

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**ÇOK DEĞİŞKENLİ GAUSS KARIŞIM MODELLEME
YÖNTEMİYLE GÖRSEL DOKU ANALİZİ**

**YÜKSEK LİSANS TEZİ
Yiğitcan SAVRAN**

Anabilim Dalı : Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Programı : Telekomünikasyon Mühendisliği

TEMMUZ 2009

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**ÇOK DEĞİKENLİ GAUSS KARIŞIM MODELLEME
YÖNTEMİYLE GÖRSEL DOKU ANALİZİ**

YÜKSEK LİSANS TEZİ
Yiğitcan SAVRAN
(504061353)

Tezin Enstitüye Verildiği Tarih : 4 Mayıs 2009

Tezin Savunulduğu Tarih : 29 Temmuz 2009

Tez Danışmanı : Prof. Dr. Bilge GÜNSEL (İTÜ)
Diğer Jüri Üyeleri : Prof. Dr. Melih PAZARCI (İTÜ)
Doç. Dr. Zehra ÇATALTEPE (İTÜ)

TEMMUZ 2009

ÖNSÖZ

Yüksek lisans süresince her türlü bilgisini benimle paylaşan danışmanım Prof. Dr. Bilge GÜNSEL'e çok teşekkür ederim. Ayrıca Çoğul Ortam Sinyal İşleme ve Örüntü Tanıma Laboratuvar'ındaki arkadaşlarıma ve aileme teşekkürlerimi sunarım.

Temmuz 2009

Yiğitcan SAVRAN

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iii
İÇİNDEKİLER	v
KISALTMALAR	vii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	xi
ÖZET.....	xiii
SUMMARY	xv
1. GİRİŞ.....	1
2. GÖRSEL DOKU SINIFLAMA	5
2.1 Çok Değişkenli Gauss Karışım Modeli	6
2.2 Beklenen Değeri En Büyükleme	7
2.3 Çok Değişkenli Gauss Karışım Modeliyle Görsel Doku Sınıflama	7
2.3.1 Eğitim aşaması	7
2.3.2 Sınıflandırma aşaması	10
3. GABOR ÖZNİTELİKLERİ KULLANARAK GAUSS KARIŞIM MODELLEME YÖNTEMİYLE DOKU SINIFLAMA	13
3.1 Gabor Dalgacık Fonksiyonu Matematiksel Formülasyonu	14
3.2 Gabor Uzayında Öznitelik Çıkarımı ve Doku Modelleme	20
3.2.1 Örneklem oluşturma	20
3.2.1.1 Tek kanalda örneklem oluşturma	21
3.2.1.2 Çok kanallı örneklem oluşturma	21
3.2.2 Gabor uzayında doku modelleme	22
3.3 Görsel Doku Sınıflama	24
4. TESTLER.....	25
4.1 İkili Sınıflama Testleri	26
4.1.1 Food0005-Sand0000 görüntüleri için yapılan sınıflama testleri	26
4.1.2 Water0006 ve Water0007 görüntüleri için yapılan testler	29
4.1.3 Fabric0010 ve Fabric0016 görüntüleri için yapılan testler	31
4.2 Üçlü Sınıflama Testi.....	35
4.2.1 Fabric0010-Fabric0002-Fabric0016 görüntüleri için yapılan testler.....	36
4.2.2 Flowers0007-Fabric0014-Water0006 görüntüleri için yapılan testler	38
4.3 Dörtlü Sınıflama Testleri	41
4.3.1 Food5-Fabric10-Fabric14-Water7 görüntüleri için yapılan testler	41
4.4 [17] Nolu Referans Makalesi İle Karşılaştırma Sonuçları	44
5. SONUÇLAR VE ÖNERİLER	47
KAYNAKLAR	49

KISALTMALAR

BMP	: Bitmap
DC	: Direct Current
MIT	: Massachusetts Institute of Technology
EM	: Expectation Maximization

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 1.1 : Bazı Haralick doku öznitelikleri	2
Çizelge 4.1 : (d) ve (e) şıkları için hata matrisi(Confussion Matrix)	37
Çizelge 4.2 : (d) ve (e) şıkları için hata matrisi(Confussion Matrix)	42

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Sistem eğitim aşaması	8
Şekil 2.2 : Sınıflama aşaması blok şeması	10
Şekil 3.1 : Bir Boyutta a) Gauss fonksiyonu, b) Sinüsoidal fonksiyon, c) Gabor fonksiyonu [23].....	15
Şekil 3.2 : Bir boyutta a) Gauss fonksiyonu, b) x eksenine göre 30° döndürülmüş iki boyutlu sinüsoidal fonksiyon, c) Gabor fonksiyonu gerçel kısmı [23]....	15
Şekil 3.3 : Gabor çekirdeklerinin frekans uzayını tarama alanı. Merkez frekans (64, 64) nolu pikseldir. (satır, sütun)	16
Şekil 3.4 : Birinci satır Gabor dalgacık fonksiyonu çekirdekleri gerçel kısmı. İkinci satır Gabor dalgacık fonksiyonu çekirdekleri sanal kısmı	18
Şekil 3.5 : Gabor dalgacık fonksiyonu: a) gerçel kısım, b) sanal kısım	18
Şekil 3.6 : Şekil 1’de verilen Gabor dalgacık fonksiyonunun frekans uzayında transfer fonksiyonları	19
Şekil 3.7 : a) Giriş görüntüsü b) $O(x,y)$ ’nin gerçel kısmı c) $O(x,y)$ ’nin sanal kısmı d) $O(x,y)$ ’nin genlik görüntüsü	20
Şekil 3.8 : Tek kanalda örneklem oluşturma.....	21
Şekil 3.9 : Çok kanallı örneklem oluşturma.....	22
Şekil 4.1 : Yazılım kullanıcı ara yüzü	25
Şekil 4.2 : a) Food0005 görüntüsü, b) Sand0000 görüntüsü, c) Bileştirilmiş renkli görüntü, d) Birleştirilmiş gri düzey görüntü	27
Şekil 4.3 : Gri düzey kullanılarak alınan sonuçlar	27
Şekil 4.4 : Tek kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar	28
Şekil 4.5 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar.....	28
Şekil 4.6 : a) Water0006 görüntüsü b) Water0007 görüntüsü c) Bileştirilmiş renkli görüntü d) Birleştirilmiş gri düzey görüntü	29
Şekil 4.7 : Gri düzey kullanılarak alınan sonuçlar	30
Şekil 4.8 : Tek kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar	30
Şekil 4.9 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar.....	31
Şekil 4.10 : a) Fabric.0010 görüntüsü b) Fabric.0016 görüntüsü c) Bileştirilmiş renkli görüntü d) Birleştirilmiş gri düzey görüntü.....	31
Şekil 4.11 : Gri düzey kullanılarak alınan sonuçlar	32
Şekil 4.12 : Tek kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar	33
Şekil 4.13 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar.....	33
Şekil 4.14 : Gauss karışım sayısının başarıma etkisi, birinci satır gri düzey sonuçlar ikinci satır tek kanallı Gabor öznitelikleri sonuçları, üçüncü satır çok kanalda Gabor öznitelikleri sonuçları	34
Şekil 4.15 : Uzamsal uzayda ve Gabor uzayında ortalama-standart sapma grafiği ..	34
Şekil 4.16 : Gabor uzayında oy çokluğu kuralıyla sınıflama	35
Şekil 4.17 : a) Fabric0010 görüntüsü, b) Fabric0002 görüntüsü, c) Fabric0016 görüntüsü, d) Bileştirilmiş renkli görüntü e) Birleştirilmiş gri düzey görüntü	36
Şekil 4.18 : Gri düzey kullanılarak alınan sonuçlar	36

Şekil 4.19: Tek kanalda Gabor öznitelikleri kullanılarak alınan sonuçlar	37
Şekil 4.20: Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar	38
Şekil 4.21 : a) Flowers0007 görüntüsü, b) Fabric0014 görüntüsü, c) Water0006 görüntüsü, d) Bileştirilmiş renkli görüntü e) Birleştirilmiş gri düzey görüntü	39
Şekil 4.22 : Gri düzey kullanılarak alınan sonuçlar	39
Şekil 4.23 : Tek kanalda Gabor öznitelikleri kullanılarak alınan sonuçlar	40
Şekil 4.24 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar	40
Şekil 4.25 : a) Food0005 görüntüsü, b) Fabric0010 görüntüsü, c) Fabric0014 görüntüsü, d) Water0007 görüntüsü e) Bileştirilmiş renkli görüntü f) Birleştirilmiş gri düzey görüntü	42
Şekil 4.26 : Gri düzey kullanılarak alınan sonuçlar	43
Şekil 4.27 : Tek kanalda Gabor öznitelikleri kullanılarak alınan sonuçlar	43
Şekil 4.28 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar	44
Şekil 4.29 : Food0005 Sand0000 görüntüleri sınıflama sonuçları, 1. satır [17]'de elde edilen sonuçlar, 2. satır Bölüm 4.1.1'de elde edilen sonuçlar	44
Şekil 4.30 : Water0006 Water0007 görüntüleri sınıflama sonuçları, 1. satır [17]'de elde edilen sonuçlar, 2. satır Bölüm 4.1.1'de elde edilen sonuçlar	45

ÇOK DEĞİŞKENLİ GAUSS KARIŞIM MODELLEME YÖNTEMİYLE GÖRSEL DOKU ANALİZİ

ÖZET

Bilgisayar tabanlı görüntü işleme uygulamalarında doku analizi, doku sınıflama, hata sezimi, nesne tanıma, nesne izleme ve doku bölütleme gibi birçok uygulamada temel oluşturmaktadır.

Görsel dokular, periyodik olmayan çok farklı renk ve biçimlerde olabilmektedir. Bu yönüyle karmaşık ve zorlayıcı bir konu olan görsel doku analizi geniş kullanım alanlarına sahip olmasıyla güncelliğini korumaktadır. Bu çalışmada, görsel dokuların çok farklı yapılarda olan özniteliklerinin çok ölçekli (multiscale) bir yapıda modellenmesi ve bu modeller kullanılarak görsel dokuların otomatik sınıflanması hedeflenmiştir. Bu amaçla görsel doku modellemesinde çok boyutlu Gauss karışım modeli kullanılmıştır. Gauss karışım model parametreleri, uzamsal uzay ve Gabor uzayı olmak üzere iki farklı uzayda çıkarılan öznitelikler kullanılarak, beklentiyi en büyükleme (EM) algoritmasıyla hesaplanmıştır. Gabor uzayı çok ölçekli analiz imkânı sunarak dokuların farklı frekans ve yönelim özniteliklerini inceleme fırsatı vermesi nedeniyle tercih edilmiştir.

Uzamsal uzayda yapılan doku modellemede görsel doku görüntülerinin gri düzey değerleri kullanılmıştır. Görsel dokuların tekrarlı veya tekrarlı olmayan özellikleri birçok küçük parçanın bir araya gelmesiyle bir bütünlük hissi yaratmaktadır. Bu nedenle Gauss karışım modeli parametreleri gri düzey görsel doku örnekleri örtüşen küçük kare yamalara bölünerek hesaplanmıştır. Görsel doku sınıflama, eğitim aşamasında her farklı doku için elde edilen Gauss karışım parametreleri kullanılarak, en büyük olabilirlik oranı kuralına göre yapılmıştır.

Doku analizinde sıkça kullanılan yöntemlerden biri de Gabor dalgacık fonksiyonu kullanarak öznitelik çıkarımıdır. Yapılan çalışmalarda Gabor dalgacık fonksiyonunun insan görme sistemini en iyi modelleyen süzgeçlerden biri olduğu belirtilmektedir. Gabor dalgacık fonksiyonları ile farklı yönelim ve ölçeklerde frekans uzayı özellikleri incelenebilmektedir. Bu çalışmada, yenilik olarak, aynı ölçekte farklı yönelimlerdeki özniteliklerin çok boyutlu Gauss karışım modeli yöntemi ile modellenmesi ve farklı yönelimdeki Gabor özniteliklerinin tümleştirilmesi denenmiştir. Eğitim aşamasında, Gabor özniteliklerinin çok değişkenli Gauss karışımı parametreleri beklenen değeri en büyükleme algoritması ile hesaplanmıştır. Görsel doku sınıflama eğitim aşamasında Gabor uzayında elde edilen Gauss karışım parametreleri kullanılarak en büyük olabilirlik oranı kuralına göre yapılmıştır.

Gabor süzgeçleriyle elde edilen öznitelikler C/C++ programlama dillerini kullanan bir yazılımla elde edilmiştir ve sınıflama algoritmaları Matlab'ta yazılan bir programla gerçekleştirilmiştir. İki sınıflama yöntemi farklı özellikteki görsel dokularda farklı başarımlarla çalışmaktadır. İki yöntemde iki dokulu sınıflama testlerinde %95'in üstünde başarımlar elde edilmiştir. Yönelimli dokularda ikinci yöntemin

daha yüksek başarılı sonuçlar verdiği durumlar bulunmuştur. Bazı dokuların Gabor uzayı öznitelikleri gri düzey özniteliklerine göre daha fazla yoğun (compact) bir yapıda olduğu görülmüştür. Bu ise daha az karmaşık Gauss karışım modelleri sağlamaktadır.

VISUAL TEXTURE ANALYSIS USING MULTIVARIATE GAUSSIAN MIXTURE METHOD

SUMMARY

Visual texture analysis is one of the most important topics in computer vision. Texture analysis comprises texture classification, texture segmentation, novelty detection, object recognition and object tracking problems.

Visual texture could be in variable shape, form and colors. Being a complex and challenging topic, visual texture analysis is an up to date subject with its wide spread application areas. The aim of this study is to model visual texture in a multiscale structure and classify visual textures automatically using these models. In order to model visual texture, multivariate Gaussian mixture model is used. Visual textures are modelled in two domains. First one is spatial domain and the second domain is Gabor space. Gabor wavelet functions which has the ability of analysing frequency domain in different orientations, provides a multiscale approach. Gaussian mixture parameters of visual texture is calculated by expectation maximization algorithm which is one of the most popular topics nowadays.

Modelling visual texture in spatial domain is done by using gray level values of visual texture images. All textures, periodic or unperiodic, have its common sense which is composed of its small components so that modelling is done by splitting visual texture images into small patches. Using these small patches by expectation maximization algorithm, multivariate Gaussian mixture parameters are calculated. Visual texture classification process is done according to the maximum likelihood ratio rule.

Gabor wavelet functions are commonly used method in texture analysis for feature extraction. In literature, it is stated that Gabor wavelet functions are one of the best models for human visual system. Gabor wavelet function has the ability of analysing frequency domain in different orientations. As a novel method, modelling Gabor wavelet features with multivariate Gaussian mixture is tested and fusion of Gabor features with this model is realized. Gaussian mixture model parameters is calculated by expectation maximization. Visual texture classification in Gabor domain is done according to the maximum likelihood ratio rule.

Feature extraction with Gabor filters are done using a C/C++ program and classification algorithms are tested with a Matlab program. Both classification methods has modelled textures with different performances due to the structure of texture. Both classification methods have classification rates over 95% in two class classification. In Gabor domain some textures has more compact structure than it is in spatial domain.

1. GİRİŞ

Bilgisayar tabanlı görüntü işleme uygulamalarında görsel doku analizi büyük bir öneme sahiptir. Doku analizi, doku sınıflama, hata sezimi, nesne tanıma, nesne izleme ve doku bölütleme gibi birçok araştırma konusunda temel bir bölümü oluşturmaktadır. Görsel doku gri düzey farklılıkları, frekans bileşenleri, içerdiği geometrik oluşumlar, dokunulduğunda edinilen hisler ve içerdiği renkler gibi birçok özellikle ifade edilebilmesinden dolayı kesin bir tanımı olmamakla birlikte bilimsel yazında çeşitli görsel doku tanımları yapılmıştır. Tuceryan ve Jain, her yerde aynı özelliği göstermese de belli bir örüntü ve desen arz eden yüzeyleri görsel dokusu olan yüzeyler olarak tanımlamışlardır [1]. Sklansky, resimdeki belli bir bölgenin yerel istatistiksel ve diğer özellik fonksiyonları sabit veya yavaş yavaş değişirse ya da hemen hemen periyodikse bu bölgede sabit bir doku olduğunu belirtmiştir [2].

Görsel doku, sahnelerin farklı nesne ve bölgelere ayrılması, yüzeylerin sınıflanması ve tanınması ve yüzey şekillerinin hesaplanmasında kullanılabilmektedir [3]. Doku analizi çok geniş uygulama alanlarına sahiptir ve sürekli yeni alanlarda kullanılmaya başlanmaktadır. Otomatik kalite kontrol, medikal görüntü işleme, metin ve belge işleme, uzaktan algılama gibi alanlarda uzun süredir kullanılmaktadır. Örneğin SAR görüntülerinde doku, görüntüdeki yerel sahne heterojenliği olarak tanımlanabilir ve bu tanıma göre görüntüdeki kara, deniz, tarım alanı, orman gibi sınıflamalar yapılabilmektedir. Başka bir uygulamada, kalpten alınan ses üstü (ultrasound) görüntülerinde doku, rastgelelik miktarı olarak tanımlanmıştır ve bu tanıma göre kalp boşluğu ile kalbin iç duvarı arasındaki sınır bu rastgelelik değerinin düşük olduğu yerler olup bu rastgelelik değeri ile bir sınıflama yapılabilmektedir [1].

Jain ve Tuceryan doku analiz yöntemlerini dört sınıfta toplamışlardır. Bu yöntemler, gri düzey istatistiklerini kullanan yöntemler, geometrik yöntemler, modele dayalı yöntemler ve işaret işleme yöntemleri olarak verilmiştir [1].

İstatistiksel yöntemlerle doku analizi uzamsal uzayda piksellerin gri düzey ilişkilerini çeşitli yöntemlerle ölçerek sınıflamaya dayanmaktadır[1]. İstatistiksel yöntemlerde en bilinen istatistiksel özellikler Haralick'in doku özellikleridir. Tekrar meydana

gelme matrisleri görüntüdeki piksel değerlerinin komşuluk ilişkileri ile oluşturulmaktadır. Haralick, piksel gri düzeylerinin aynı anda meydana gelme (co-occurrence) matrislerini kullanarak 14 adet dokusal öznitelik tanımlamıştır [4]. Haralick ‘in bazı dokusal öznitelikleri Çizelge 1.1’ de verilmiştir. P , $N_g \times N_g$ boyutunda aynı anda meydana gelme matrisi olmak üzere, i ve j sırasıyla yatay ve düşeyde matris elemanlarının yerlerini, μ matrisin ortalamasını göstermektedir.

Çizelge 1.1 : Bazı Haralick doku öznitelikleri

Açısal ikinci moment(Enerji)	$\sum_i \sum_j P(i, j)^2$
Karesel toplam (Varyans)	$\sum_i \sum_j (i - \mu)^2 P(i, j)^2$
Entropi	$-\sum_i \sum_j P(i, j) \log(P(i, j))$

Gri düzeylerin aynı anda meydana gelme matrisleri kullanılarak doku sınıflama birçok çalışmada kullanılmıştır [5-7]. Doku sınıflamada gri düzey ilişkileri kullanılan bir başka yöntem de özilinti öznitelikleridir. Özilinti fonksiyonu bir görüntüdeki düzenliliği, görüntüdeki dokunun kabalık ve yumuşaklığını ölçebilmektedir [1]. Özilinti fonksiyonları bilimsel yazında sıkça başvurulmuş yöntemlerdendir [8].

Görsel doku analizinde kullanılan bir yöntem de dokuların geometrik özelliklerinden yararlanmaktır. Tuceryan ve Jain “Voronoi” karolama yöntemiyle oluşturduğu öznitelikleri kullanarak görsel doku bölütleme üzerine çalışmışlardır [9]. Görsel dokuların geometrik özelliklerini kullanarak yapılan doku modellemesi ile motif içeren dokular yüksek doğrulukla modellenenilmekte ve bu dokularda hata sezimi yüksek doğrulukla yapabilmektedir [10].

Görsel doku analizinde modele dayalı yöntemler, görüntüye ait bir model oluşturarak doku belirleyen özelliklerin çıkarımı olup aynı zamanda bu yöntemle doku sentezi de yapılabilir [1]. Rastgele alanlar ve fraktal yöntemleriyle doku modelleme bu yöntemler içinde ele alınmaktadır. Mandelbrot fraktalı genel olarak kendisiyle aynı daha küçük parçalara bölünebilen parça ya da parçalanmış geometrik yapı olarak tanımlanmıştır [8]. Fraktal yapılarına dayalı yöntemler uzaktan algılama ve doku sınıflama çalışmalarında kullanılmıştır [11-12].

İşaret işleme yöntemleri dokunun frekans özelliklerinden dolayı çok uygun bir yöntemdir. İşaret işleme yöntemleri üç bölümde toplanabilir. Bunlar uzamsal uzayda filtreleme, Fourier uzayında filtreleme ve Gabor ve dalgacık modelleri ile doku

analizidir [1]. Uzamsal uzayda filtreleme, Laplacian ve Robert maskeleri gibi maskeler kullanarak ayrıtların birim alandaki yoğunluğunun hesaplanmasıyla belli yönelim ve özellikleri hesaplayarak yapılabilir [1]. Görsel dokular Fourier dönüşümü ile frekans uzayında incelenebilmektedir. Fourier dönüşümü sayesinde görüntü farklı frekans ve yönelimlerde incelenebilmektedir. Fourier dönüşümünde olduğu gibi Gabor ve dalgacık dönüşümleri ise frekans ve uzamsal uzay arasındaki ilişkiyi kurarken hem frekans uzayındaki bilgiyi hem de uzamsal uzaydaki bilgiyi en verimli şekilde inceleme imkânı sunmaktadır [13]. Bununla birlikte Gabor dalgacık fonksiyonları farklı yönelim özellikleri içeren, değiştirilebilir merkez frekansı ile büyük bir fayda sağlamaktadır [3]. Gabor süzgeçleme ve diğer dalgacık analizi yöntemleri doku analizinde geniş bir kullanım alanına sahiptir [14,15] .

Görsel doku sınıflama iki aşamadan oluşmaktadır. İlk aşamada veritabanındaki görsel doku sınıfının özniteliklerini en iyi temsil eden görsel doku örneklerinden o dokuyu en iyi şekilde ifade eden öznitelikleri öğrenilir. İkinci aşamada öğrenilen öznitelikleri kullanarak incelenmek istenen dokunun veritabanındaki dokuya ne kadar benzediği araştırılır. Doku analizinde birçok farklı yöntem kullanılmaktadır. Bunun nedeni ise doku algısının birçok değişik öznitelikle ifade edilebilmesidir. Bazı dokular tekrarlı bir yapı gösterirken bazı dokular ise tekrarlı bir özellik göstermemesine rağmen dokunun genelinde bir algı oluşturmaktadır. Tekrarlı dokuların sınıflamasında Hough dönüşümü, Fourier dönüşümü ve çeşitli geometrik yöntemler kullanılarak belli bir başarımla sağlanmıştır [16]. Belli bir yönelim ve frekans bileşenlerine sahip dokular için Gabor dalgacık fonksiyonu kullanarak filtreleme yöntemleri dokuyu çoklu ölçekte yüksek başarımlarla modelleyebilmektedir. Ancak tekrarlı olmayan dokuların sınıflamasında bu yöntemlerin yeterli başarımla sağlayamadığı durumlar da bulunmaktadır [17]. Bu amaçla [17]'den esinlenerek, görsel doku modellemesinde çok boyutlu Gauss karışım modeli kullanılmıştır. Çok değişkenli Gauss karışım modelinin, görsel dokuların karmaşık yapısını esnek bir şekilde modelleyebileceği düşünülmektedir. Gauss karışım modelleri uzamsal uzay ve Gabor uzayı olmak üzere iki farklı uzayda modellenmiştir. Gabor uzayı çok ölçekli analiz imkânı sunarak , dokuların farklı frekans ve yönelim özniteliklerini inceleme fırsatı vermektedir. Çok değişkenli Gauss karışım modelinin parametreleri beklenen değeri en büyükleme yöntemiyle elde edilmiştir.

Uzamsal uzayda yapılan doku modellemede görsel doku görüntülerinin gri düzey değerleri kullanılmıştır. Görsel dokuların tekrarlı veya tekrarlı olmayan özellikleri birçok küçük parçanın bir araya gelmesiyle bir bütünlük hissi yaratmaktadır. Bu nedenle gri düzey görsel doku örnekleri küçük kare yamalara bölünerek beklenen değeri en büyükleme algoritması ile Gauss karışım modeli parametreleri hesaplanmaktadır. Görsel doku sınıflama eğitim aşamasında elde edilen Gauss karışım parametreleri kullanılarak en büyük olabilirlik oranı kuralına göre yapılmaktadır.

Bilimsel yazında Gabor dalgacık fonksiyonu ile görsel doku analizi yapılmıştır. Ayrıca psikofiziksel alandaki araştırmalar insan beyninin görüntüleri frekans çözümlemesi yaparak algıladığı yönünde ipuçları vermektedir ve görüntünün belli frekans ve yönelimlere sahip görüntülere ayrıştırılarak çözümlendiği düşünülmektedir [18]. Bu duruma en uygun filtrelerden birisi de Gabor dalgacık fonksiyonlarıdır. Gabor dalgacık fonksiyonlarının görüntüyü belli frekanslarda çözümleme imkânı sunarken, görüntüdeki yönelimleri de işin içine katarak insan gözünü modellemek için kullanılabileceği bilimsel yazında belirtilmektedir. Gabor dalgacık fonksiyonu görsel dokuyu farklı ölçek ve yönelimlerle inceleyebilmektedir. Bu çalışmada yenilik olarak Gabor dalgacık fonksiyonu ile elde edilmiş özniteliklerin çok değişkenli Gauss Karışım modeli ile modellenebileceği düşünülmüştür. Aynı ölçekte, farklı yönelime sahip Gabor dalgacık fonksiyonları ile süzgeçlenerek elde edilen öznitelikler çok değişkenli Gauss Karışımları ile birleştirilerek, parametrik bir şekilde piksel boyutunda doku sınıflamada kullanılması denenmiştir.

Bu çalışmada, sonraki bölümlerde uygulanan yöntemler ve kullanılan matematiksel ifadeler ve açıklamaları anlatılacaktır. Bölüm 2’de çok değişkenli Gauss karışım modeli, beklenen değeri en büyükleme algoritması ve görsel doku sınıflama, Bölüm 3’te Gabor öznitelikleri kullanarak gauss karışım modelleme yöntemiyle doku sınıflama ve görsel doku sınıflama konuları anlatılmıştır. Bölüm 4’te test sonuçları verilmiştir. Bölüm 5’te bölümde ileriki dönemler için sonuç ve öneriler verilmiştir.

2. GÖRSEL DOKU SINIFLAMA

Doku analizi geçmişte olduğu gibi günümüzde de hala güncelliğini koruyan bir konudur. Genel olarak doku analizi doku sentezi, doku sınıflama, doku bölütleme ve doku ile şekil çıkarımı olarak dört alt gruba ayrılabilir ve 1990'ların başında özellikle ilk üç alanda süzgeç ailesi yöntemlerin sağladığı başarımla çok hızlı bir ilerleme görülmüş olmakla birlikte Zisserman ve Varma çok geniş süzgeç ailelerinin gerekliliğini sorgulamışlar ve süzgeçleri kullanmadan daha iyi sonuçlar elde ettiklerini belirtmişlerdir [19, 20] .

Tekrarlı olan dokularda, Bölüm 1'de bahsedilen doku analizi yöntemlerinin başarımla tatmin edici seviyelere ulaşmakla birlikte Xie ve Mirmehdi tekrarlı olmayan karmaşık örüntülü fakat daha büyük alanlarda düzenli bir doku hissi veren doku türlerinde bu yöntemlerin başarımlarının düştüğünü belirtmişlerdir. Karmaşık yapıları dokuların modellenmesi için "Texem" isimli beklenen değeri en büyükleme yöntemini kullanan parametrik bir yöntem önermişlerdir [17]. Bu yöntemle dokuları modelleyerek ikili bir sınıflama yaparak dokulardaki farklılıkları sezmişlerdir. Yöntem karmaşık dokuları çok boyutlu Gauss karışımları olarak modellemektedir ve çok boyutlu Gauss karışım modeli parametreleri beklenen değeri en büyükleme yöntemi ile döngülü bir şekilde belirlenmektedir.

Bu çalışmada, [17]'den esinlenerek karmaşık yapıları dokuların, parametrik bir yöntem olan beklenen değeri en büyükleme yöntemi kullanılarak çok boyutlu Gauss karışım modeli ile modellenmesi ve sınıflandırılması hedeflenmiştir. [17]'de uygulanan yöntem ek olarak ikiden fazla farklı dokuları içeren görüntülerin piksel bazında sınıflanması da hedeflenmiştir. Doku özelliklerinin çıkarımında renk bilgisi kullanılmamış olup doku özelliklerinin modellenmesinde gri düzey değerleri kullanılmıştır. Yöntem, iki aşamadan oluşmaktadır. İlk aşamada az sayıdaki doku örneğinden dokuyu temsil eden farklı boyutlarda olabilen küçük yamalarla dokuyu modelleyen çok boyutlu Gauss karışımı parametreleri elde edilmektedir. Böylelikle doku, çok boyutlu Gauss karışım modeli ile modellenmiş olur ve belli bir ortalama ve değişim (variance) bileşenleri ile ifade edilir. İkinci aşamada ise sisteme verilen doku örneğinin o dokuya ne kadar yakın olduğu hesaplanarak sınıflama

yapılmaktadır. Sınıflama işlemi Gauss Karışım parametreleri olabilirlik oranı (likelihood ratio) ile yapılmaktadır.

Öncelikle kullanılan matematiksel modeller açıklanacaktır ve sonrasında yönteme nasıl uyarlandığı verilecektir.

2.1 Çok Değişkenli Gauss Karışım Modeli

Bilimsel yazında sıkça kullanılan sürekli tek değişkenli Gauss olasılık yoğunluk fonksiyonu (2.1)'de verilmektedir. $p(x)$, x değişkeninin olasılık yoğunluk fonksiyonu σ ve μ ise sırasıyla, x değişkeninin ortalaması ve değişintisidir (variance).

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right) \quad (2.1)$$

(2.1)'de verilen Gauss dağılım fonksiyonunun beklenen değer ve değişinti hesabı (2.2)'de verilmiştir. Böylelikle x değişkeni, ortalaması μ ve değişintisi σ^2 olan normal bir dağılıma sahip olup $x \sim N(\mu, \sigma^2)$ olarak gösterilir [20].

$$\begin{aligned} \mu &= E(x) = \int_{-\infty}^{\infty} xp(x)dx \\ \sigma^2 &= Var(x) = \int_{-\infty}^{\infty} (x-\mu)^2 p(x)dx \end{aligned} \quad (2.2)$$

Çok değişkenli Gauss dağılım yoğunluk fonksiyonu d boyutta genel gösterilimi (2.3)'te verilmiştir.

$$p(x) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp\left[-(x-\mu)^T \Sigma^{-1} (x-\mu)\right] \quad (2.3)$$

μ , d boyutlu ortalama vektörü; Σ , $d \times d$ boyutunda ortak değişinti (Covariance) matrisi, $|\Sigma|$ ve Σ^{-1} sırasıyla, Σ 'nin determinanı ve ters matrisidir.

$$\mu = [\mu_1 \ \mu_2 \ \mu_3 \dots \mu_d] \quad (2.4)$$

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1d} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2d} \\ \dots & \dots & \dots & \dots \\ \sigma_{d1} & \dots & \dots & \sigma_{dd} \end{bmatrix}_{d \times d} \quad (2.5)$$

Birçok örüntü, Gauss olasılık dağılımı ya da birden fazla Gauss olasılık dağılımının bileşeni olan çok değişkenli Gauss karışım modeli ile modellenebilmektedir [20]. Çok değişkenli Gauss karışımının K bileşenli modeli (2.6)'da verilmiştir. Burada α_k her bir bileşenin önsel olasılık değeridir.

$$p(x) = \sum_{k=1}^K \frac{1}{(2\pi)^{d/2} |\Sigma_k|^{1/2}} \exp\left[-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right] \alpha_k \quad (2.6)$$

2.2 Beklenen Değeri En Büyükleme


Genel olarak, beklenen değeri en büyükleme algoritması bilinen bir dağılım için en büyük olabilirlik kestirim parametrelerini, tam olmayan bir veri kümesi için bulmayı sağlamaktadır. Beklenen değeri en büyükleme algoritması iki adımdan oluşmaktadır. İlk adımda beklenen değer hesaplanır ve ikinci adımda logaritmik olabilirlik kestirimini en büyükleyen parametre kümesi bulunur [20]. Yöntem içinde, beklenen değeri en büyükleme algoritmasının matematiksel ifadeleri verilecektir.

2.3 Çok Değişkenli Gauss Karışım Modeliyle Görsel Doku Sınıflama

2.1'de belirtildiği gibi dokuların çok boyutlu Gauss karışım modeli ile modellenmesi ve sınıflanması iki aşamadan oluşmaktadır. Birinci aşamada, veritabanındaki doku örneklerinden çok boyutlu Gauss karışım parametreleri öğrenilir ikinci aşamada öğrenilen parametreler ile olabilirlik oranına göre doku sınıflaması yapılır.

2.3.1 Eğitim aşaması

Eğitim aşamasında, dokuların çok boyutlu Gauss karışım modelleri ile modellenmesi amaçlanmaktadır. Her bir Gauss karışım bileşeni ortalama bir görüntü yaması ve ona ait bir değişintiyi ifade etmektedir. Elde edilen Gauss bileşenlerinden doku tekrar geri çatılabilmektedir. Eğitim aşamasının blok şeması Şekil 2.1'de verilmiştir. Eğitim aşamasında veritabanından alınan I görüntüsü $d \times d'$ lik P adet küçük yamaya ayrılmaktadırlar. Yamalar $Z = \{Z_i\}_{i=1}^P$ şeklinde gösterilmektedir. Küçük yamaların boyutları değişken olabilmektedir fakat kolaylık olması amacıyla eğitim aşamasında boyut sabit tutulmuştur. d değeri 1'den başlayarak çok daha büyük değerlere kadar çıkabilmektedir. $d=1$ olduğu durumda, Gauss karışım modeli tek değişkenli Gauss karışım modeli olmaktadır.



Şekil 2.1 : Sistem eğitim aşaması

Oluşturulan yamalardan, parametreleri m_k ile temsil edilen $k=1 \dots K$ için çok değişkenli Gauss bileşeni hesaplanmaktadır. Her bir m_k , bir ortalama değer vektörü μ_k ve bir değişinti matrisi w_k ile tanımlanmaktadır. K adet çok değişkenli Gauss bileşeni ile $M = \{m_k\}_{k=1}^K$ şeklinde gösterilen çok değişkenli Gauss karışım modeli elde edilmiş olur. Ayrıca I görüntüsünden alınan Z 'deki her bir yama bir m dağılımından geri çatılabilir [17].

Çok boyutlu Gauss karışım modeli bileşenlerinin parametreleri beklenen değeri en büyükleme algoritması ile hesaplanmaktadır. Oluşturulan $d \times d$ 'lik yamalar $d \times d$ 'lik bir uzaya izdüşürülmektedirler ve yamalardaki her bir piksel koordinatı uzayın bir boyutunu oluşturmaktadır ve uzaydaki bir nokta Z içindeki bir yamaya karşılık düşmektedir [17]. Ortalama değer vektörü μ_k ve bir değişinti matrisi w_k ile ifade edilen her bir Gauss karışım bileşeni m_k , Z içindeki bir grup yamayı temsil eder. Böylelikle verilen k . Gauss bileşeni m_k için Z_i yamasının olasılığı (2.7)'de hesaplanır.

$$p(Z_i | \mu_k, \psi) = N(Z_i; \mu_k, \omega_k) \quad (2.7)$$

Burada $\psi = \{\alpha_k, \mu_k, \omega_k\}_{k=1}^K$ çok değişkenli Gauss karışımının parametre kümesidir ve α_k , k . Gauss bileşeninin önsel olasılığıdır. Önsel olasılıkların toplamı $\sum_{k=1}^K \alpha_k = 1$ 'dir. Hiçbir Gauss bileşeninin parametrelerinin bilinmemesinden dolayı verilen parametre

kümesi için Z 'nin koşullu olasılığı her bir Z_i için tüm Gauss bileşenleri ile (2.8)'de hesaplanır.

$$p(Z_i | K, \psi) = \sum_{k=1}^K p(Z_i | m_k, \psi) \alpha_k \quad (2.8)$$

Sonrasında bütün küme için log-olabilirlik ifadesinin en iyilemesi (2.9)'da verilmiştir.

$$\log p(Z | K, \psi) = \sum_{i=1}^P \log(p(Z_i | m_k, \psi)) \alpha_k \quad (2.9)$$

Bu aşamada ψ parametre kümesi için en büyük olabilirlik kestirimi beklenen değeri en büyükleme algoritması ile eldeki yamaları kullanarak hesaplanmaktadır. Eşitlik (2.10)'daki hale gelir.

$$\psi = \arg \max_{\psi} \log(L(\psi | Z)) = \arg \max_{\psi} \log p(Z_i | K, \psi) \quad (2.10)$$

Bundan sonra en büyükleme algoritması döngüsel olarak beklenen değer hesabı ve en büyükleme aşamalarını çağırılmaktadır. İlk adımda ψ parametre kümesi için ilk değerlerini tahmin ederek her bir Z_i yamasının Gauss karışım bileşenlerine atanması gerçekleştirilir. Sonrasında ise her bir t . ara adımda ψ^t parametre grubu hesaplanır. k . Gauss bileşeni verilen Z_i için olabilirliği Bayes kuralı kullanılarak (2.11)'deki gibi hesaplanır.

$$p(m_k | Z_i, \psi^{(t)}) = \frac{p(Z_i | m_k, \psi^{(t)}) \alpha_k}{\sum_{i=1}^K p(Z_i | m_k, \psi^{(t)}) \alpha_k} \quad (2.11)$$


En büyükleme aşamasında ise log-olabilirliği en büyükleyerek ψ^t parametre grubu (2.12) ile güncellenir.

$$\begin{aligned} \bar{\alpha}_k &= \frac{1}{P} p(m_k | Z_i, \psi^{(t)}) \\ \bar{\mu}_k &= \frac{\sum_i^P Z_i p(m_k | Z_i, \psi^{(t)})}{p(m_k | Z_i, \psi^{(t)})} \\ \bar{w}_k &= \frac{\sum_i^P (Z_i - \bar{\mu}_k)(Z_i - \bar{\mu}_k)^T p(m_k | Z_i, \psi^{(t)})}{\sum_1^P p(m_k | Z_i, \psi^{(t)})} \end{aligned} \quad (2.12)$$

Beklenen değer ve en büyükleme adımları kestirimler kararlılaşınca kadar döngülü bir şekilde tekrar edilirler. Böylelikle çok boyutlu Gauss karışım parametreleri hesaplanmış olunur.

2.3.2 Sınıflandırma aşaması

Eğitim aşamasında veritabanındaki doku örneklerinin çok değişkenli Gauss karışımı parametreleri elde edilmişti. Sınıflama işlemi ise piksel bazında yapılmaktadır.



Şekil 2.2 : Sınıflama aşaması blok şeması

Sınıflama aşamasının blok şeması Şekil 2.2’de verilmiştir. Sınıflanacak görüntüde her bir piksel için $d \times d$ boyutunda yamalar alınmaktadır. $d \times d$ ’lik görüntü matrisi $1 \times d^2$ vektörlere dönüştürülerek veritabanındaki çok değişkenli Gauss karışımları ile (2.13)’te verilen olabilirlik oranı kuralına göre olasılıksal olarak karşılaştırılmaktadırlar. Karşılaştırma sonucunda piksel, en büyük olasılık değerini

veren Gauss karışım modeline ait doku sınıfına atanmaktadır. Burada Z_i sınıflanmak istenen piksel için

$$p_t(Z_i | \psi_k) = \sum_{k=1}^K p_t(Z_i | m_k, \psi_k) \alpha_k \quad (2.13)$$

alınan yama, $p_t(Z_i | \psi_k)$, Z_i yamasının veritabanındaki t . doku modeline olan olasılıksal yakınlık değeri, m_k , ψ_k ve α_k , t . dokunun k . Gauss bileşeni, parametreleri ve ağırlık katsayısıdır.

3. GABOR ÖZNİTELİKLERİ KULLANARAK GAUSS KARIŞIM MODELLEME YÖNTEMİYLE DOKU SINIFLAMA

Gabor süzgeçleri kullanılarak yapılan doku analizi çalışmalarında çok kanallı süzgeçleme yaklaşımı ile doku modellenmektedir. 1980’de Daugman bazı memelilerin görsel korteksinde bulunan algılayıcı hücrelerin Gabor süzgeçleri ile modellenebileceğini ileri sürmüştür [18]. Literatürde birçok araştırmaya konu olan Gabor süzgeçleri, uzamsal konumlanma ve farklı yönelimlerdeki seçicilik özelliklerini birlikte sağladığından, istenilen uzamsal koordinatta ve seçilen frekansta optimum konumlamayı sağlamaktadır ve bu özellikleriyle memelilerin korteks hücrelerinin iki boyutlu algı alanlarına benzetilmektedir [22].

Jain ve Farrokhnia çok kanallı süzgeçleme yönteminin getirisini süzgeçlenmiş görüntülerin gri düzey istatistiksel özelliklerinin doğrudan kullanılabilmesi olarak belirtmişler ve çok kanallı süzgeçleme yaklaşımında dört temel konunun düşünülmesi gerektiğini ortaya koymuşlardır. Bu temel konular; kanalların fonksiyonel karakterlerinin çıkarılması, süzgeçlenmiş görüntülerden uygun dokusal özniteliklerin çıkarılması, kanallar arasındaki ilişkilerin kurulması ve farklı kanallardaki bilgilerin birleştirilmesidir [14].

Bu bilgiler ışığında, Bölüm 2’de kullanılan gri düzeylerinin modellenmesine dayalı sınıflandırma yöntemi dışında, doku modellemede bir grup Gabor süzgeci kullanarak dokuların farklı frekans ve yönelimlerde özniteliklerinin çıkarılması ve bu özniteliklerin Gauss karışım modelleri ile modellenmesinin sınıflandırma başarımını arttırabileceği düşünülmüş ve bu tez kapsamında incelenmiştir. Gabor süzgeçleri ile elde edilen öznitelikler modelleme işleminde iki farklı şekilde kullanılmıştır. Birinci yöntemde doku modellemede tek bir ölçek ve yönelimde elde edilen öznitelik kullanılmıştır. İkinci yöntemde farklı frekans ve yönelim kanallarından elde edilen bilginin tümleştirilmesi hedeflenmiştir.

Gabor süzgeçleri kullanarak gerçekleştirilen doku sınıflama işlemi üç adımdan oluşmaktadır. Birinci adımda Gabor süzgeçleriyle dokuların belli frekans ve yönelimlerdeki öznitelikleri çıkarılır. İkinci adımda süzgeç çıkışılarındaki öznitelikler

beklenen değeri en büyükleme algoritması yardımıyla çok değişkenli Gauss karışımı modeli ile modellenir. Üçüncü adımda, sınıflanacak görüntü, Gabor süzgeçleriyle süzgeçlenir ve ikinci adımda belirlenen doku modelleri kullanılarak olabilirlik oranına göre piksel bazında karşılaştırma yapılır. Pikseller en yüksek olabilirlik oranına göre sınıflanır.

Gabor dalgacık fonksiyonlarının matematiksel formülasyonu Bölüm 3.1’de sunulmaktadır. Bölüm 3.2’de dokuların öznitelik çıkarımı ve Gabor özniteliklerinin Gauss karışım modeli ile modellenmesi, Bölüm 3.3’te Gabor süzgeçleri kullanılarak gerçekleştirilen sınıflandırma işlemi açıklanmaktadır.

3.1 Gabor Dalgacık Fonksiyonu Matematiksel Formülasyonu


Bilimsel yazında Gabor dalgacık fonksiyonunun matematiksel formülasyonu değişik şekillerde verilmiştir. Bir boyutlu Gabor filtresi sinüsoidal bir fonksiyonun bir Gauss fonksiyonu ile modülasyonu ile elde edilmektedir [14]. Sinüsoidal fonksiyonun C genliğinde, f_c frekansında θ fazlı bir boyutlu taşıyıcı olması durumunda, $m(t)$ modüle eden işaret olmak üzere, elde edilen modülasyonlu $y(t)$ işareti (3.1) ile ifade edilmektedir. Modüle eden işaret olan $m(t)$ fonksiyonu, standart sapması σ ve ortalaması sıfır olan bir Gauss fonksiyonu olarak alındığında, $C=1$ ve $\theta = \frac{\pi}{2}$ olarak alınırsa, $y(t)$ işareti bir boyutlu Gabor fonksiyonu haline gelmektedir ve (3.2)’de görülen $y_1(t)$ işaretine dönüşmektedir.

$$y(t) = m(t)C \sin(2\pi f_c t + \theta) \quad (3.1)$$

$$y_1(t) = \frac{1}{2\pi\sigma^2} e^{-\frac{t^2}{2\sigma^2}} \cos(2\pi f_c t) \quad (3.2)$$

Şekil 3.1’de bir sinüsoidal fonksiyon ve Gauss fonksiyonu kullanılarak elde edilen bir boyutlu Gabor fonksiyonu görülmektedir. Şekil 3.1’de elde edilen Gabor filtresinin darbe yanıtı f_c frekansında oluşmaktadır ve Gauss fonksiyonu zaman uzayında konum bilgisini içerir. (3.1)’de $C=i$ ve $\theta = 0$ olarak alındığında oluşan $y_2(t)$ (3.3)’te verilmiş olup $y_1(t)$ ve $y_2(t)$ ’nin toplamıyla oluşan ve (3.4)’te görülen $G(t)$ ise kompleks Gabor fonksiyonudur. Bir boyutlu kompleks Gabor fonksiyonu $G(t)$ ’nin iki boyutlu uzamsal koordinatlarda matematiksel formülasyonu (3.5)’te verilmiştir.

$$y_2(t) = \frac{1}{2\pi\sigma^2} e^{-\frac{t^2}{2\sigma^2}} i \sin(2\pi f_c t) \quad (3.3)$$




Şekil 3.1 : Bir Boyutta a) Gauss fonksiyonu, b) Sinüsoidal fonksiyon, c) Gabor fonksiyonu [23]

$$G(t) = \frac{1}{2\pi\sigma^2} e^{-\frac{t^2}{2\sigma^2}} e^{2\pi f_c t i} \quad (3.4)$$

(3.5)'te görülen x ve y uzamsal piksel koordinatları olup uzamsal koordinatların ϕ açısı kadar döndürülmesiyle kompleks Gabor fonksiyonunun yönelimi belirlenmektedir.

$$G(x, y, f_c, \phi) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} e^{2\pi f_c i(x \cos \phi + y \sin \phi)} \quad (3.5)$$


Şekil 3.2'de $G(x, y, f_c, \phi)$ fonksiyonu ve onu oluşturan Gauss fonksiyonu ve taşıyıcı fonksiyon verilmiştir.



Şekil 3.2 : Bir boyutta a) Gauss fonksiyonu, b) x eksenine göre 30° döndürülmüş iki boyutlu sinüsoidal fonksiyon, c) Gabor fonksiyonu gerçel kısmı [23]

(3.5)'te kompleks Gabor fonksiyonunun genel bir formülasyonu verilmiştir. Bununla birlikte uygun parametre grupları ile oluşturulan Gabor süzgeç grubu hemen hemen bütün frekans uzayını kapsama özelliğine sahiptir. Bu özelliğiyle Gabor süzgeç grubu bir dalgacık dönüşümü (wavelet transform) temel yapısını sağlamaktadır [14]. Bununla birlikte Jain ve Farrokhnia dalgacık dönüşümünü basit anlamda bir giriş görüntüsü için bant geçiren süzgeçleme işlemi olarak yorumlamışlardır. Bu tanıma

göre Gabor süzgeçleri ile süzgeçleme işlemi dalgacık dönüşümü olarak kabul edilebilir fakat Gabor fonksiyonları frekans uzayında tam anlamıyla ortogonal bir ayrışma sağlayamamaktadır [14]. Şekil 3.3'te Gabor filtrelerinin frekans uzayında en büyük yarı genlikten büyük değerini sağlayan tarama alanları 128x128 görüntü boyutunda çizdirilmiştir. Ayrıca frekans uzayı simetrik olduğundan taramanın tek tarafta yapılması yeterlidir.



Şekil 3.3 : Gabor çekirdeklerinin frekans uzayını tarama alanı. Merkez frekans (64, 64) nolu pikseldir. (satır(u), sütun(v))

Bu bilgilerden faydalanarak bu çalışmada, öznitelik çıkarımında dalgacık dönüşümü özelliğini sağlayan bir grup Gabor süzgeci kullanılmaktadır ve bu süzgeç grubuna Gabor tipi dalgacık fonksiyonu denilmektedir. Süzgeçleme işlemi, doku örneği gri düzey bilgisi içeren $I(x,y)$ görüntüsünün Gabor dalgacık fonksiyonu ailesi $\psi_{m,v}$ süzgeçleri ile konvolüsyonu işlemine karşı gelmektedir ve konvolüsyon işlemi (3.6)'da formüle edilmiştir.

$$O_{m,v}(x,y) = I(x,y) * \psi_{m,v}(x,y) = \iint \psi_{m,v}(x,y) I(x,y) dx dy \quad (3.6)$$

Burada, * iki boyutlu konvolüsyon işlemini, $O_{m,v}(x,y)$ konvolüsyon çıkışında oluşan sonuç görüntüsünü ve (x,y) piksel uzamsal koordinatlarını belirtmektedir. Bu çalışmada dokuların özniteliklerinin çıkarımı (3.7)'de verilen Gabor tipi dalgacık fonksiyonu ailesi ile süzgeçlenerek yapılmaktadır [21-23]. (2.18)'de sinüsoidal

fonksiyonun merkez frekansı $f_c = \frac{k_v}{2\pi}$ ve $\sigma_t = \frac{\sigma}{\|k_{m,v}\|}$ alındığında elde edilen sonucu

2π ile çarptığımızda (3.7) elde edilmektedir. Görüntü düzleminde tanımlanan $\psi_{m,v}(x,y)$ süzgeç grubundaki bütün çekirdekler (3.7)'de verilen ana dalgacık fonksiyonundan, $k_{m,v}$ dalga vektörünün farklı ölçek ve yönelim değerleriyle türetilmektedirler ve birbirlerine aynen benzemektedirler. Türetilen bu

çekirdekler, düzlemsel bir dalga fonksiyonunun, bir Gauss zarfı ile sınırlandırılmasıyla oluşmaktadır.

$$\psi_{m,v}(x,y) = \frac{\|k_{m,v}\|^2}{\sigma^2} e^{-\frac{\|k_{m,v}\|^2(x^2+y^2)}{2\sigma^2}} \left[e^{(ik_{m,v})} - e^{-\frac{\sigma^2}{2}} \right] \quad (3.7)$$

(3.7)'de m çekirdeklerin yönelimini, v çekirdeklerin ölçeğini, $\| \cdot \|$ işlemi norm operatörünü ve $k_{m,v}$ ise (3.8) de tanımlı dalga vektörünü göstermektedir.

$$k_{m,v} = k_v e^{i\phi_m} = k_v (\cos \phi_m, \sin \phi_m) \quad , \quad \phi_m = \frac{\pi m}{8}, \quad m \in \{0, \dots, 7\} \quad (3.8)$$

(3.8)'de görülen k_v (3.9) eşitliği ile tanımlanmaktadır.

$$k_v = \|k_{\mu,v}\| = \frac{k_{\max}}{f^v}, \quad k_{\max} = \frac{\pi}{2} \quad (3.9)$$


(3.7)'de köşeli parantezin içerisindeki ilk terim sinüzoidal dalga fonksiyonudur ve ikinci terim çekirdeğin doğru akım bileşenini bastırmaktadır [24]. σ parametresi ise Gauss penceresinin genişliğinin dalga boyuna oranını belirler. σ 'nin büyük değerleri için doğru akım bileşeninin etkisi ihmal edilebilir düzeye gelmektedir. Oluşturulan $\psi_{m,v}(x,y)$ çekirdeklerinin merkez frekansı (2.22)'de verilen k_v ve yönelimiye ϕ_m ile belirlenmektedir. $k_{\max}$ çekirdeklerin en büyük frekansını, f frekans uzayının tarama büyüklüğünü, v ise fonksiyonun ölçek değerini belirler.

Birçok araştırmada en büyük frekans değeri $k_{\max} = \frac{\pi}{2}$ 'nin iyi sonuç verdiği


gözlenmiştir ve bu çalışmada da bu değer seçilmiştir [22]. $f = \sqrt{2}$ ve $v = \{0 \dots 4\}$ değerlerini aldığı anda frekans uzayı 0.5 oktav aralıklarla taranmış olur. Yapılan psikofiziksel çalışmalarda insan gözü korteks hücrelerinin algı alanlarının 1 oktav değişimlerle algıladığı belirtilmiştir [14]. Şekil 3.4'te, kullanılan Gabor dalgacık fonksiyonu çekirdeklerinin farklı yönelim açlarına göre uzamsal uzaydaki darbe yanıtının gerçel ve sanal kısımları 128x128'lik boyutlarda çizdirilmiştir. Şekil 3.4'te

$$\sigma=2, \quad k_{\max} = \frac{\pi}{2}, \quad f = 3\sqrt{2}, \quad v=1 \text{ olarak alınmıştır ve yönelim açıları } 0 \text{ dan } \frac{3\pi}{4} \text{ e } \frac{\pi}{4}$$

artımlarla verilmiştir. Şekil 3.5'te, Şekil 3.4'te görülen Gabor dalgacık fonksiyonlarının gerçel ve sanal kısımlarının üç boyutlu görüntüsü verilmiştir.



Şekil 3.4 : Birinci satır Gabor dalgacık fonksiyonu çekirdekleri gerçel kısmı.İkinci satır Gabor dalgacık fonksiyonu çekirdekleri sanal kısmı




Şekil 3.5 : Gabor dalgacık fonksiyonu: a) gerçel kısım, b) sanal kısım

(3.7)'de tanımlanan $\psi_{m,v}$ 'nin Fourier dönüşümü (3.10)'da gösterilmiştir ve $F()$ operatörü Fourier dönüşümünü göstermektedir. İlk terim olan üstel Gauss fonksiyonu bant geçiren bir çekirdek oluşturur ve ikinci üstel terim ise

$$F(\psi_{m,v})(k_0) = \exp\left(-\frac{\sigma^2(k_0 - k_{m,v})^2}{2k_{m,v}^2}\right) - \exp\left(-\frac{\sigma^2(k_0^2 - k_{m,v}^2)}{2k_{m,v}^2}\right) \quad (3.10)$$

çekirdeğin doğru akım bileşeni etkisini ortadan kaldıran terimdir. Şekil 3.6'da Gabor dalgacık fonksiyonlarının frekans uzayında transfer fonksiyonları ve onların üç boyutlu çizimi verilmektedir. Frekans uzayında ikinci bir tepecik bulunmaktadır ve bu ikinci tepecik çekirdeğin doğru akım bileşeni etkisini ortadan kaldıran terimden kaynaklanmaktadır.




Şekil 3.6 : Şekil 3.4’te verilen Gabor dalgacık fonksiyonunun frekans uzayında transfer fonksiyonları

$\psi_{m,v}$ birbirine benzeyen farklı öteleme, yönelim ve ölçeklerde olan çekirdeklerden oluşan gruba ise Gabor dalgacık fonksiyonu ailesi denmektedir [24]. Bu çekirdeklerin , parametreleri dalga vektörü $k_{m,v}$ tarafından belirlenir. $k_{m,v}$ çekirdeğin yönelim, dalga boyu ve Gauss penceresinin büyüklüğünü belirler.

Görsel doku sınıflamada, kullanılan dalgacık modeli dokunun özelliklerini ortaya çıkarırken, diğer dokulardan farklı olan özelliklerini de modelleyebilmelidir. Gabor fonksiyonu ise dalga vektörü $k_{m,v}$ ’ya dik olan yönelimlerdeki yüksek frekans geçişlerini ortaya çıkarabilmektedir. Gabor çekirdekleri ile konvolüsyon sonucunda oluşan $O(x,y)$ süzgeç cevabının gerçel ve sanal kısımları yüksek frekans geçişlerindeki noktalarda bir tepe noktası oluşturmayıp bu noktada bir salınım yapmaktadırlar. Bu nedenle bu çalışmada dokuların frekans özelliklerini belirleyebilmek için kompleks $O(x,y)$ cevabının genlik değeri kullanılmıştır. Fourier uzayında ise bu değer güç spektrumunun karesel köküdür. Şekil 3.7’de MIT “Vistex”

veritabanından alınan Fabric.0000.bmp görüntüsü için parametreleri $\sigma=2$, $k_{\max} = \frac{\pi}{2}$,

$f = \sqrt{2}$, $v=3$ olarak alınan Gabor çekirdeğiyle süzgeçlenmiş $O(x,y)$ görüntüsünün gerçel, sanal kısmı ve genlik görüntüsü 0-255 ölçeğine ölçeklenerek verilmiştir.



Şekil 3.7 : a) Giriş görüntüsü b) $O(x,y)$ 'nin gerçel kısmı c) $O(x,y)$ 'nin sanal kısmı d) $O(x,y)$ 'nin genlik görüntüsü

Doku öznitelikleri çıkarımı, veritabanından alınan görsel doku örneğinin farklı ölçek ve yönelimlerdeki Gabor dalgacık çekirdekleriyle, (3.6)'da verilen konvolüsyon işlemine sokulmasıyla yapılır. Doku modellemede kullanılacak örneklem grubu, $O_{m,v}(x,y)$ 'lerin piksel değerlerinden Bölüm 3.2'de anlatıldığı gibi oluşturulmaktadır. Bölüm 3.3'te Gabor öznitelikleriyle elde edilen doku modelleri kullanılarak sınıflama işlemi yapılmaktadır.

3.2 Gabor Uzayında Öznitelik Çıkarımı ve Doku Modelleme


Dokuların (3.6) kullanılarak elde edilen Gabor öznitelikleri belli frekans ve yönelimlerde oluşmaktadır. Eğitim aşaması için elde edilen bu özniteliklerden doku örneklemeleri oluşturulur. Örneklem oluşturma işlemi bölüm 3.2.1'de verilmektedir. Oluşturulan örneklem, doku modelleme aşamasında kullanılmaktadırlar. Oluşturulan örneklem beklenen değeri en büyükleme algoritmasına verilerek her doku için Gauss karışım modelleri elde edilmektedir. Gauss Karışım modeli ile doku modelleme Bölüm 3.2.2'de verilmektedir.

3.2.1 Örneklem oluşturma

Örneklem oluşturma işlemi iki farklı yöntemle gerçekleştirilmiştir. Birinci yöntem, bir ölçek ve bir yönelimde filtrelenmiş çıkışın kullanıldığı yöntemdir. Bu yöntem tek kanalda örneklem oluşturma işlemi olarak adlandırılabilir. İkinci yöntem ise bir ölçekte farklı yönelimlerdeki çıkışların tümleştirilerek kanallar arasında ilişkilerin kurulmaya çalışıldığı yöntemdir. Bu yöntem ise çok kanallı örneklem oluşturma olarak adlandırılabilir. Bölüm 3.2.1.1'de tek kanalda örneklem oluşturma işlemi Bölüm 3.2.1.2'de çok kanallı örneklem oluşturma işlemi anlatılmaktadır.

3.2.1.1 Tek kanalda örneklem oluşturma


Jain ve Farrokhnia çok kanallı süzgeçleme yönteminin getirisini süzgeçlenmiş görüntülerin gri düzey istatistiksel özelliklerinin doğrudan kullanılabilmesi olarak belirtmişlerdir [14] ve bu özellikten yola çıkarak sadece bir ölçek ve yönelimde elde edilen öznitelik kullanılarak örneklem grubu oluşturulmuştur. Örneklem oluşturma işlemi Bölüm 2.3.1’de anlatıldığı gibi yapılmıştır fakat bu aşamada doku içeren görüntünün kendisi değil bu görüntünün bir yönelim ve bir ölçekte Gabor süzgeciyle süzgeçlenmiş çıkışı kullanılmaktadır. Şekil 3.8’de bir ölçek ve bir yönelimde örneklem oluşturma işlemi verilmektedir. Bu aşamada veritabanından alınan süzgeçlenmiş görüntü $d \times d$ ’lik P adet küçük yamalara ayrılmaktadır. Yamalar $Z = \{Z_i\}_{i=1}^P$ şeklinde gösterilmektedir. Yama boyutu d değişken olabilmektedir. Elde edilen bu yamalardan $1 \times d^2$ boyutunda örneklem oluşturulur ve doku modellemeye bu vektörler kullanılır.



Şekil 3.8 : Tek kanalda örneklem oluşturma

3.2.1.2 Çok kanallı örneklem oluşturma

Çok kanallı süzgeçleme yaklaşımının içerdiği konulardan bir tanesi farklı kanallar arasındaki ilişkilerin kurulmasıdır. Bu amaçla farklı yönelimlerde süzgeçlenmiş görüntülerinden oluşturulan örneklem birleştirilerek tümleşik örneklem oluşturulur. Şekil 3.9’da çok kanallı örneklem oluşturma blok şeması verilmiştir. Çok kanallı örneklem oluşturma işlemi farklı yönelimlerdeki tek kanalda oluşturulan örneklem birleştirilerek oluşturulmaktadır. Tek kanalda örneklem oluşturma bölüm 3.2.1’de verilmektedir. Bu çalışmada öznitelik çıkarımı 4 yönelim açısında gerçekleştirilmiştir. Her yönelimde elde edilen örneklem birleştirilerek $Z = \{Z_i\}_{i=1}^P$ örneklem grubunu oluştururlar ve doku modelleme işleminde bu örneklem grubu kullanılır.



Şekil 3.9 : Çok kanallı örneklem oluşturma

3.2.2 Gabor uzayında doku modelleme

Bu bölümde Bölüm 3.2.1’de elde edilen Z örneklem grubundan çok değişkenli Gauss karışım modelinin elde edilmesi anlatılmaktadır. Çok boyutlu Gauss karışım modeli bileşenlerinin parametreleri beklenen değeri en büyükleme algoritması ile hesaplanmaktadır. Gauss karışım modelinin boyutu bir örneklemin boyutu kadardır. Her bir örneklemin bir boyutu süzgeç çıkışındaki bir piksel değeridir. Oluşturulan Z ’den m_k parametreleriyle tanımlanan $k=1 \dots K$ adet çok değişkenli Gauss bileşeni hesaplanmaktadır. Her bir m_k , bir ortalama değer vektörü μ_k ve bir değişim matrisi w_k ile tanımlanmaktadır. K adet çok değişkenli Gauss bileşeni ile M olarak isimlendirilen $M = \{m_k\}_{k=1}^K$ şeklinde gösterilen çok değişkenli Gauss karışım modeli elde edilmiş olur. Ortalama değer vektörü μ_k ve bir değişim matrisi w_k ile ifade edilen her bir Gauss karışım bileşeni m_k , Z içindeki bir grup noktayı temsil eder. Böylelikle verilen k . Gauss bileşeni m_k için Z_i noktasının olasılığı (3.11)’de hesaplanır.

$$p(Z_i | \mu_k, \psi) = N(Z_i; \mu_k, \omega_k) \quad (3.11)$$

Burada $\psi = \{\alpha_k, \mu_k, \omega_k\}_{k=1}^K$ çok deęişkenli Gauss karışımının parametre kümesidir ve α_k k . Gauss bileşeninin önsel olasılığıdır. Önsel olasılıkların toplamı $\sum_{k=1}^K \alpha_k = 1$ 'dir. Hiçbir Gauss bileşeninin parametrelerinin bilinmemesinden dolayı verilen parametre kümesi için Z 'nin koşullu olasılığı her bir Z_i için her Gauss bileşeni ile (3.12)'de hesaplanır.

$$p(Z_i | K, \psi) = \sum_{k=1}^K p(Z_i | m_k, \psi) \alpha_k \quad (3.12)$$

Sonrasında bütün küme için log-olabilirlik ifadesini en iyilemesi (3.20)'de verilmiştir.

$$\log p(Z | K, \psi) = \sum_{i=1}^P \log(p(Z_i | m_k, \psi)) \alpha_k \quad (3.13)$$

Bu aşamada ψ parametre kümesi için en büyük olabilirlik kestirimi beklenen değeri en büyükleme algoritması ile eldeki noktaları kullanarak hesaplanmaktadır. Eşitlik (3.14)'teki hale gelir.

$$\psi = \arg \max_{\psi} \log(L(\psi | Z)) = \arg \max_{\psi} \log p(Z_i | K, \psi) \quad (3.14)$$

Bundan sonra ise en büyükleme algoritması döngüsel olarak beklenen değer hesabı ve en büyükleme aşamalarını çağırılmaktadır. İlk adımda ψ parametre kümesi için ilk değerlerini tahmin ederek her bir Z_i yamasını Gauss karışım bileşenlerine atanması gerçekleştirilir. Sonrasında ise her bir t . ara adımda ψ^t parametre grubu hesaplanır. k . Gauss bileşeni verilen Z_i için olabilirliği Bayes' kuralı kullanılarak (3.15)'teki gibi hesaplanır.

$$p(m_k | Z_i, \psi^{(t)}) = \frac{p(Z_i | m_k, \psi^{(t)}) \alpha_k}{\sum_{i=1}^K p(Z_i | m_k, \psi^{(t)}) \alpha_k} \quad (3.15)$$

En büyükleme aşamasında ise log-olabilirliği en büyükleyerek ψ^t parametre grubu (3.16) ile güncellenir.

$$\begin{aligned}
\bar{\alpha}_k &= \frac{1}{P} p(m_k | Z_i, \psi^{(t)}) \\
\bar{\mu}_k &= \frac{\sum_i^P Z_i p(m_k | Z_i, \psi^{(t)})}{\sum_i^P p(m_k | Z_i, \psi^{(t)})} \\
\bar{w}_k &= \frac{\sum_i^P (Z_i - \bar{\mu}_k)(Z_i - \bar{\mu}_k)^T p(m_k | Z_i, \psi^{(t)})}{\sum_i^P p(m_k | Z_i, \psi^{(t)})}
\end{aligned} \tag{3.16}$$

Beklenen değer ve en büyükleme adımları kestirimler kararlılaşınca kadar döngülü bir şekilde tekrar edilirler. Böylelikle çok boyutlu Gauss karışım parametreleri hesaplanmış olunur.

3.3 Görsel Doku Sınıflama


Birinci aşamada veritabanındaki doku örneklerinin Gabor dalgacık fonksiyonu ile oluşturulmuş özniteliklerin çok değişkenli Gauss karışımı parametreleri elde edilmişti. Sınıflama işlemi ise piksel bazında yapılmaktadır. Öncelikle sınıflanacak görüntü eğitim aşamasında kullanılan Gabor dalgacık fonksiyonu ya da fonksiyonlarıyla süzgeçlenir. Eğitim aşamasında tek kanalda yapıldıysa, sınıflanacak görüntünün her bir pikseli için Bölüm 3.2.1.1’de anlatılan işlem yapılır ve her bir piksel için öznitelik vektörü oluşturulur. Eğitim aşamasında çok kanallı örneklemeler oluşturulduysa, sınıflanacak görüntü eğitim aşamasında kullanılan Gabor süzgeçleri ile süzgeçlenir. Sınıflanacak görüntüdeki her bir piksel için Bölüm 3.2.1.2’de anlatılan işlem yapılır ve her piksel için bir öznitelik vektörü oluşturulur. Her bir piksel için oluşturulan öznitelik vektörleri veritabanındaki çok değişkenli Gauss karışımları ile (3.17)’de verilen olabilirlik oranına göre olasılıksal olarak karşılaştırılırlar. O piksel olasılık değerinin en yüksek olduğu sınıfa atanır.

$$p_i(Z_i | \psi_k) = \sum_{k=1}^K p(Z_i | m_k, \psi_k) \alpha_k \tag{3.17}$$

Z_i sınıflanmak istenen piksel için oluşturulan vektör, $p_i(Z_i | \psi_k)$, Z_i vektörünün veritabanındaki t . doku modeline olan olasılıksal yakınlık değeri, m_k , ψ_k ve α_k , t . dokunun k . Gauss bileşeni, parametreleri ve ağırlık katsayısıdır.

4. TESTLER

İkinci ve üçüncü bölümde anlatılan yöntemler, C/C++ programlama dili ve Matlab kullanılarak test edilmiştir. Gabor fonksiyonu ile öznitelik çıkarımı Şekil 4.1’de kullanıcı ara yüzü verilen program ile yapılmaktadır. Öznitelik çıkarımında kullanılan Gabor fonksiyonu Liu Chengjun tarafından yazılmıştır. Görüntü işleme algoritmaları Matlab programlama dilinde “Prtools” kütüphanesi kullanılarak test edilmiştir. Oluşturulan yazılımlarla, veritabanındaki görsel doku örneklerinin okunması, doku örneklerinin çok değişkenli Gauss parametrelerinin belirlenmesi, beklenen değeri en büyükleme algoritmasının çalıştırılması, Gabor dalgacık fonksiyonlarının oluşturulması, görüntülerin süzgeçlenmesi ve olasılık hesapları yaparak piksel düzeyinde sınıflama işlemleri yapabilmektedir. Bunlara ek olarak testler için resimleri birleştiren bir program yazılmıştır. Bu yazılımlarla sınıflamanın başarımları test edilmektedir.



Şekil 4.1 : Yazılım kullanıcı ara yüzü

Testler MIT Vistex veritabanından alınan 128x128 boyutlu görsel doku örnekleriyle yapılmıştır. Görüntüler renkli BMP formatında olup görüntü işleme sırasında gri düzey görüntülere dönüştürülmektedir. Gri düzey dönüşümleri (4.1)'de verilen formülasyona göre yapılmaktadır.

$$Y = 0.299R + 0.587G + 0.114B \quad (4.1)$$

Burada Y gri düzey değeri, R kırmızı renk değeri, G yeşil renk değeri ve B mavi renk değeridir.


Testler ikili sınıflama, üçlü sınıflama ve dörtlü sınıflama olmak üzere üç başlıkta yapılmıştır. Her bir başlıkta Bölüm 2 ve Bölüm 3'te anlatılan yöntemlerin başarımları ve bu başarımlara etki eden parametreler araştırılmıştır. Bu parametreler Bölüm 2'de anlatılan yöntem için yama boyutu ve Gauss karışım sayısıdır. Bölüm 3'te anlatılan yöntemin başarımları yama boyutu ve Gauss karışım sayısına ek olarak Gabor süzgeci parametreleri ve kullanılan yönelim sayısına bağlıdır. Gabor süzgeçlerinin parametre kümelerinin seçimi deneysel olarak belirlenmiştir ve her test için sabit parametre kümesi kullanılmıştır.

4.1 İkili Sınıflama Testleri

Bu bölümdeki her test için MIT Vistex veritabanından iki farklı doku görüntüsü seçilmiştir. Bu görüntüler kullanılarak eğitim yapılmış ve eğitimden elde edilen veriler veritabanına kaydedilmiştir. Eğitim aşamasında görüntülerin %22'si kullanılmıştır. Sınıflama başarımlarını test etmek için eğitim aşamasında kullanılan görüntülerden alınan daire şekilli doku parçaları üst üste eklenerek test görüntüleri oluşturulmuştur. Oluşturulan test görüntülerinin ikili olarak sınıflama başarımları test edilmiştir. Test görüntüleri oluşturulurken, piksellerin ait olduğu sınıf bir dosyada tutulmaktadır ve test sonunda alınan sınıflama sonuçları bu dosya ile karşılaştırılarak sınıflama başarımları elde edilmektedir. Yapılan testlerde yama boyutu $d=\{1,3,5,6,7\}$ ve Gauss karışım sayısı $k=\{1,2,4,5,6\}$ değerleri kullanılmıştır. Test sonuçlarında, her yöntemle ilgili o yama boyutunda alınan en iyi Gauss karışım sayılı sonuç gösterilmiştir.


4.1.1 Food0005-Sand0000 görüntüleri için yapılan sınıflama testleri

Bu bölümde Şekil 4.2 de verilen Food0005.bmp ve Sand0000.bmp görüntüleri için farklı yama boyutu ve Gauss karışım sayıları için test sonuçları verilmiştir.



Şekil 4.2 : a) Food0005 görüntüsü, b) Sand0000 görüntüsü, c) Bileştirilmiş renkli görüntü, d) Birleştirilmiş gri düzey görüntü

Görüntülerin gri düzeyleri kullanılarak yapılan test sonuçları Şekil 4.3'te verilmektedir. Bu testte en yüksek başarımla, yama boyutu $d=5$ ve Gauss karışım sayısı $k=5$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.3.c'de verilmiştir. Görüntüdeki piksellerin % 97.2'si doğru sınıflandırılmıştır. Yama boyutunun büyümesi uzamsal uzayda daha fazla sayıda komşu pikselin istatistiksel ortalamaya katılması anlamına gelmektedir. Bunun sonucunda dokular daha iyi modellenebilmektedir. Buna karşın büyük yama boyutları sınıflanacak pikselin yerel öznelitliklerinin istatistiksel ortalamalara etkisi azaltacaktır. Bu nedenle yama boyutunun optimum şekilde seçilmesi önemlidir.




Şekil 4.3 : Gri düzey kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1, k=4$ b) $d=3, k=4$, c) $d=5, k=5$, d) $d=6, k=4$, e) $d=7, k=5$


Tek kanalda Gabor öznelitiği kullanılarak yapılan sınıflama sonuçları Şekil 4.4'te verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=0$ ve

$\phi_m = \frac{7\pi}{8}$ olarak seçilmiştir. Bu testte en yüksek başarımlı, yama boyutu $d=6$ ve Gauss

karışım sayısı $k=5$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.4.d’de verilmiştir. Görüntüdeki piksellerin %90.42’si doğru sınıflanmıştır.



Şekil 4.4 : Tek kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1, k=2$ b) $d=3, k=6$, c) $d=5, k=2$, d) $d=6, k=2$, e) $d=7, k=2$



Şekil 4.5 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1, k=6$ b) $d=3, k=5$, c) $d=5, k=1$, d) $d=6, k=1$, e) $d=7, k=1$


Şekil 4.5’te çok kanallı Gabor öznitelikleri kullanarak yapılan test sonuçları verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1, f = \sqrt{2}, v=0$ ve yönelim

açısı ϕ_m 0'dan, $\frac{3\pi}{4}$ 'e kadar $\frac{\pi}{4}$ artımlarla alınarak 4 kanal kullanılmıştır. Bu testte en yüksek başarımla, yama boyutu $d=5$ ve Gauss karışım sayısı $k=1$ değerleriyle elde edilmiştir.

En yüksek başarımlı sonuç görüntüsü Şekil 4.5.c'de verilmiştir. Görüntüdeki piksellerin % 86,7'si doğru sınıflandırılmıştır. Bu testte, yönelimli olmayan dokularda Gabor özneliklerinin yüksek başarımlı vermediği görülmektedir.

4.1.2 Water0006 ve Water0007 görüntüleri için yapılan testler

Bu bölümde Şekil 4.6'da verilen Water0006.bmp ve Water0007.bmp görüntüleri için farklı yama boyutu ve Gauss karışım sayıları için test sonuçları verilmiştir.




Şekil 4.6 : a) Water0006 görüntüsü b) Water0007 görüntüsü c) Bileştirilmiş renkli görüntü d) Birleştirilmiş gri düzey görüntü


Görüntülerin gri düzeyleri kullanılarak yapılan test sonuçları Şekil 4.7'de verilmektedir. Bu testte en yüksek başarımla, yama boyutu $d=3$ ve Gauss karışım sayısı $k=1$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.7.b'de verilmiştir. Görüntüdeki piksellerin % 97.1'i doğru sınıflandırılmıştır. Ancak hata matrislerine bakıldığında yama boyutu $d=7$ ve $k=1$ değerleriyle Water0007 dokusuna ait pikseller %19 yanlış alarmla %100 doğru olarak sınıflandırılmıştır.

Tek kanalda Gabor özneliği kullanılarak yapılan sınıflama sonuçları Şekil 4.8'de verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $\nu=1$ ve $\phi_m = 0$ olarak seçilmiştir. Bu testte en yüksek başarımla, yama boyutu $d=3$ ve Gauss karışım sayısı $k=1$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.8.b'de verilmiştir. Görüntüdeki piksellerin %93.3'ü doğru sınıflanmıştır. Ancak hata matrislerine bakıldığında yama boyutu $d=7$ ve $k=1$ değerleriyle Water0007 dokusuna ait pikseller %24 yanlış alarmla %100 doğru olarak sınıflandırılmıştır. Bu testte doku örneklerini birleştirme şekli sınıflama başarımlarına etki etmiştir.

Birleştirilen görüntüde dokular eşit sayıda piksellerden oluşması hata performanslarına yüksek yama boyutları açısından bir performans artışı sağlayabilir.



Şekil 4.7 : Gri düzey kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=1 b) d=3, k=1, c) d=5, k=1, d) d=6, k=1, e) d=7, k=1




Şekil 4.8 : Tek kanallı Gabor öznelikleri kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=1 b) d=3, k=1, c) d=5, k=1, d) d=6, k=1, e) d=7, k=1

Şekil 4.9’da çok kanallı Gabor öznelikleri kullanarak yapılan test sonuçları verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=1$ ve yönelim

açısı ϕ_m 0’dan, $\frac{3\pi}{4}$ ’e kadar $\frac{\pi}{4}$ artırımlarla alınarak 4 kanal kullanılmıştır. Bu testte


en yüksek başarımlı, yama boyutu $d=3$ ve Gauss karışım sayısı $k=1$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.9.b’de verilmiştir. Görüntüdeki piksellerin % 94.2’si doğru sınıflandırılmıştır. Bu test sonucunda yama boyutu büyüdükçe başarımların düştüğü görülmektedir. Bunun nedeninin örnek boyutu olduğu düşünülmektedir. Yama boyutu $d=7$ olarak alınan testte bir boyutu 196 olmaktadır ve bu veri boyutu sınıflama için çok büyüktür.



Şekil 4.9 : Çok kanallı Gabor öznelikleri kullanılarak alınan sonuçlar . d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1$, $k=1$ b) $d=3$, $k=1$, c) $d=5$, $k=1$, d) $d=6$, $k=1$, e) $d=7$, $k=1$

4.1.3 Fabric0010 ve Fabric0016 görüntüleri için yapılan testler


Bu bölümde Şekil 4.10’da verilen Fabric0010.bmp ve Fabric.0016.bmp görüntüleri için farklı yama boyutu ve Gauss karışım sayıları için test sonuçları verilmiştir.



Şekil 4.10 : (a) Fabric.0010 görüntüsü (b) Fabric.0016 görüntüsü (c) Bileştirilmiş renkli görüntü d) Birleştirilmiş gri düzey görüntü

Görüntülerin gri düzeyleri kullanılarak yapılan test sonuçları Şekil 4.11’de verilmektedir. Bu testte en yüksek başarımlı, yama boyutu $d=6$ ve Gauss karışım sayısı $k=5$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil


4.11.d’de verilmiştir. Görüntüdeki piksellerin % 96.8’i doğru sınıflandırılmıştır. Bölüm 4.1.2’de yapılan testlerde en iyi sonuçlar Gauss karışım sayısı $k=1$ değerinde alınmıştır. Bu bölümde yapılan testlerde ise Gauss karışım sayısı $k=4$ ve üstü değerlerde en yüksek başarımları sağlamıştır. En uygun Gauss karışım sayısının dokuların yapısına bağlı olarak değiştiği gözlenmektedir.




Şekil 4.11 : Gri düzey kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1, k=6$ b) $d=3, k=4$, c) $d=5, k=5$, d) $d=6, k=5$, e) $d=7, k=5$

Tek kanalda Gabor özneliği kullanılarak yapılan sınıflama sonuçları Şekil 4.12’de verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=3$ ve $\phi_m = \frac{\pi}{2}$ olarak seçilmiştir. Bu testte en yüksek başarımlar, yama boyutu $d=6$ ve Gauss karışım sayısı $k=5$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.12.d’de verilmiştir. Görüntüdeki piksellerin %96’sı doğru sınıflanmıştır.

Şekil 4.13’te çok kanallı Gabor öznelikleri kullanarak yapılan test sonuçları verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=3$ ve yönelim açısı ϕ_m 0’dan, $\frac{3\pi}{4}$ ’e kadar $\frac{\pi}{4}$ artımlarla alınarak 4 kanal kullanılmıştır. Bu testte en yüksek başarımlar, yama boyutu $d=6$ ve Gauss karışım sayısı $k=1$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.13.d’de verilmiştir. Görüntüdeki piksellerin % 96.9’u doğru sınıflandırılmıştır. Bununla birlikte bu doku örneği için en iyi sonucu bu yöntem vermiştir. Bunun nedeni ise bu dokuların yönelimli doku özelliği göstermesi olduğu düşünülmektedir.




Şekil 4.12 : Tek kanalda Gabor öznitelikleri kullanılarak alınan sonuçlar . d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1$, $k=4$ b) $d=3$, $k=6$, c) $d=5$, $k=4$, d) $d=6$, $k=1$, e) $d=7$, $k=2$




Şekil 4.13 : Çok kanallı Gabor öznitelikleri kullanılarak alınan sonuçlar . d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1$, $k=6$ b) $d=3$, $k=4$, c) $d=5$, $k=1$, d) $d=6$, $k=1$, e) $d=7$, $k=1$

Bu testte dikkat çeken başka bir yön ise Gabor uzayında yapılan sınıflama testlerinde düşük sayıda karışım sayısı ile yüksek başarımlı modelleme yapılabilmesidir. Şekil 4.14 'te Gauss karışım sayısı $k=1$ için gri düzey sınıflama başarımlı %92'ye düşerken, Gabor uzayında yapılan testlerde sınıflama başarımlı %96 seviyelerindedir. Bu durumun nedeni Gabor dönüşüm uzayının öznitelikleri daha yoğun (compact) bir

duruma dönüştürmesi olduğu düşünülmektedir. Bu durum Şekil 4.15'te uzamsal uzayda ve Gabor uzayında 6x6'lık örneklemelerin ortalama ve standart sapma grafikleri çizdirilerek gösterilmiştir.




Şekil 4.14 : Gauss karışım sayısının başarıma etkisi, birinci satır gri düzey sonuçlar ikinci satır tek kanallı Gabor öznelikleri sonuçları, üçüncü satır çok kanalda Gabor öznelikleri sonuçları



Şekil 4.15 : Uzamsal uzayda ve Gabor uzayında ortalama-standart sapma grafiği

Bu testte, farklı olarak çok kanallı Gabor öznitelikleri oy çokluğu (majority voting) kuralıyla birleştirilmiş ve sonuç görüntüsü Şekil 4.16'da verilmiştir. Birleştirme işleminde, tek kanallı Gabor özniteliklerini kullanarak 4 farklı yönelimde ayrı ayrı elde edilen sonuçlar oy çokluğu kuralıyla birleştirilmiştir. Bu birleştirme yöntemiyle başarımlar diğer yöntemlerle aynı seviyede kalmış ve %96.5 olmuştur. Oy çokluğu kuralının getirisi dokuların Gauss karışım modelinin daha az parametre sayısı ile temsil edilmesidir.



Şekil 4.16 : Gabor uzayında oy çokluğu kuralıyla sınıflama, a) Tek kanalda alınan sonuç, b) Çok kanalda Gabor özniteliklerinin tümleştirilerek alınan sonuç, c) Oy çokluğu kuralı kullanılarak elde edilen sonuç (d ,yama boyutu, k Gauss karışımı bileşen sayısı)


İkili sınıflama testlerinde %90 ve üzerinde başarımlar gözlenmiştir. Görüntülerin gri düzeyleri kullanılarak yapılan sınıflamalarda %95'in üstünde başarımlar elde edilmiştir. 4.1.3'te yapılan testte 3. yöntem en iyi sınıflama başarımını göstermiştir.

4.2 Üçlü Sınıflama Testi


Bu bölümdeki her test için MIT Vistex veritabanından üç farklı doku görüntüsü seçilmiştir. Bu görüntüler kullanılarak eğitim yapılmış ve eğitimden elde edilen veriler veritabanına kaydedilmiştir. Eğitim aşamasında görüntülerin %22'si kullanılmıştır. Sınıflama başarımlarını test etmek için eğitim aşamasında kullanılan görüntülerden alınan daire ve dikdörtgen şekilli doku parçaları üst üste eklenerek test görüntüleri oluşturulmuştur. Oluşturulan test görüntülerinin üç sınıflı sınıflama başarımları test edilmiştir. Test görüntüleri oluşturulurken, piksellerin ait olduğu sınıf bir dosyada tutulmaktadır ve test sonunda alınan sınıflama sonuçları bu dosya ile karşılaştırılarak sınıflama başarımları elde edilmektedir. Yapılan testlerde yama boyutu $d=\{1,3,5,6,7\}$ ve Gauss karışım sayısı $k=\{1,2,4,5,6\}$ değerleri kullanılmıştır. Test sonuçlarında, her yöntemle ilgili o yama boyutunda alınan en iyi Gauss karışım sayısı sonuç gösterilmiştir.

4.2.1 Fabric0010-Fabric0002-Fabric0016 görüntüleri için yapılan testler

Bu bölümde Şekil 4.17’de verilen Fabric0010.bmp, Fabric0002.bmp ve Fabric0016.bmp görüntüleri için farklı yama boyutu ve Gauss karışım sayıları için test sonuçları verilmiştir.



Şekil 4.17 : a)Fabric0010 görüntüsü, b)Fabric0002 görüntüsü, c)Fabric0016 görüntüsü, d) Birleştirilmiş renkli görüntü e) Birleştirilmiş gri düzey görüntü



Şekil 4.18 : Gri düzey kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1$, $k=2$ b) $d=3$, $k=6$, c) $d=5$, $k=6$, d) $d=6$, $k=6$, e) $d=7$, $k=5$

Görüntülerin gri düzeyleri kullanılarak yapılan test sonuçları Şekil 4.18’de verilmektedir. Bu testte en yüksek başarımlı sonuç, yama boyutu $d=6$ ve Gauss karışım sayısı $k=6$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil

4.18.d’de verilmiştir. Görüntüdeki piksellerin % 92’si doğru sınıflandırılmıştır. Çizelge 4.1’de yama boyutu $d=6$ ve Gauss karışım sayısı $k=6$ ve yama boyutu $d=7$ ve Gauss karışım sayısı $k=5$ değerleriyle elde edilen sonuçlar için hata matrisleri verilmiştir. Birinci parametre kümesi Fabric0002 ve Fabric0016 dokularını daha iyi sınıflarken ikinci parametre kümesi Fabric0010’u daha yüksek başarımla sınıflamaktadır.


Çizelge 4.1 : (d) ve (e) şıkları için hata matrisi(Confussion Matrix)

d=6, k=6	Fabric 0010	Fabric 0002	Fabric 0016
Fabric 0010	10209	171	62
Fabric 0002	626	2464	30
Fabric 0016	405	22	2299

(a)

d=7, k=5	Fabric 0010	Fabric 0002	Fabric 0016
Fabric 0010	10415	107	16
Fabric 0002	749	2348	23
Fabric 0016	463	3	2260


(b)



Şekil 4.19 : Tek kanalda Gabor özneteliği kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1$, $k=2$, b) $d=3$, $k=6$, c) $d=5$, $k=6$, d) $d=6$, $k=6$, e) $d=7$, $k=5$

Tek kanalda Gabor özneteliği kullanılarak yapılan sınıflama sonuçları Şekil 4.19’da verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f=\sqrt{2}$, $v=3$ ve $\phi_m = \frac{3\pi}{8}$ olarak seçilmiştir. Bu testte en yüksek başarımla, yama boyutu $d=7$ ve Gauss

karışım sayısı $k=5$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.19.e’de verilmiştir. Görüntüdeki piksellerin %86.7’si doğru sınıflanmıştır.




Şekil 4.20 : Çok kanallı Gabor öznelilikleri kullanılarak alınan sonuçlar . d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1$, $k=6$ b) $d=3$, $k=6$, c) $d=5$, $k=4$, d) $d=6$, $k=2$, e) $d=7$, $k=1$

Şekil 4.20’de çok kanallı Gabor öznelilikleri kullanarak yapılan test sonuçları verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=3$ ve yönelim açısı ϕ_m 0’dan, $\frac{3\pi}{4}$ ’e kadar $\frac{\pi}{4}$ artımlarla alınarak 4 kanal kullanılmıştır. Bu testte en yüksek başarımlı, yama boyutu $d=6$ ve Gauss karışım sayısı $k=2$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.20.d’de verilmiştir. Görüntüdeki piksellerin % 90’ı doğru sınıflandırılmıştır. Bu hata oranıyla gri düzey kullanılarak yapılan sınıflama başarımlına oldukça yakın bir değer elde edilmiştir.


4.2.2 Flowers0007-Fabric0014-Water0006 görüntüleri için yapılan testler

Bu bölümde Şekil 4.21’de verilen Flowers0007.bmp, Fabric0014.bmp ve Water0006.bmp görüntüleri için farklı yama boyutu ve Gauss karışım sayıları için test sonuçları verilmiştir.

Görüntülerin gri düzeyleri kullanılarak yapılan test sonuçları Şekil 4.22’de verilmektedir. Bu testte en yüksek başarımlı, yama boyutu $d=6$ ve Gauss karışım sayısı $k=6$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.22.d’de verilmiştir. Görüntüdeki piksellerin %93.4’ü doğru sınıflandırılmıştır.




Şekil 4.21 : a)Flowers0007 görüntüsü, b)Fabric0014 görüntüsü, c)Water0006 görüntüsü, d) Bileştirilmiş renkli görüntü e)Birleştirilmiş gri düzey görüntü




Şekil 4.22 : Gri düzey kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=1 b) d=3, k=6, c) d=5, k=6, d) d=6, k=6, e) d=7, k=5

Tek kanalda Gabor özneliği kullanılarak yapılan sınıflama sonuçları Şekil 4.23'te verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f=\sqrt{2}$, $v=2$ ve $\phi_m = \frac{3\pi}{8}$ olarak seçilmiştir. Bu testte en yüksek başarımlı sonuç görüntüsü Şekil 4.23.d'de verilmiştir. Görüntüdeki piksellerin %89.2'si doğru sınıflanmıştır



Şekil 4.23 : Tek kanalda Gabor öz niteliği kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=4 b) d=3, k=6, c) d=5, k=6, d) d=6, k=6, e) d=7, k=5



Şekil 4.24 : Çok kanalda Gabor öz niteliği kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=6 b) d=3, k=4 c) d=5, k=4, d) d=6 k=2, e) d=7, k=1

Şekil 4.24'te çok kanallı Gabor öz nitelikleri kullanarak yapılan test sonuçları verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=2$ ve yönelim açısı ϕ_m 0'dan, $\frac{3\pi}{4}$ 'e kadar $\frac{\pi}{4}$ artımlarla alınarak 4 kanal kullanılmıştır. Bu testte en yüksek başarımlı, yama boyutu $d=6$ ve Gauss karışım sayısı $k=2$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.24.d'de verilmiştir. Görüntüdeki piksellerin % 90.9'u doğru sınıflandırılmıştır. Bu hata oranıyla gri

düzey kullanılarak yapılan sınıflama başarımına oldukça yakın bir değer elde edilmiştir.

Üçlü sınıflama testlerinde yüksek başarımli sınıflamaların çoğu $k=5$, $k=6$ gibi büyük Gauss karışım bileşeni değerleriyle sağlanmıştır. Sınıflanacak görüntülerin karmaşıklığı oranında Gauss karışım bileşenlerinin sayısı artmaktadır. Böylelikle doku daha iyi modellenenilmektedir. Ayrıca çok kanallı Gabor süzgeçleme yöntemiyle yapılan testlerde hata sınıflama başarımının gri düzey hata sınıflama başarımına yakın olduğu görülmüştür.


4.3 Dörtlü Sınıflama Testleri

Bu bölümdeki her test için MIT Vistex veritabanından dört farklı doku görüntüsü seçilmiştir. Bu görüntüler kullanılarak eğitim yapılmış ve eğitimden elde edilen veriler veritabanına kaydedilmiştir. Eğitim aşamasında görüntülerin %22'si kullanılmıştır. Sınıflama başarımlarını test etmek için eğitim aşamasında kullanılan görüntülerden alınan daire, dikdörtgen ve kare şekilli doku parçaları üst üste eklenerek test görüntüleri oluşturulmuştur. Oluşturulan test görüntülerinin dört sınıflı sınıflama başarımları test edilmiştir. Test görüntüleri oluşturulurken, piksellerin ait olduğu sınıf bir dosyada tutulmaktadır ve test sonunda alınan sınıflama sonuçları bu dosya ile karşılaştırılarak sınıflama başarımları elde edilmektedir. Yapılan testlerde yama boyutu $d=\{1,3,5,6,7\}$ ve Gauss karışım sayısı $k=\{1,2,4,5,6\}$ değerleri kullanılmıştır. Test sonuçlarında, her yöntemle ilgili o yama boyutunda alınan en iyi Gauss karışım sayılı sonuç gösterilmiştir.

4.3.1 Food5-Fabric10-Fabric14-Water7 görüntüleri için yapılan testler

Bu bölümde Şekil 4.25'te verilen Food0005.bmp, Fabric0010.bmp ve Water0007.bmp görüntüleri için farklı yama boyutu ve Gauss karışım sayıları için test sonuçları verilmiştir.

Görüntülerin gri düzeyleri kullanılarak yapılan test sonuçları Şekil 4.26'da verilmektedir. Bu testte en yüksek başarımlı, yama boyutu $d=5$ ve Gauss karışım sayısı $k=6$ değerleriyle elde edilmiştir. En yüksek başarımli sonuç görüntüsü Şekil 4.26.c'de verilmiştir. Görüntüdeki piksellerin % 90.2'si doğru sınıflandırılmıştır. Çizelge 4.2'de yama boyutu $d=5$ ve Gauss karışım sayısı $k=6$ ve yama boyutu $d=6$ ve Gauss karışım sayısı $k=6$ değerleriyle alınan sonuçlar için hata matrisleri verilmiştir.



Şekil 4.25 : a)Food0005 görüntüsü, b)Fabric0010 görüntüsü, c)Fabric0014 görüntüsü, d) Water0007 görüntüsü e)Bileştirilmiş renkli görüntü f) Birleştirilmiş gri düzey görüntü

Tek kanalda Gabor özniteliği kullanılarak yapılan sınıflama sonuçları Şekil 4.27’de verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=2$ ve $\phi_m = 0$ olarak seçilmiştir. Bu testte en yüksek başarımlı sonuç görüntüsü Şekil 4.27.d’de verilmiştir. Görüntüdeki piksellerin %79.6’sı doğru sınıflanmıştır. Dörtlü sınıflamada bu yöntem gri düzeyleri kullanılarak yapılan test sonuçlarına göre daha düşük başarımlıdır.


Çizelge 4.2 : (d) ve (e) şıkları için hata matrisi(Confussion Matrix)

d=5 k=6	Food 0005	Fabric 0010	Fabric 0014	Water 0007
Food 0005	7399	839	118	9
Fabric 0010	32	3578	9	0
Fabric 0014	13	285	2187	15
Water 0007	15	214	57	1614


(a)

d=6 k=6	Food 0005	Fabric 0010	Fabric 0014	Water 0007
Food 0005	7220	1006	79	10
Fabric 0010	13	3604	2	0
Fabric 0014	5	306	2185	4
Water 0007	17	260	41	1582

(b)




Şekil 4.26 : Gri düzey kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=1 b) d=3, k=6, c) d=5, k=6, d) d=6, k=6, e) d=7, k=5



Şekil 4.27 : Tek kanalda Gabor özneliği kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) d=1, k=1 b) d=3, k=6, c) d=5, k=4, d) d=6, k=5, e) d=7, k=5


Şekil 4.28’de çok kanallı Gabor öznelilikleri kullanarak yapılan test sonuçları verilmektedir. Gabor fonksiyonu parametreleri olarak $\sigma=1$, $f = \sqrt{2}$, $v=2$ ve yönelim açısı ϕ_m 0’dan, $\frac{3\pi}{4}$ ’e kadar $\frac{\pi}{4}$ artırımlarla alınarak 4 kanal kullanılmıştır. Bu testte en yüksek başarımlı, yama boyutu $d=5$ ve Gauss karışım sayısı $k=2$ değerleriyle elde edilmiştir. En yüksek başarımlı sonuç görüntüsü Şekil 4.28.d’de verilmiştir. Görüntüdeki piksellerin % 84’sı doğru sınıflandırılmıştır.




Şekil 4.28 : Çok kanalda Gabor özneliği kullanılarak alınan sonuçlar. d, yama boyutu ve k, Gauss karışım sayısı olmak üzere a) $d=1, k=1$, b) $d=3, k=1$ c) $d=5, k=2$ d) $d=6, k=2$

4.4 [17] Nolu Referans Makalesi İle Karşılaştırma Sonuçları

Şekil 4.29 ve 4.30'da, [17] nolu makalede verilen sonuç görüntüleri ve bölüm 4.1'de elde edilen sonuç görüntüleri verilmiştir. Bu testlerde [17]'de elde edilen sonuçlara yakın seviyelerde başarımlar elde edilmiştir. İkinci sütunda verilen Bölüm 4.1'de Gabor uzayında elde edilen sonuçlarda [17] makalesinde elde edilen sonuçlara göre iyileşmeler gözlenmektedir. Bunun nedeni [17]'de Gabor uzayında bir Gauss karışım modellemesi yapılmayıp filtre sonuçları sınıflamada kullanılması olabilir. Bölüm 4.1'de elde edilen sonuçlarda Gabor uzayında Gauss karışım modelleme yöntemi kullanılmıştır.



Şekil 4.29 : Food0005 Sand0000 görüntüleri sınıflama sonuçları, 1. satır [17]'de elde edilen sonuçlar, 2. satır Bölüm 4.1.1'de elde edilen sonuçlar. 2. sütun Gabor uzayında elde edilen sonuçlar. 3. sütun uzamsal uzayda elde edilen sonuçlar



Şekil 4.30 : Water0006 Water0007 görüntüleri sınıflama sonuçları, 1. satır [17]'de elde edilen sonuçlar, 2. satır Bölüm 4.1.2'de elde edilen sonuçlar. 2. sütun Gabor uzayında elde edilen sonuçlar. 3. sütun uzamsal uzayda elde edilen sonuçlar

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada görsel doku sınıflama problemi üstünde durulup görsel doku analizi yöntemleri ve uygulama alanlarına değinilmiştir. Görsel doku sınıflama için iki farklı yöntem gerçekleştirilmiştir.

İlk yöntem, iki aşamadan oluşmaktadır. Birinci aşamada eldeki doku örneğinden dokuyu temsil eden farklı boyutlarda olabilen küçük yamalarla dokuyu modelleyen çok boyutlu Gauss karışımı parametreleri elde edilmektedir. Böylelikle doku, çok boyutlu Gauss karışım modeli ile modellenmiş olur ve belli bir ortalama ve değişinti bileşenleri ile ifade edilir. Gauss karışım modelleri beklenen değeri en büyükleme algoritması kullanılarak elde edilmektedir. İkinci aşamada ise sisteme verilen doku örneğinin o dokuya ne kadar yakın olduğu hesaplanarak sınıflama yapılmaktadır. Sınıflama işleminde Gauss Karışım parametreleri olabilirlik oranı (likelihood ratio) kullanılmaktadır. Bu yöntem ikili sınıflama testlerinde %95'in üzerinde başarımlar sağlamıştır. Üçlü ve dörtlü sınıflama testlerinde başarımlar ikili sınıflama testlerine göre daha düşüktür. Üçlü ve dörtlü sınıflama testlerinde problemin karmaşıklığı artmıştır. Bu nedenle bu testlerde dokular çok sayıda (5-6 adet) Gauss bileşeni ile modellendiklerinde başarımları yükselmiştir.

Gerçeklenen ikinci yöntemde insan görme sistemini en iyi modelleyen süzgeçlerden biri olan farklı yönelim ve ölçeklerde frekans uzayı özelliklerini inceleyebilen Gabor süzgeçleri kullanılmıştır. Yenilik olarak Gabor dalgacık fonksiyonu ile elde edilen öznitelikler çok değişkenli Gauss karışımlarıyla modellenmiştir. Gabor süzgeçleri kullanarak gerçekleştirilen doku sınıflama işlemi üç adımdan oluşmaktadır. Birinci adımda Gabor süzgeçleriyle dokuların belli frekans ve yönelimlerdeki öznitelikleri çıkarılır ve bu öznitelikler kullanılarak örneklemeler oluşturulur. İkinci adımda süzgeç çıkışlarındaki öznitelikler beklenen değeri en büyükleme algoritması yardımıyla çok değişkenli Gauss karışımı modeli ile modellenir. Üçüncü adımda, sınıflanacak görüntü, Gabor süzgeçleriyle süzgeçlenir ve ikinci adımda belirlenen doku modelleri kullanılarak en büyük olabilirlik kuralına göre piksel bazında karşılaştırma yapılır. Pikseller ise en yüksek olabilirlik oranına göre sınıflanır. Bu yöntemde öznitelikler

iki farklı şekilde kullanılmıştır. Birinci yöntemde tek kanal çıkışı Gauss karışım modeli ile modellenmiştir. İkinci yöntemde ise çok kanallı bir yapı denenmiştir. Çok kanallı yapıda farklı yönelimlerdeki Gabor öznitelikleri Gauss Karışım modelleri modellenerek kanallar arasında bağlantı kurulması hedeflenmiştir. Çok kanallı yapı tek kanallı yapıya göre daha yüksek başarılı sonuçlar vermiştir. Gabor öznitelik kullanımıyla sınıflama başarımı ilk yöntemin başarımından daha yüksek olmasa da ona yakın bir başarımla sağlamış ve Bölüm 4.1.3'te yapılan testlerde daha yüksek başarımla sağlamıştır. Gabor özniteliklerinin kullanımı çok kanallı yapıda yüksek boyut problemi oluşturabilmektedir ve bir örnek 196 boyutlu yapıya kadar çıkabilmektedir. Bu nedenle temel bileşen analizi gibi boyut düşürme yöntemleriyle boyut düşürme işlemi yapılabilir.

Yapılan testlerde gözlenen başka bir durum ise doku özniteliklerinin Gabor uzayında daha yoğun (compact) bir duruma dönüşmesidir. Bu durumun getirisi kullanılacak Gauss karışım modelinin karmaşıklığını düşürmesidir.

Bundan sonraki çalışmalarda ise gri düzey görüntüler yerine renk bilgisi kullanılabilir. Ayrıca Gabor dalgacık fonksiyonu öznitelikleri için farklı dokularda farklı parametre grupları belirlenerek her dokunun kendine ait frekans ve yönelim özellikleri kullanılarak başarımların artırılması sağlanabilir.

KAYNAKLAR

- [1] **Tuceryan M., Jain A. K.**, 1998: Texture Analysis In: The Handbook of Pattern Recognition and Computer Vision (2nd Edition), Chen C. H., Pau L. F., Wang P. S. P. (eds.), World Scientific Publishing Co., pp. 207-248.
- [2] **Sklansky, J.**, 1978, Image Segmentation and Feature Extraction, IEEE Transactions on Systems, Man, and Cybernetics, SMC-8, pp. 237-247.
- [3] **Bovik A.C., Clark M., Geisler W.S.**, 1990, Multichannel Texture Analysis Using Localized Spatial Filters, IEEE Transactions on PAMI, vol. 12, no. 1, pp. 55-73.
- [4] **Haralick R. M.**, 1979, Statistical and structural approaches to texture, Proc. IEEE, vol. 67, no. 5, pp. 786-804.
- [5] **Khoo H., Ong H., Wong Y.**, 2008, Image Texture Classification using Combined Grey Level Co-occurrence Probabilities and Support Vector Machines”, IEEE Computer Vision Society Fifth International Conference on Computer Graphics, Imaging and Visualization, 2008, Washington, pp. 180-184.
- [6] **Dyer C., Hong T., Rosenfeld A.**, 1980, Texture Classification Using Gray Level Cooccurrence Based on Edge Maxima, IEEE Transactions On Systems, MAN, and Cybernetics, VOL. SMC-10, NO. 3, pp. 158-163.
- [7] **Bai X., Wang K., Wang H.**, 2005, Research on the classification of wood texture based on Gray Level Co-occurrence Matrix, Journal of Harbin Institute of Technology, vol. 37, pp. 1667-1670.
- [8] **Mandelbrot, B. B.**, 1983, The Fractal Geometry of Nature, New York , W. H Freeman and Company.
- [9] **Tuceryan, M. and Jain A. K.**, 1990, Texture Segmentation Using Voronoi Polygons, 1990, IEEE Transactions On Pattern Analysis and Machine Intelligence, vol. 12, pp. 211-216.
- [10] **Ngan H., Pang G., Yung N.**, 2007, Motif-based defect detection for patterned fabric, Pattern Recognition, Vol. 41, pp. 1878-1894.
- [11] **Pentland A.**, 1984, Fractal-based description of natural scenes, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 6, pp. 661-674.

- [12] **Myint S. W.**, 2003, Fractal approaches in texture analysis and classification of remotely sensed data: comparisons with spatial autocorrelation techniques and simple descriptive statistics, *International Journal Of Remote Sensing*, Vol. 24, No. 9, pp. 1925-1947.
- [13] **Daugman J. G.**, 1988, Complete Discrete 2-D Gabor Transforms by Neural Networks for Image Analysis and Compression, *IEEE Transactions On Acoustics, Speech, And Signal Processing*. Vol. 36. No. 7. pp. 1169-1179.
- [14] **Jain A. K., Farrokhnia F.**, 1991, Unsupervised Texture Segmentation Using Gabor Filters, *Pattern Recognition*, Vol. 24, pp, 1167-1186.
- [15] **Bianconi F., Fernandez A.**, 2007, Evaluation of the effects of Gabor filter parameters on texture classification, *Pattern Recognition*, vol. 40, pp. 3325-3335.
- [16] **Campos J., Kasparis T.**, Classification of periodic patterns using Hough transform, 1994, Southeastcon '94. 'Creative Technology Transfer - A Global Affair', Proceedings of the 1994 IEEE, 10-13 Apr 1994, Miami , pp.367 – 371.
- [17] **Xie X., Mirmehdi M.**, 2007, TEXEMS: Texture Exemplars for Defect Detection on Random Textured Surfaces, *IEEE Transactions On Pattern Analysis and Machine Intelligence*, vol. 29, no. 8, pp. 1454-1464.
- [18] **Daugman, J.G.**, 1980, Two-dimensional spectral analysis of cortical receptive field profiles, *Vision Research*, 20, pp. 847-856.
- [19] **Varma M. , Zisserman A.**, 2003, Texture Classification: Are Filter Banks Necessary?, *Proc. IEEE Conference Computer Vision and Pattern Recognition*, pp. 691-698.
- [20] **Duda, R.O., Hart ,E. P.,Stork D. G.**, 1973, *Pattern Clasification* , Second Edition, John Wiley&Sons.
- [21] **Buhmann J., Langea N. D., Von Der Malsburg C.**, 1989, Distortion Invariant Object Recognition by Matching Hierarchically Labeled Graphs , in *Proceedings IJCNN International Conference Neural Networks*, Washington,DC, IEEE, pp. 155-159.
- [22] **Liu C.**, 2004, Gabor-Based Çekirdek PCA with Fractional Power Polynomial Models for Face Recognition, *IEEE Transactions On Pattern Analysis and Machine Intelligence*, Vol. 26, No 5, pp.572-581.
- [23] **Prasad N.S. V., Domke J.**, 2005, Gabor Filter Visualization, Technical Report, University of Maryland

- [24] **Lades M., Vorbrüggen J. C., Buhmann J., Lange J., Malsburg C., Würtz R. P. Konen W.**, 1993, Distortion Invariant Object Recognition in the Dynamic Link Architecture, IEEE Transactions on Computers, Vol. 42, No 3, pp. 300-310.

ÖZGEÇMİŞ



Ad Soyad: Yiğitcan SAVRAN
Doğum Yeri ve Tarihi: İzmir / 29.11.1983
Lisans Üniversitesi: İstanbul Teknik Üniversitesi
Lise: İzmir Fen Lisesi

İş Deneyimi:

- SIEMENS-Türkiye (Şubat 2007 – Nisan 2007)
Yazılım ve Test Mühendisliği (C/C++)
- SIEMENS-PG Group - Karlsruhe (Nisan 2007 – Kasım 2007)
Yazılım ve Test Mühendisliği (C/C++)
- EVOLINE TR (Kasım 2007– Ocak 2008)
Yazılım ve Test Mühendisliği (C/C++)
- Çoğul Ortam İşaret İşleme ve Örüntü Tanımı Laboratuvarı (Şubat 2008-...)
Araştırma Asistanı