantilemek için genellikle $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° olacak şekilde dört yönde inceleme yapılır (Şekil 2). Haralick bu dört yön için bulunan GLCM'den elde edilen özelliklerin ortalamasının alınmasını önermiştir. Uzaklık olarak genellikle $d = 1, 2$ değerleri tercih edilir.



Şekil 2. Gri Düzey Eş Oluşum Matrisi (Gray Level Co-Occurrence Matrix)

Bu çalışma için 5×5 boyutundaki pencere görüntüler üzerinde gezdirilerek $d = 1$ ve $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° değerleri ile GLCM'ler oluşturulmuştur. Bu matrislerden görüntünün doku karakteristiğini içeren enerji, karşıtlık, korelasyon, homojenlik ve entropi olmak üzere 5 adet özellik bulunmuştur.

$$1. \text{ Enerji, } \sum_{i,j} P_{ij}^2 \quad (1)$$

$$2. \text{ Karşıtlık, } \sum_{i,j} |i - j|^2 P_{ij} \quad (2)$$

$$3. \text{ Korelasyon, } \frac{\sum_{i,j} (ij) P_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

$$4. \text{ Homojenlik, } \sum_{i,j} \frac{P_{ij}}{1 + |i - j|} \quad (4)$$

$$5. \text{ Entropi, } - \sum_{i,j} P_{ij} \log P_{ij} \quad (5)$$

Buradaki μ_x, μ_y, σ_x ve σ_y değerleri, olasılık yoğunluk fonksiyonu P_{ij} 'nin satırları ve sütunlarının ortalaması ve standart sapmasıdır.

GLCM'den elde edilen enerji özelliği görüntüdeki homojenliğin bir ölçüsüdür. Tekdüzelik veya açısız


ikinci moment olarak da bilinir. Sabit görüntüler için enerji 1'dir. Karşıtlık özelliği görüntüde bulunan yerel değişimlerin miktarını gösterir. Bir piksel ve komşusu arasındaki yoğunluk zıtlığıdır. Sabit görüntülerde karşıtlık 0'dır. Korelasyon özelliği görüntüdeki gri seviyesi lineer bağımlılıklarının bir ölçüsüdür. Bir piksel ve komşusunun birbiriyle nasıl ilişkili olduğunu gösterir. Korelasyon özelliği birbirleriyle tamamen pozitif ilişkili görüntülerde 1 ve tamamen negatif ilişkili görüntülerde ise -1'dir. Homojenlik özelliği GLCM'deki elemanların dağılımının diyagonal GLCM'deki elemanların dağılımına yakınlığının bir ölçüsüdür. Entropi özelliği ise görüntüde bulunan gri seviyelerinin uzaysal düzensizliğinin düzeyini gösterir.

2.2. Özörgütlemeli Harita Ağları (Self-Organizing Map Networks)

Özörgütlemeli harita (SOM) ağları 1982'de Kohonen tarafından geliştirilmiştir [14]. Danışmansız bir yapay sinir ağıdır. Yarışmacı öğrenme algoritmasını kullanır. Yarışmacı öğrenme algoritmasında ağı çıkış nöronları aktive edilmek için kendi aralarında yarışır. Sonuçta aynı anda yalnızca bir çıkış nöronu kazanarak aktive edilir. Yarışmayı kazanan çıkış nöronuna *kazanan-her şeyi-alır nöronu* ya da basitçe *kazanan nöron* denir [15]. SOM'un temel hedefi herhangi bir boyuttaki girdi sinyal desenini bir ya da iki-boyutlu bir ayrık haritaya dönüştürmek ve bu dönüşümü topografik olarak düzenli bir biçimde adaptif olarak gerçekleştirmektir. SOM ağını sağlayan algoritmanın işlem adımları [4] ve [16]'deki gibidir.

Görüntü bölütleme teknikleri, görüntüdeki her pikselin yüzey özelliklerine göre bir özellik vektörü ile ilişkilendirilerek özellik vektörlerinin kümelenebileceği temeline dayanır. $N_x \times N_y$ boyutlarındaki giriş görüntüsü $\{z = f(x,y)\}$, M adet bölgeden oluşan kümeye haritalanır, $R = \{R_i; 1 \leq i \leq M\}$. SOM ağı bu haritalamayı öğrenmek veya belirlemek için kullanılır.


Bir SOM'da nöronlar genellikle bir ya da iki boyutlu bir *ızgaranın* düğümleri olarak yerleştirilmiştir. Yüksek boyutlu haritalar da mümkündür fakat genel değildir. Şekil 3'te SOM ağı yapısını görülmektedir. Bu ağ satırlar ve sütunlar şeklinde düzenlenmiş nöronlar içeren tek bir hesapsal katmanı olan ileri



Şekil 3. SOM ağı yapısı (SOM network structure)

beslemeli bir yapıyı göstermektedir. Basit bir SOM ağı iki katmandan oluşur. İlk katman giriş düğümleridir ve ikinci katman ise çıkış düğümlerini içerir. Çıkış düğümleri Şekil 3'te gösterildiği gibi iki boyutlu bir ızgara görüntüsündedir. Her giriş nöronu her çıkış nöronuna ayarlanabilen ağırlıklarla bağlıdır [15].

Ağırlık vektörünün başlangıç değerleri rasgeledir. Ağırlıklar girişin ağı tarafından öğrenilmesi ile ayarlanır. Girişe en iyi cevabı veren işlem elamanı etrafında bir $N_c(t)$ komşuluk kümesi oluşur. Komşuluk kümesi iki boyutlu, dikdörtgen, altıgen vb. yapılarda oluşabilir. Herhangi bir çıkış işlem elamanının, verilen bir dairesel yarıçap ile bütün komşulukları belirlenebilir. Ağırlık vektörünün başlangıçtaki keyfi dağılımı, giriş örüntü vektörlerinin ağı tarafından öğrenilmeye başlanması ile kendi kendine ayarlanır. Şekil 4'te bir nöronun yapısal komşuluğunu gösterilmektedir [17].



Şekil 4. Bir nöronun yapısal komşuluğu ($t_1 < t_2 < t_3$) (a) dikdörtgen komşuluk (b) altıgen komşuluk (Structural neighbourhood of a neuron ($t_1 < t_2 < t_3$) (a) rectangle neighbourhood (b) hexagon neighbourhood)

SOM ağının kalitesini ölçmek için topolojinin çözünürlüğü ve korunması gibi çeşitli değerlendirme kriterleri kullanılmaktadır. SOM'un çözünürlüğünü değerlendirmek için yaygın olarak kullanılan bir metot *ortalama nicemleme hatasının* (Q_{err}) bulunmasıdır. Bu hata her veri vektörü ve onun en iyi uyan birimi (Best Matching Unit-BMU) arasındaki ortalama mesafeyi ölçer. Nicemleme hatası Eşitlik 6'daki gibi bulunur. Burada N veri vektörlerinin sayısı ve $m_{\vec{x}_i}$ ise \vec{x}_i veri vektörüne ilişkin en iyi uyan prototiptir. Bu hata sinir haritasının veriye uygunluğunu ölçer. Böylece en uygun harita en düşük nicemleme hatasına sahip olmalıdır [18].

$$Q_{err} = \frac{1}{N} \sum \|\vec{x}_i - m_{\vec{x}_i}\| \quad (6)$$

Nicemleme hatasına ek olarak SOM'un kalitesini değerlendirmek üzere bir hata kriteri olarak Kohonen tarafından da önerilen [4] *topolojik hata* (T_{err}) topolojinin korunmasını tespit etmek amacıyla hesaplanmaktadır. Bu hata birinci ve ikinci BMU'ları birbirine komşu olmayan tüm veri vektörlerinin oranıdır. Topolojik hata ne kadar düşük olursa SOM topolojisi o oranda korumuş demektir. Topolojik hata Eşitlik 7'deki gibi hesaplanmaktadır. Burada $u(\vec{x}_i)$ fonk-

siyonu \vec{x}_i veri vektörünün birinci ve ikinci BMU'ları komşu olduğunda 1, diğer durumlarda 0'dır [18].

$$T_{err} = \frac{1}{N} \sum_{i=1}^N u(\vec{x}_i) \quad (7)$$

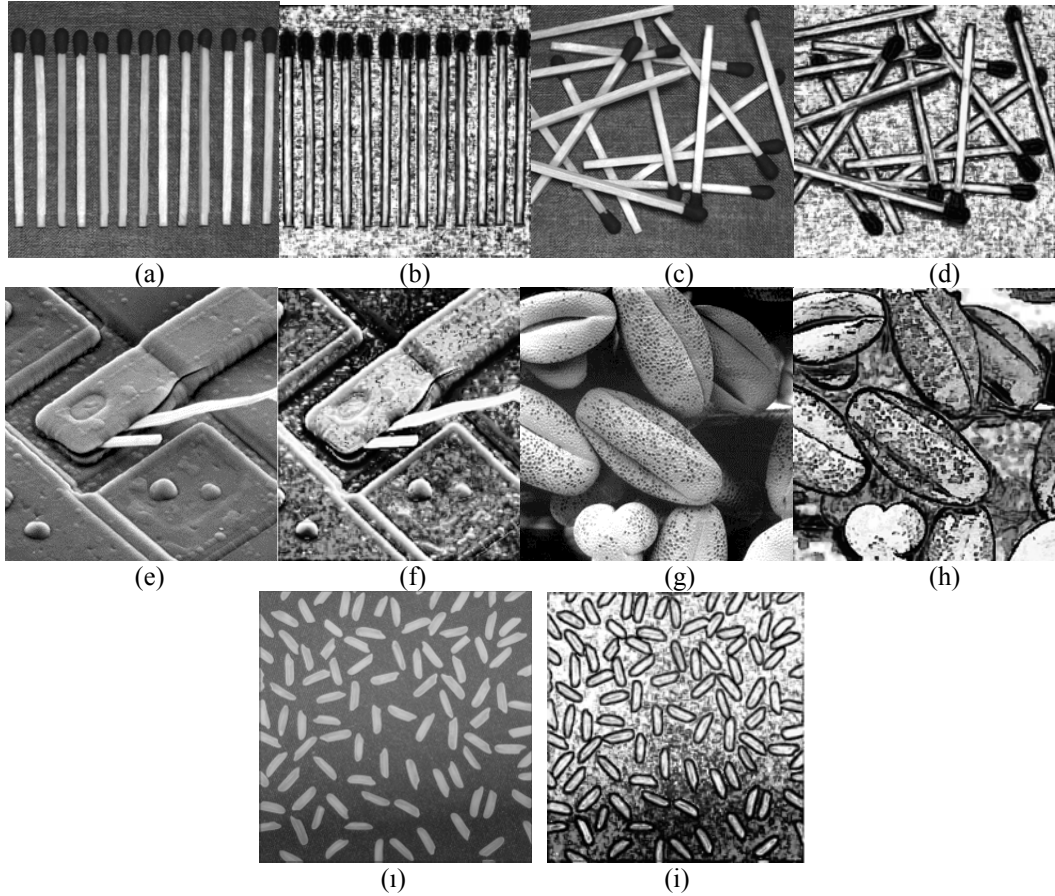
Bu çalışmada önerilen sistemin orijinal görüntüleri bölütlemeye gösterdiği performansı değerlendirmek üzere bölütleme işlemi sonucunda elde edilen görüntülerin incelenmesi ile birlikte, bölütleme işlemini gerçekleştiren SOM'un bu görevdeki performansı da nicemleme ve topolojik hata kriterleri kullanılarak incelenmiştir. Kullanılan SOM'un görüntüleri bölütleme işlemine uygunluğu hesaplanırken nicemleme ve topolojik hatanın performans incelemesine eşit oranlarda katkı sağlaması amacıyla %50 oranında nicemleme hatası ve %50 oranında da topolojik hatanın değerlendirmeye katıldığı Eşitlik 8 kullanılmıştır.

$$Uygunluk = 1 - (0.5 * Q_{err} + 0.5 * T_{err}) \quad (8)$$

3. SONUÇLAR VE İRDELEME (RESULTS AND DISCUSSIONS)

Bu çalışmada SOM ağları ve GLCM'nin görüntü bölütlemesindeki performansları incelenmiştir. Sistemin performansını test etmek üzere çeşitli özelliklerde test görüntüleri kullanılmıştır [19]. Bu çalışma için seçilen Şekil 5(a) ve (c)'deki hizalanmış ve dağınık kibrit çöplerinin oluşturduğu test görüntüleri benzer histogramlara sahiptir. Geliştirilen sistemin görüntüdeki homojen bölgeleri izole etme, bu bölgeler arasındaki sınırları bulma ve farklı dokulara sahip nesnelere ayırt etme kapasitesinin nesnelere uzaysal yerleşiminden bağımsız olduğunu göstermek üzere bu görüntüler seçilmiştir. Şekil 5(e)'deki tarama elektron mikroskopundan elde edilmiş hasarlı entegre devre görüntüsü $\pm 45^\circ$ yönlerinde kenarlara sahiptir. Bölütleme işlemi sonunda nesnelere kenarlarının ve dış hatlarının daha belirginleştirildiği ve anlaşılır hale getirildiğini göstermek üzere bu görüntü iyi bir örnektir. Şekil 5(g)'deki polenin elektron mikroskopundaki görüntüsünün histogramı gri seviyesinin tüm spektrumuna yayılan, histogramı eşitlenmiş bir görüntüdür. Şekil bilgisinin kullanılmadığı görüntü bölütleme uygulamalarında piksel değerlerinin istatistiksel dağılımları önemli rol oynadığından geliştirilen bölütleme sisteminin bölge sınırlarının bulunmasında histogramı eşit dağılmış görüntülerdeki etkililiğini gözlemek üzere bu görüntü seçilmiştir. Şekil 5(i)'deki pirinç taneleri görüntüsü ise bir zemin üzerinde bulunan nesnelere arka plandan bölütleme ile ayrılabilirliğini göstermek üzere kullanılmıştır.

Görüntülerin bölütlenmesi işleminde öncelikle görüntüye 5×5 boyutlarında pencereleme işlemi uygulanmıştır. Pencerenin merkezindeki her piksel için $d = 1$ uzaklık ve $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° açı değerleriyle 4



Şekil 5. Sistemi test etmek için kullanılan görüntüler ve uygulama sonucunda elde edilen bölütlenmiş görüntüler (Images used to test the system and segmented images obtained from application results)

farklı yön için GLCM hesaplanmıştır. GLCM'nin 4 yön için hesaplanmasındaki amaç görüntüden elde edilecek özelliklerin görüntüdeki doku ve nesnelerin uzaysal yerleşimlerinden ve açıdan bağımsız olarak bulunmasını sağlamaktır. GLCM'nin hesaplanmasında pikseller arasındaki uzaklık olan d parametresinin uygun bir değer seçilmesi incelenen görüntüde bulunan dokuların kalınlığı veya inceliği ile yakından ilişkili olduğundan önem taşımaktadır. Doku ne kadar kabaysa pikseller arasındaki uzaklık da o derecede artırılabilir. Doğal bir görünümde çok çeşitli kalınlık ve incelikte çok sayıda doku bulunabilir. Bu çalışmada görüntülerde bulunan ince, detaylı dokuları da tespit edebilmek üzere uzaklık parametresi 1 olarak seçilmiştir.

Hesaplanan GLCM'ler normalize edilmiş ve her biri için görüntüde bulunan farklı dokuları tespit edebilmek amacıyla enerji, karışıklık, korelasyon, homojenlik ve entropi özellikleri bulunmuştur. 4 farklı yön için ayrı ayrı bulunan bu özelliklerin ortalamaları alınarak elde edilen özelliklerin yönden bağımsız olması sağlanmıştır. Daha sonra bu değerlerin $[0, 1]$ aralığında normalizasyonu yapılmış ve özellik vektörü olarak SOM ağına girdi olarak kullanılmıştır.

SOM ağı MATLAB yazılım paketi için geliştirilmiş olan *SOM Toolbox* kullanılarak oluşturulmuştur [20]. Ağ oluşturulurken öncelikle ağdaki birim sayısının

belirlenmesi gerekmektedir. SOM'daki çıkış nöronlarının sayısı verideki sapmaları tespit edebilmek için önemlidir. SOM'daki çıkış nöronlarının sayısı Vesanto ve diğerleri tarafından önerilen sezgisel kural kullanılarak seçilmiştir [21]. Bu kurala göre harita birimlerinin en uygun sayısı $5\sqrt{n}$ 'dir. Burada n , eğitim örneklerinin sayısıdır. Ağın boyutlarının belirlenmesi için eğitim verisinde bulunan en büyük iki öz değer (eigen-value) arasındaki oran hesaplanmıştır ve ağın kenar uzunlukları olarak atanmıştır. Kenar uzunluklarının çarpımı Vesanto ve diğerlerinin önerdiği harita birimi sayısına yakın olmuştur [21]. Ağın başlangıç durumuna getirilmesi işlemi lineer olarak yapılmıştır. Ağ başlangıç durumuna getirildikten sonra eğitim kaba ve ince ayar olmak üzere iki aşamada gerçekleştirilmiştir. Ağın eğitilmesi için ardışık eğitime göre daha hızlı çalışan toplu eğitim yöntemi tercih edilmiştir. Oluşturulan SOM ağının görüntüleri bölütlemeye gösterdiği performansı değerlendirmek için topolojik hata (T_{err}) ve nicemleme hatası (Q_{err}) birlikte kullanılarak ağın uygunluğu Eşitlik 8'e göre hesaplanmıştır.

Görüntü analizinin çeşitli aşamalarında kullanılan Şekil 5(a,c,e,g,i)'daki test görüntülerine önerilen sistem uygulandığında ağdan elde edilen bölütleme sonuçları Şekil 5(b,d,f,h,i)'de verilmiştir.

Geliştirilen görüntü bölütleme sisteminde Şekil 5'te görülen test görüntülerinden GLCM'ler hesaplanmış, bu GLCM'lerden elde edilen ikinci dereceden istatistik özellikler olan enerji, karşıtlık, korelasyon, homojenlik ve entropi özellikleri SOM ağına girişinde özellik vektörü olarak kullanılmıştır. Elde edilen sonuçlar ağına uygunluğu açısından Eşitlik 6-8'de belirtildiği gibi hesaplanarak Çizelge 1'de verilmiştir.

Çizelge 1. Sistemden elde edilen test görüntülerini bölütleme performansı (Segmentation performance of the system on test images)

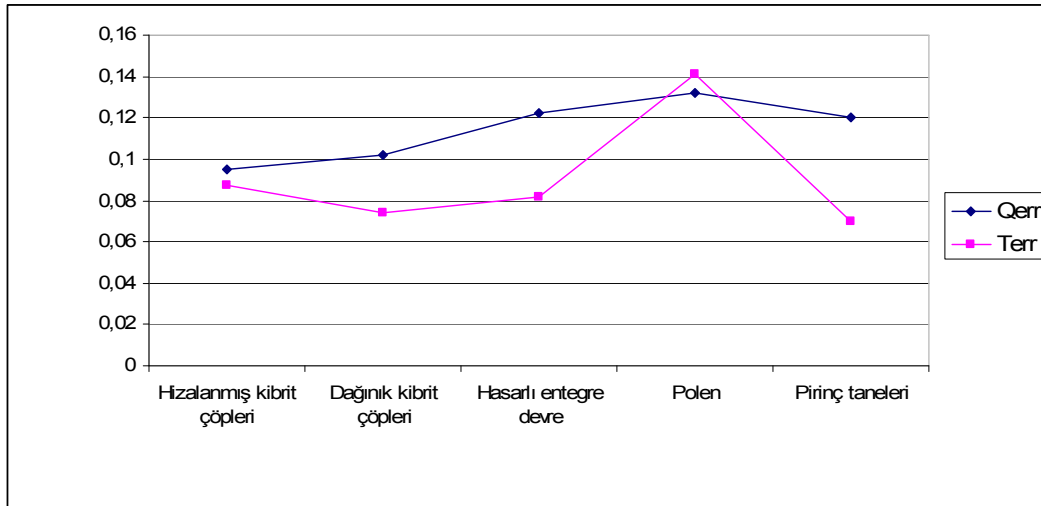
Test Görüntüsü	Q_{err}	T_{err}	Uygunluk
Hızalanmış kibrit çöpleri	0.095	0.087	0.9088
Dağınık kibrit çöpleri	0.102	0.074	0.9123
Hasarlı entegre devre	0.122	0.082	0.8980
Polen	0.132	0.141	0.8635
Pirinç taneleri	0.120	0.070	0.9051

Bu çizelgeden de görüldüğü üzere geliştirilen sistem hızlı ve dağınık yerleştirilmiş, küçük ve büyük boyutlarda nesnelere içeren, farklı gri seviyesi dağılımlarına sahip test görüntüleri üzerinde yaklaşık %90 oranında bölütleme performansı göstermiştir. Çizelge 1'de görülen ağ hata değerleri T_{err} ve Q_{err} Şekil 6'da grafik olarak sunulmuştur. Şekil 6'da görüldüğü gibi en yüksek bölütleme hatası polen görüntüsünde ortaya çıkmıştır. Bunun nedeni polen görüntüsünün diğer görüntülere göre daha yüksek karşıtlıkta olması ve geniş aralığa yayılmış bir histograma sahip olmasıdır.

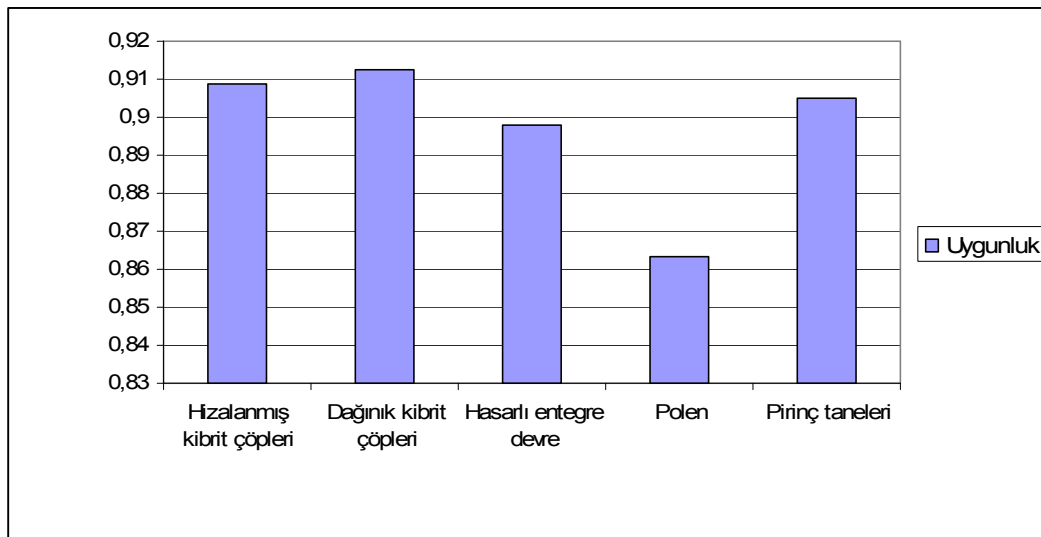
Şekil 7'de sistemin test görüntülerini bölütlemeye gösterdiği performans grafik olarak verilmiştir.

Şekil 7'de görüldüğü gibi en yüksek bölütleme performansı dağınık kibrit çöpleri görüntüsünden elde edilirken, en düşük bölütleme performansı polen görüntüsünden elde edilmiştir.

Geliştirilen sistemden elde edilen hata değerleri ile bölütleme performansları değerlendirildiğinde GLCM



Şekil 6. Bölütleme sonucunda elde edilen ağ hata değerleri (Network error values obtained from segmentation)



Şekil 7. Sistemden elde edilen bölütleme performansı (Segmentation performance obtained from the system)

ve SOM ağları yöntemlerini kullanan bir görüntü bölütleme sistemin görüntü analizi uygulamalarında etkin olarak kullanılabilceği görülmektedir.

KAYNAKLAR (REFERENCES)

1. Koh, J., Suk, M., Bhandarkar, S.M., "A multi-layer Kohonen's self-organizing feature map for range image segmentation", **IEEE International Conference on Neural Networks**, San Francisco, CA, USA, vol.3., 1270-1275, 1993.
2. Egmont-Petersen, M., Ridder, D., Handels, H., "Image Processing with Neural Networks-a Review", **Pattern Recognition**, Vol.35, 2279-2301, 2002.
3. Murino V., Vernazza G., "Artificial Neural Networks for Image Analysis and Computer Vision", **Image and Vision Computing**, Vol.19, Num.9, 583-584, 2001.
4. Kohonen, T., "The Self-Organizing Map", **Proceedings of Institute of Electrical and Electronics Engineers**, Vol.78, 1464-1480, 1990.
5. Güler, İ., Demirhan, A., Karakış, R., "Interpretation of MR images using self-organizing maps and knowledge-based expert systems", **Digital Signal Processing**, In Press, doi:10.1016/j.dsp.2008.08.002, 2009.
6. Haralick, R.M., Shanmugam, K. ve Dinstein, I., "Textural Features for Image Classification", **IEEE Transactions on Systems, Man and Cybernetics**, Vol. SMC-3, No.6, 610-621, 1973.
7. Beliaikov, G., James, S. ve Troiano, L., "Texture recognition by using GLCM and various aggregation functions", **IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2008)**, Hong Kong, 1472-1476, 2008.
8. Baraldi, A., Parmiggiani, F., "An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters", **IEEE Transactions on Geoscience and Remote Sensing**, 33(2), 293-304, 1995.
9. Zaim, A., Sawalha, A., Quweider, M., Iglesias, J., Tang, R., "A New Method for Iris Recognition using Gray-Level Cooccurrence Matrix", **IEEE International Conference on Electro/information Technology**, Michigan, U.S.A, 350-353, 2006.
10. Hu, Y., Zhao, C., Wang, H., "Directional Analysis of Texture Images Using Gray Level Co-Occurrence Matrix", **2008 IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application**, Wuhan, China, Vol. 2, 277-281, 2008.
11. Amornrit, P., Jouvencel, B., Tomas, S., "A new method of pipeline detection in sonar imagery using Self-Organizing Maps", **IEEE/RSJ International Conference on Intelligent Robots and Systems, (IROS 2003)**, Nevada, Vol.1, 541-546, 2003.
12. Siqueira, M.L., Gasperin, C.V., Scharcanski, J., Zielinsky, P., Navaux, P.O.A., "Echocardiographic image sequence segmentation using self-organizing maps", **Neural Networks for Signal Processing X, Proceedings of the 2000 IEEE Signal Processing Society Workshop**, Sydney, Australia, Vol.2, 594-603, 2000.
13. Zizzari, A., Seiffert, U., Michaelis, B., Gademann, G., Swiderski, S., "Detection of tumor in digital images of the brain", **Proceedings of the International Conference on Signal Processing, Pattern Recognition and Applications**, Rhodes, Greece, 132-137, 2001.
14. Kohonen, T., "Self-Organizing Formation of Topologically Correct Feature Maps", **Biological Cybernetics**, 43(1), 59-69, 1982.
15. Haykin, S., **Neural Networks: A Comprehensive Foundation**, Prentice-Hall, New Jersey, 1999.
16. Şengür, A., Türkoğlu, İ., ve İnce, M.C., "Eğiticiyiz Yapay Sinir Ağları ile Görüntü Bölütme Uygulamaları", **IEEE 13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, (SIU 2005)**, 271-274, Kayseri, 2005.
17. Kotropoulos, C., Pitas, I., "Self-Organizing Maps and Their Applications in Image Processing, Information Organization, and Retrieval", **Nonlinear Signal and Image Processing**, Editör: Barner, K.E, Arce, G.E., CRC Press, 387-444, 2004.
18. Uriarte, E.A. ve Martín, F.D., "Topology Preservation in SOM", **Proceedings of World Academy Of Science, Engineering And Technology**, Vol.15, 187-190, 2006.
19. Gonzales, R.C., Woods, R.E., **Digital Image Processing**, Prentice Hall, New Jersey, 2002.
20. İnternet: **Helsinki University of Technology**, Department of Computer Science and Engineering, "SOM Toolbox", <http://www.cis.hut.fi/projects/somtoolbox/>, 2005.
21. Vesanto, J., Himberg, J., Alhoniemi, E., Parhankangas, J., "SOM Toolbox for Matlab 5", Technical Report A57, **Neural Networks Research Centre, Helsinki University of Technology**, Helsinki, Finland, 2000.