

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DOKU TANIMADA ŞEKİL BİLGİSİ KULLANARAK
YENİ ÖZNİTELİKLERİN ELDE EDİLMESİ**

DOKTORA TEZİ

Nihan KAZAK ÇERÇEVİK

Enstitü Anabilim Dalı : **BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**

Tez Danışmanı : **Dr. Öğr. Üyesi Mehmet KOÇ**

Ortak Tez Danışmanı : **Doç. Dr. Devrim AKGÜN**

Kasım 2018

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DOKU TANIMADA ŞEKİL BİLGİSİ KULLANARAK
YENİ ÖZNİTELİKLERİN ELDE EDİLMESİ**


DOKTORA TEZİ


Nihan KAZAK ÇERÇEVİK

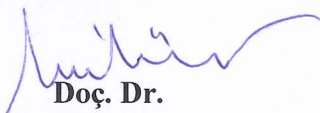
**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**


Bu tez 15 / 11 /2018 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.


**Dr. Öğretim Üyesi
Mehmet KOÇ
Jüri Başkanı**


**Doç. Dr.
Cüneyt BAYILMIŞ
Üye**


**Dr. Öğretim Üyesi
Serap KAZAN
Üye**


**Doç. Dr.
Nilüfer YURTAY
Üye**


**Doç. Dr.
Tolga YÜKSEL
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Nihan KAZAK ÇERÇEVİK

30.10.2018

TEŐEKKÜR

Doktora eđitimim süresince deđerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteđini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren deđerli danışman hocam Dr. Öğr. Üyesi Mehmet KOÇ'a ve ortak danışmanım Doç. Dr. Devrim AKGÜN'e çok teşekkür ederim.

Hayatım boyunca maddi, manevi hiçbir zaman desteklerini esirgemeyen, beni her zaman yüreklendiren ve kızları olduğum için çok şanslı hissettiğim aileme, bu süreç boyunca yaşadığım her zorlu durumdan beni kaldıran, benimle birlikte üzülen, sevinen, her anımda yanımda olan ve anlayış gösteren sevgili eşim Ali Erdem ÇERÇEVİK'e sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	viii
ÖZET	ix
SUMMARY	x
BÖLÜM 1.	
GİRİŞ	1
1.1. Literatürdeki Çalışmalar	2
1.2. Tezin Literatüre Katkısı	10
1.3. Tez Organizasyonu	11
BÖLÜM 2.	
YEREL İKİLİ ÖRÜNTÜLER (LBP)	13
BÖLÜM 3.	
SINIFLANDIRICILAR	20
3.1. Doğrusal Regresyon Sınıflandırıcı (LRC)	20
3.2. Destek Vektör Makineleri (SVM)	21
3.3. Doğrusal Ayırtaç Analizi (LDA)	23
3.4. Log-likelihood İstatistiği	24
3.5. χ^2 Testi	24

BÖLÜM 4.

SPİRALLİ YEREL İKİLİ ÖRÜNTÜLER	26
4.1. Tek Spiralli Yerel İkili Örüntüler (S1LBP)	27
4.2. Çift Spiralli Yerel İkili Örüntüler (S2LBP)	30
4.3. Dört Spiralli Yerel İkili Örüntüler (S4LBP)	32

BÖLÜM 5.

DENEYSEL SONUÇLAR	37
5.1. Doku Tanıma Uygulamaları	37
5.1.1. Spiral şeklinin belirlenmesi	39
5.1.2. Sınıflandırma yönteminin belirlenmesi	41
5.1.3. Geliştirilen yöntemlerin testi	45
5.1.4. Doku tanımda kenar bilgilerinin kullanımı	52
5.2. Yüz Tanıma Uygulamaları	57
5.3. Öznitelik Seçimi	61

BÖLÜM 6.

SONUÇ VE ÖNERİLER	69
KAYNAKLAR	72
ÖZGEÇMİŞ	77

SİMGELER VE KISALTMALAR LİSTESİ

BSIF	: İkileştirilmiş istatistiksel görüntü öznitelikleri
CLBC	: Tamamlanmış yerel ikili sayı
CLBP	: Tamamlanmış yerel ikili örüntüler
CURet	: Columbia-Utrecht yansıma ve doku veritabanı
DRLBP	: Baskın döndürülmüş yerel ikili örüntüler
ELBP	: Uzatılmış yerel ikili örüntüler
ELGS	: Genişletilmiş yerel grafik yapısı
EULBP	: Tekdüze uzatılmış yerel ikili örüntüler
LBC	: Yerel ikili sayı
LBP	: Yerel ikili örüntüler
LBP ^{riu2}	: Dönme değişmez tekdüze örüntüler
LDA	: Doğrusal ayırtaç analizi
LEP	: Yerel enerji örüntüsü
LRC	: Doğrusal regresyon sınıflandırıcı
LTP	: Yerel üçlü örüntüler
MRELBP	: Medyan gürbüz geliştirilmiş yerel ikili örüntüler
MSJLBP	: Çok ölçekli ortak kodlanmış yerel ikili örüntüler
NRLBP ^{riu2}	: Gürültü dayanıklı yerel ikili örüntüler
PCA	: Temel bileşen analizi
PRICoLBP	: Çiftli dönme değişmez birliktelik yerel ikili örüntüler
RBF	: Radyal temelli fonksiyon
S1LBP	: Tek spiralli yerel ikili örüntüler
S1LBP_EI	: Kenar bilgili tek spiralli yerel ikili örüntüler
S1ULBP	: Tek spiralli tekdüze yerel ikili örüntüler
S2LBP	: Çift spiralli yerel ikili örüntüler
S2LBP_EI	: Kenar bilgili çift spiralli yerel ikili örüntüler

S2ULBP : Çift spiralli tekdüze yerel ikili örüntüler
S4LBP : Dört spiralli yerel ikili örüntüler
S4LBP_EI : Kenar bilgili dört spiralli yerel ikili örüntüler
S4ULBP : Dört spiralli tekdüze yerel ikili örüntüler
SIFT : Ölçek deęişmez öznitelik dönüşümü
SVM : Destek vektör makineleri
UIUC : Illinois Urbana-Champaign üniversitesi
ULBP : Tekdüze yerel ikili örüntüler

ŞEKİLLER LİSTESİ

Şekil 1.1. Farklı topolojileri kullanan LBP türleri (Liu ve ark., 2017)	8
Şekil 2.1. Orijinal LBP operatörü	13
Şekil 2.2. (a) (8,1) komşuluğa sahip örüntü, (b) (8,2) komşuluğa sahip örüntü, (c) (16,2) komşuluğa sahip örüntü	14
Şekil 2.3. Bilineer interpolasyon için örnek bir görüntü	15
Şekil 2.4. Eliptik topoloji örnekleri	18
Şekil 3.1. SVM'de hiper düzlemin seçilmesi	22
Şekil 4.1. Kutupsal koordinat sistemi	26
Şekil 4.2. İki farklı b değeri (a) $b = 0,3$ (b) $b = 0,6$ için çizilen spiral örnekleri ...	27
Şekil 4.3. 8 komşuluğa sahip 1 spiralli yapı (S1LBP)	28
Şekil 4.4. 8 komşuluğa sahip 2 spiralli yapı (S2LBP)	31
Şekil 4.5. 8 komşuluğa sahip 4 spiralli yapı (S4LBP)	32
Şekil 4.6. S4LBP'nin çalışma yapısı	33
Şekil 4.7. SLBP algoritma adımları	35
Şekil 5.1. CUREt doku veritabanından örnekler	38
Şekil 5.2. UIUC doku veritabanından örnekler	39
Şekil 5.3. Farklı b parametreleri ile elde edilen doğruluk oranları	40
Şekil 5.4. LBP ile sınıflandırma oranları	42
Şekil 5.5. ULBP ile sınıflandırma oranları	42
Şekil 5.6. Sınıflandırma yöntemlerinin 30 eğitim imgesi için ortalamaları	43
Şekil 5.7. UIUC doku veritabanında doğruluk oranları	44
Şekil 5.8. CUREt doku veritabanında doğruluk oranları	45
Şekil 5.9. S2LBP ile kenar bilgilerinin birlikte kullanımı	55
Şekil 5.10. AR yüz veritabanının deneylerde kullanılan altkümesindeki sınıflardan rastgele seçilen örnekler	58
Şekil 5.11. ORL yüz veritabanındaki sınıflardan seçilen örnekler	59

Şekil 5.12. Yüz görüntüsünün alt imgelere bölünmesi	60
Şekil 5.13. Sınıflar arası varyansların hesaplanması	62
Şekil 5.14. 8 komşuluklu S4LBP için hesaplanan varyansların sıralanması	63
Şekil 5.15. UIUC veritabanında 8 komşuluklu S2LBP (S2LBP_8) üzerindeki tanıma oranları değişimi	64
Şekil 5.16. UIUC veritabanında 16 komşuluklu S2LBP (S2LBP_16) üzerindeki tanıma oranları değişimi	64
Şekil 5.17. UIUC veritabanında 8 komşuluklu S4LBP (S4LBP_8) üzerindeki tanıma oranları değişimi	65
Şekil 5.18. UIUC veritabanında 16 komşuluklu S4LBP (S4LBP_16) üzerindeki tanıma oranları değişimi	65
Şekil 5.19. CUREt veritabanında 8 komşuluklu S2LBP (S2LBP_8) üzerindeki tanıma oranları değişimi	67

TABLolar LİSTESİ

Tablo 1.1. Öznitelik çıkarım yöntemleri literatür özeti	11
Tablo 5.1. UIUC doku veritabanı üzerinde elde edilen doğruluk oranları	48
Tablo 5.2. CURet doku veritabanı üzerinde elde edilen doğruluk oranları	49
Tablo 5.3. Geliştirilen yöntemler ile bilinen diğer yöntemlerin doğruluk oranları ..	50
Tablo 5.4. Geliştirilen yöntemler ile bilinen diğer yöntemlerin öznitelik boyutları ve öznitelik çıkarım süreleri	50
Tablo 5.5. UIUC doku veritabanında χ^2 ile elde edilen doğruluk oranları	56
Tablo 5.6. CURet doku veritabanında χ^2 ile elde edilen doğruluk oranları	56
Tablo 5.7. UIUC doku veritabanında LRC ile elde edilen doğruluk oranları	56
Tablo 5.8. CURet doku veritabanında LRC ile elde edilen doğruluk oranları	57
Tablo 5.9. ORL yüz veritabanı için tanıma oranları (%)	60
Tablo 5.10. AR yüz veritabanı için tanıma oranları (%)	60
Tablo 5.11. Öznitelik seçim algoritmasının UIUC veritabanı üzerindeki tanıma oranları	66

ÖZET

Anahtar kelimeler: Doku tanıma, öznitelik çıkarımı, yerel ikili örüntüler

Bu tezde, doku tanıma başarılı bir şekilde kullanılan yerel ikili örüntüler (Local Binary Pattern - LBP) öznitelik çıkarım yönteminin komşuluk topolojisi üzerinde çalışılmıştır. LBP, görüntünün gri seviye değerlerini kullanan basit bir öznitelik çıkarım yöntemidir. Görüntüdeki her piksel referans piksel olarak belirlenir ve etrafındaki komşuları dairesel bir topoloji ile seçilir. Bu tez çalışması kapsamında LBP yöntemi ile farklı spiral topolojilere sahip komşuluklar kullanılarak daha anlamlı özniteliklerin elde edilmesi amaçlanmıştır. Ayrıca, özniteliklerin ayırt edici özelliklerini arttırmak amacıyla, spiral topoloji kullanan LBP kodları ile görüntünün kenar bilgileri birleştirilmiştir. Histogram tabanlı öznitelik vektörlerinin sınıflandırılmasında genellikle benzerlik ölçütleri kullanılmaktadır. Yapılan tezde, doku tanıma sınıflandırma aşamasında altuzay tabanlı yöntemler ile tanıma başarımının artırılması hedeflenmiştir.

Önerilen öznitelik çıkarım yöntemi, doku tanıma CURet ve UIUC doku veritabanları, yüz tanıma ise AR ve ORL yüz veritabanları üzerinde çeşitli deneyler ile test edilmiştir. Yapılan deneyler sonucunda, CURet doku veritabanında % 99,6'lara varan bir tanıma oranı elde edilmiştir. Farklı LBP varyasyonları ile karşılaştırıldığında, daha iyi sınıflandırma başarımları elde edilmiştir.

Ayrıca geliştirdiğimiz öznitelik çıkarım yöntemi ile elde edilen öznitelik vektör boyutunu azaltmak amacıyla yeni bir öznitelik seçim algoritması önerilmiştir. Önerilen yöntemde sınıflar arası varyansın olabildiğince yüksek hale getirilmesi amaçlanmaktadır. Önerilen öznitelik seçimi yönteminin başarımı doku tanıma test edilmiştir. Deney sonuçlarına göre, öznitelik vektörünün boyutu %99'a kadar azaldığında tanıma oranı sadece %0,06 azalmaktadır.

EXTRACTING NEW FEATURES USING SHAPE INFORMATION IN TEXTURE RECOGNITION

SUMMARY

Keywords: Texture recognition, feature extraction, local binary pattern,

In this thesis, neighborhood topology of Local Binary Pattern (LBP) which is used successfully applied in texture recognition is studied. LBP is a simple feature extraction method that uses the gray-level values of an image. Each pixel in the image is determined as the reference pixel and its surrounding neighbors are selected over a circular topology. In this thesis work, by using the LBP method, it is aimed to obtain more meaningful features, by using neighbors with different spiral topologies. In addition, the LBP codes which use spiral topology is concatenated with the edge information of the image to enhance the distinctive characteristics of the features. Similarity measures are generally used to classify histogram-based feature vectors. In this thesis, it is aimed to increase the recognition performance with subspace based methods in the classification stage of texture recognition.

Proposed feature extraction method is tested with several experiments on CUREt and UIUC texture database in texture recognition, AR and ORL face database in face recognition. As a result of the experiments, the recognition rate is acquired up to %99,6 on CUREt texture database. Better classification performances are achieved when compared to the several LBP variations.

In addition, a new feature selection algorithm is proposed to reduce the dimension of the feature vectors obtained by the proposed feature extraction method. In the proposed method, it is aimed to make the between-class variance as high as possible. The performance of the proposed feature selection method is tested in texture recognition. The experimental results suggest that, the recognition rate is reduced by only 0.06% when the dimension of the feature vector is reduced up to 99%.

BÖLÜM 1. GİRİŞ

Doku, birbirini tekrar eden örüntülerden oluşan bir yapı olarak tanımlanabilir. Dokular günlük hayatımızda birçok kere karşılaşılabileceğimiz neredeyse tüm doğal yüzeylerin temel bir özelliğidir. Ayrıca birçok bilgisayar görme sisteminin önemli bir bileşenidir. Doku analizindeki en önemli aşamalardan biri olan doku sınıflandırması; biyomedikal görüntü analizi (Dubey ve ark., 2016, Morales ve ark., 2017, Wan ve ark., 2017), endüstriyel görsel denetim (Thompson ve Biasotti, 2018), uydu veya havadan görüntü analizi (Gupta ve ark., 2018, Anwer ve ark., 2018), hiperspektral görüntü analizi (Li ve ark., 2015, Jia ve ark., 2017), yüz ve yüz ifadesi analizi (Fan ve Hung, 2014, Jeong ve ark., 2015, Huang ve Yin, 2017, Chakraborty ve ark., 2018), bitki sınıflandırma (Naresh ve Nagendraswamy, 2016) ve nesne tanıma (Satpathy ve ark., 2014) dâhil olmak üzere bilgisayar görüşü ve örüntü tanıma alanlarında önemli bir rol oynar. Doku tanıma sistemleri son zamanlarda önemli bir alan haline gelerek yüksek doğruluklarda tanıma oranlarına sahip sistemler elde edilmeye çalışılmıştır.

Doku sınıflandırma problemi temel olarak, öznitelik çıkarımı ve sınıflandırma olmak üzere iki alt probleme ayrılmıştır. Genel olarak, güçlü doku özniteliklerinin çıkarılmasının, bir doku sınıflandırma stratejisinin genel başarısı için daha büyük bir öneme sahip olduğu ve sonuç olarak, çoğu araştırmanın öznitelik çıkartma kısmına odaklandığı kabul edilmektedir (Pietikainen ve ark., 2011). Bununla birlikte, aydınlatma, rotasyon, bakış açısı, ölçekleme, kapatılma ve gürültü seviyesindeki değişiklikler de dahil olmak üzere, hesaplama ortamına duyarlı, yüksek düzeyde ayırt edici ve etkili olan doku özniteliklerinin çıkarımı oldukça zorlu bir problemidir.

Raju ve Durai yaptıkları çalışmada özellik çıkarımına bağlı doku sınıflandırma yöntemlerini yerel ve global özniteliklere göre iki kategori altında toplamıştır (2013). Yerel özniteliklerin çıkarılma işlemi dokuyu bölgesel olarak inceler. Bu yöntemlerden

son zamanlarda en çok çalışılanlarından bir tanesi Yerel İkili Örüntüler (Local Binary Pattern - LBP) yöntemidir.

Yapılan tez kapsamında LBP'ye dayalı yeni öznitelik çıkarım yöntemleri ve yeni bir öznitelik seçim yöntemi geliştirilmiştir. Öznitelik çıkarım yönteminde, herhangi bir referans piksel etrafındaki komşu noktaların konumlandırılmasında Arşimet spirali kullanılarak bir topoloji önerilmiştir. Daha sonra, topoloji 2 spiral ve 4 spiralli yapıya genişletilmiştir. Geliştirilen yöntemler doku tanıma ve yüz tanıma problemlerinde test edilmiştir. Doku tanıma alanında önerilen yöntemler ile yapılan çalışmalar 'IET Image Processing' dergisinde yayınlanmıştır (Kazak ve Koç, 2018). Ayrıca tezde, görüntüdeki kenar bilgileri ile LBP özniteliklerini birleştiren bir başka öznitelik çıkarım yöntemi tanıtılmıştır. Doku veritabanları üzerinde etkinliği ölçülmüştür. Bu yöntem ile ilgili yapılan çalışmalar 'Advances in Intelligent Systems and Computing' kitap serisinde kitap bölümü olarak kabul edilmiştir (Kazak ve Koç, 2019). Son olarak, sınıflar arası varyansı maksimum yapmayı hedefleyen bir öznitelik seçimi algoritması tasarlanmıştır. Bunların dışında, önerilen öznitelik çıkarımı yöntemi ile yapılan çalışmaların bir kısmı da bir ulusal üç uluslararası konferansta bildiri olarak sunulmuştur.

1.1. Literatürdeki Çalışmalar

LBP yöntemi doku tanıma için uygulanmak üzere ilk defa 1996'da ortaya atılmıştır. Yöntem, doku görüntüsündeki piksellerin gri-seviye yoğunluk değerlerini kullanarak yerel öznitelikler çıkarmaktadır. Görüntüdeki her bir pikselin gri-seviye yoğunluk değeri eşik değeri olarak seçilerek belirlenen komşularının yoğunluk değerleri ile karşılaştırılır ve bu işleme göre ikili kodlar üretilir. Bu sebeple yöntem, gri-seviyeden bağımsız çalışır. (Ojala ve ark., 1996)

Gerçek hayattan alınan görüntüler her zaman tekdüze olmayabilir. Görüntüler döndürülmüş, farklı ölçeklendirilmiş ya da farklı görsel özelliklere sahip olabilir. Bu sebeple Mäenpää tarafından tekdüze LBP (Uniform LBP - ULBP) geliştirilmiştir (2003). ULBP dokunun temel önemli özelliklerini ele alır geriye kalan özellikler

kullanılmaz. Bir örüntünün tekdüze sayılabilmesi için örüntüden elde edilen ikili kodun bit geçişleri dikkate alınır. Eğer iki ya da daha az geçiş varsa bu örüntüler tekdüze sayılırlar. (Maenpaa ve ark., 2000)

ULBP yöntemiyle elde edilen öznitelikleri kullanan ve tekdüze olmayan öznitelikler için farklı bir yöntem geliştiren Guo ve arkadaşları yüz ve avuç içi izi tanınması yapmışlardır (2010). Yaptıkları çalışmada en fazla tanıma oranını %98,89 bularak orijinal LBP yönteminden daha iyi bir tanıma elde etmişlerdir.

ULBP yöntemini kullanan bir başka yüz tanıma çalışması da Ahonen ve arkadaşları tarafından gerçekleştirilmiştir (2006). Bu çalışmada yüz imgeleri birçok küçük bölgeye bölünmüş ve her bir bölge için ULBP kullanılarak öznitelikler çıkarılmıştır. Bu öznitelikler daha sonra birleştirilerek bir öznitelik vektörü elde edilmiştir. ULBP'nin, üç farklı yerel tanımlayıcı ile karşılaştırıldığında daha iyi bir tanıma oranına sahip olduğu görülmüştür.

LBP yönteminin birçok alanda çok iyi sonuçlar vermesinden dolayı üzerinde çalışılan popüler bir konu haline gelerek birçok varyasyonları türetilmiştir. LBP, görüntünün döndürülmesinden ve gri seviyeden bağımsız tekdüze örüntüleri (LBP^{riu2}) elde etmek amacıyla Ojala ve arkadaşları tarafından geliştirilmiştir (2002).

Zhao ve arkadaşları dönmeden bağımsız doku sınıflandırma için yerel ikili sayı (LBC) isminde yerel bir tanımlayıcı önermişlerdir (2013). Önerilen tanımlayıcı, yerel ikili gri-seviye farklılıkları bilgisini çıkarabilmektedir. LBC kodları görsel mikro yapıları temsil etmemesine rağmen, LBC öznitelikleri istatistikleri yerel dokuları etkin bir şekilde temsil edebilmektedir. LBC'de ikili komşuluk setlerini kodlamak yerine içindeki 1'leri sayar ve bu sayıyı temel alır. Buna ek olarak tamamlanmış LBC (CLBC) doku sınıflandırma performansını artırmak için önerilmiştir. Bu yöntemde işaret büyüklük ve merkez CLBC olarak üç operatöre sahip tamamlanmış yerel dokusal bilgiler çıkarılır. Histogramlar arasındaki benzerliği ölçmek için Ki-kare (χ^2) testi kullanılmıştır. Sınıflandırma amacıyla Outex veritabanı, CURet veritabanı ve UIUC

veritabanı kullanılmıştır. Birçok yöntem ile yapılan karşılaştırmalar sonucunda geliştirilen yöntemin daha iyi tanıma oranlarına sahip olduğu gözlemlenmiştir.

Literatürde görsel benzerliği ölçmek için birçok tanımlayıcı önerilmiştir. Bir tanımlayıcının diğerinden üstün olmasını sağlayan şey ayırt edicilik gücü ve dönme değişmezliği, ölçek değişmezliği gibi durumlarda daha başarılı olmasına bağlı olarak değişir. Hiçbir tanımlayıcı her durumda en iyiye ulaşamaz. Varma ve Ray' in yaptıkları çalışmanın amacı belirli eğitim setine ve kısıtlara göre sınıflandırma için en iyi tanımlayıcıların seçilmesidir (2007). Geliştirilen yöntemin performansı UIUC doku veritabanı, Oxford çiçek veritabanı ve Caltech 101 veritabanı üzerinde test edilmiştir. Bütün tanımlayıcılar birleştirildiğinde elde edilen sonuçlar bire karşı diğerinde (one vs one) $98,76 \pm 0,64$, bire karşı hepsinde (one vs all) $98,9 \pm 0,68$ olarak bulunmuştur.

Çok boyutlu LBP, farklı yarıçaplar kullanarak elde edilen LBP özniteliklerini birleştirip tek boyutlu bir vektör haline getirir. Schaefer ve Doshi yaptıkları çalışma ile LBP'nin farklı ölçekteki doku bilgilerini kaybetmesi sorununu ortadan kaldırarak orijinal LBP'den daha iyi sonuçlar elde etmişlerdir (2012).

Guo ve arkadaşları yönsel istatistiksel bilgileri birleştirerek dönmeden bağımsız doku sınıflandırması yapmışlardır (2010). Yerel farklılıkların hata oranını azaltmak için en küçük kareler yöntemini kullanarak adaptif LBP yöntemini geliştirmişlerdir. Dönmeden bağımsız bilinen doku sınıflandırma algoritmalarıyla karşılaştırıldığında daha iyi sonuçlara ulaşmışlardır.

Çok ölçekli uzamsal piramit LBP yöntemi, LBP histogramları temel bileşen analizi yöntemi ile boyutu azaltılarak doku ve şekil kodlaması için kullanılmıştır. Optik tolerans tomografi görüntülerinden çoklu makula patolojilerinin tanınmasında destek vektör makineleri sınıflandırma için kullanılarak elde edilen tanıma oranı %93'lere ulaşmıştır (Liu ve ark., 2011).

Doku sınıflandırmasında kullanılan diğer bir yöntem olan tamamlanmış LBP'de (CLBP) Guo ve arkadaşları, yerel farklılıklar için işaret ve büyüklük öznitelikleri elde

etmişlerdir (2010). İşaret bileşeninin büyüklük bileşenine göre daha önemli yerel farklılık bilgisine sahip olduğu sonucuna ulaşarak orijinal LBP'den daha iyi tanıma oranları elde etmişlerdir.

Tan ve Triggs, standart LBP yöntemini temel alarak, referans alınan piksel ile etrafındaki komşu pikseller arasındaki gri seviye farklılıklarını üç ikili sayı $[1 \ 0 \ -1]$ ile kodlayan yerel üçlü örüntü yöntemini (LTP) tasarlamışlardır (2010). Geliştirdikleri yöntemin etkinliğini ölçmek amacıyla yüz tanıma problemine uygulamışlardır. Diğer yöntemlerle karşılaştırıldığında geliştirdikleri yöntemin daha iyi tanıma oranlarına ulaştığını rapor etmişlerdir.

Murala ve Wu geliştirdikleri yöntemde görüntünün yerel bölgelerini işaret ve büyüklük bileşenleri ile temsil etmişlerdir (2014). Daha sonra geliştirdikleri yöntem ile Gabor dönüşümlerini birleştirmişlerdir. Önerilen bu yöntem içerik tabanlı görüntü getiriminde kullanılmış olup, farklı görüntü veritabanları üzerinde dört deneysel set ile test edilmiştir. Standart LBP ve çeşitli yöntemler ile karşılaştırıldığında diğer yöntemlere göre değerlendirme ölçümleri açısından önemli gelişmeler göstermiştir.

Zhang ve arkadaşları yaptıkları çalışmada LBP'nin detay bilgileri kaybetmesini önlemek amacıyla yüksek mertebeden yerel örüntüler önermişlerdir (2010). LBP'deki kodlamadan farklı olarak, merkez piksel ile komşu pikseller arasındaki gri-seviye farklılıklarını çeşitli ayırt edici mekânsal (spatial) ilişkileri kodlamışlardır. Böylelikle yüksek mertebeden yerel bilgilere ulaşmışlardır. Geliştirdikleri bu yöntemden elde edilen histogramların benzerliğini histogram kesişimi (intersection) yöntemini kullanarak ölçmüşlerdir. Yöntemin etkinliğini ölçebilmek amacıyla beş adet yüz veritabanı kullanmışlardır. Yüz tanıma oranları önerdikleri yöntemde standart LBP'ye göre daha iyi çıkmıştır.

Zaman-uzamsal yerel monojen ikili örüntü yapısı, video kesitlerinden yüz ifadesi tanımak amacıyla Huang ve arkadaşları tarafından geliştirilmiştir (2012). Dinamik dizilerin özneliklerini tanımlamak için iki katmanlı bir mimari önermişlerdir. İlk katmanda çok boyutlu monojenik sinyal analizinin etkili bir gösterimi kullanılmıştır.

İkinci katmanda ise üç ortogonal düzlemde monojenik büyüklüğü kodlamak için LBP kullanılmıştır. Önerilen metot iki yüz ifadesi veritabanı üzerinde gerçekleştirildiğinde elde edilen sonuçlar yöntemin ışıklandırma varyasyonlarına karşı güçlü ve diğer bilinen metotlardan daha iyi bir performans sergilediğini göstermektedir.

Kır ve arkadaşları yaptıkları çalışmada ikilileştirme yaklaşımına dayalı LBP önermişler ve sayısal imge sabitleme uygulamasında kullanmışlardır (2015). Önerilen yöntemde, 8 bit derinlikli görüntüleri ikili görüntülere dönüştürmek için LBP tabanlı bir yaklaşım kullanılır. İkili görüntüler elde edildikten sonra bir eşleştirme ölçütü global hareketi hesaplamak için kullanılır. Diğer yöntemlerle karşılaştırıldığında daha iyi performans elde ettiği belirtilmiştir.

Liu ve arkadaşlarının yaptıkları çalışmada, literatürde mevcut olan çoğu LBP türlerini sistematik olarak yeniden incelemiş ve bu türleri karakteristiklerine göre yeni bir taksonomi geliştirerek sınıflandırmışlardır (2017). Toplamda 32 adet LBP türü ve 8 adet derin konvolüsyon ağı tabanlı öznelikler, 13 doku veritabanı üzerinde karşılaştırmalı olarak rapor etmişlerdir. Ayrıca yöntemlerin avantaj ve dezavantajlarını, dönmeye, ölçeklemeye, aydınlanmaya bağlı değişikliklere ve hesapsal karmaşıklığına göre analiz etmişlerdir.

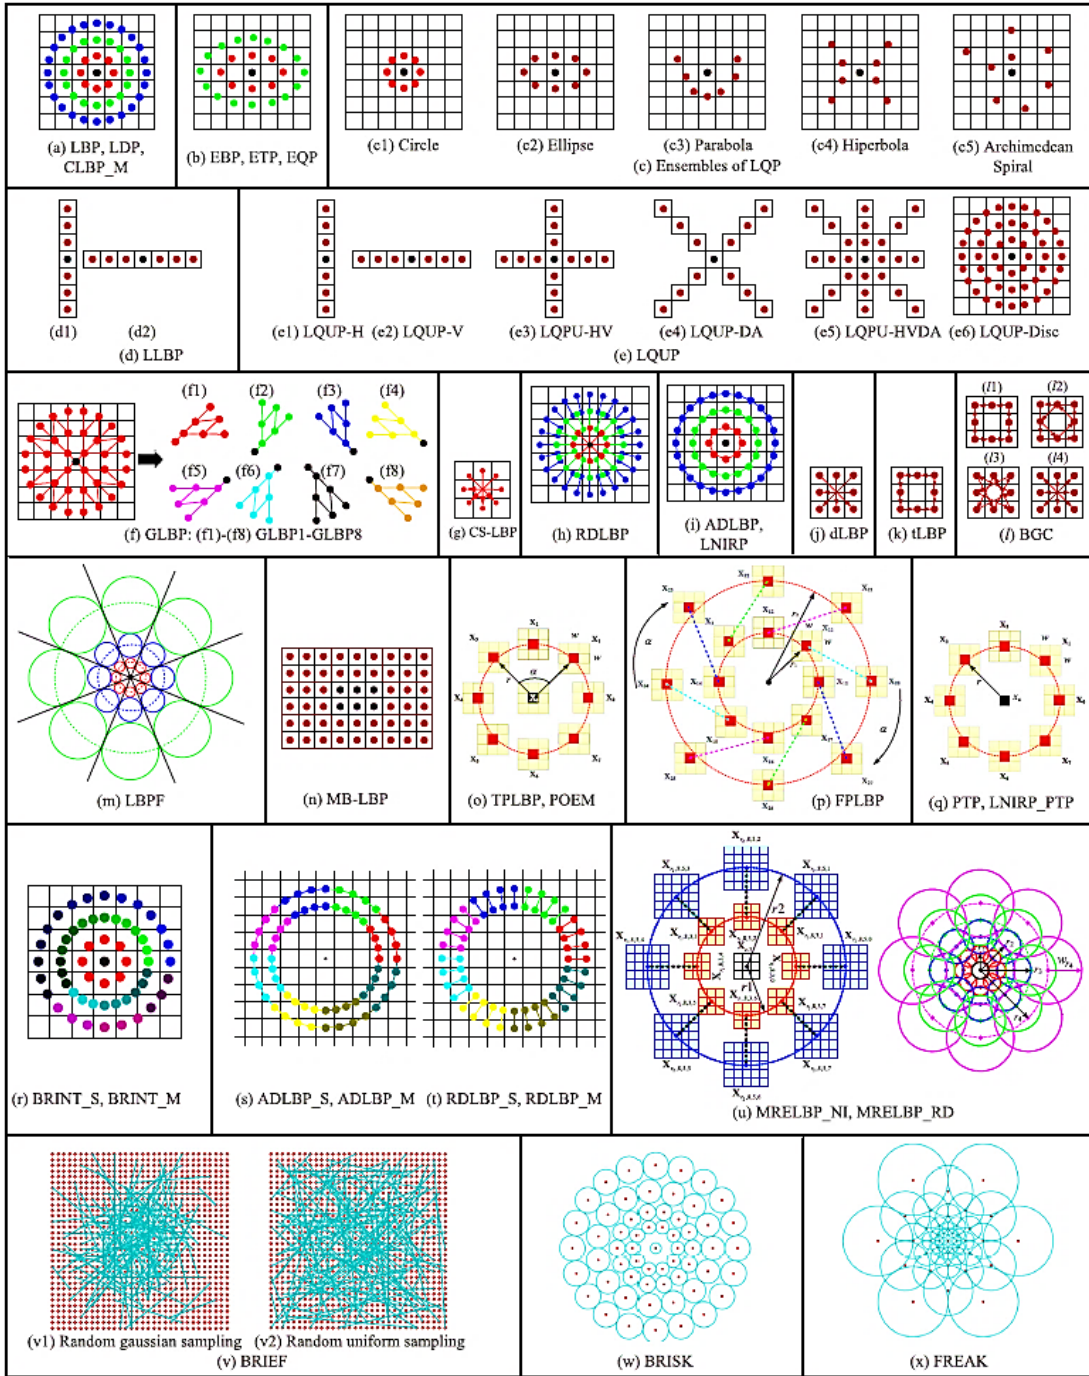
Liu ve arkadaşları, LBP veya LBP'ye dayalı öznelik çıkarım yöntemlerini temel olarak aşağıda belirtilen altı adımdan oluştuğunu öne sürmüşlerdir:

- Önişleme: Giriş olarak alınan bir görüntü Gabor filtresi ya da diğer filtreler gibi çeşitli yöntemler ile önişleme tabii tutulur.
- Komşuluk topolojisi ve örnek noktalarının şekli: Merkez piksel ve komşu noktalarının görüntü üzerindeki dağılımları belirlenir.
- Eşikleme ve niceleme: Bir eşik değeri belirlenerek, ikili kod üretme veya çoklu seviyede niceleme işlemleri yapılır.

- Kodlama ve yeniden gruplama: Ayırıcılığı artırmak amacıyla ve birleştirilmek üzere örüntü grupları tanımlanır.
- Öznitelik seçimi ve öğrenme: Çeşitli algoritmalar kullanılarak öznitelik boyutunun indirildiği adımdır.
- Tamamlayıcı özniteliklerin birleştirilmesi: LBP'ye dayalı ya da LBP harici tamamlayıcı özniteliklerin birleştirildiği adımdır.

Bu temel adımlardan önişleme ve öznitelik seçimi adımları problemin istatistiksel ve karakteristik özelliklerine bağlı olduğundan ve yeni LBP stratejilerinin geliştirilmediğinden dolayı önerilen taksonomide yer almamaktadır. Dolayısıyla oluşturulan taksonomide 6 sınıf mevcuttur. Bu sınıflar; geleneksel LBP, komşuluk topolojisi ve örnek noktalarının şekli, eşikleme ve niceleme, kodlama ve yeniden gruplandırma, tamamlayıcı özniteliklerin birleştirilmesi ve son olarak LBP'den ilham alınan yöntemler olarak sıralanmaktadır.

Yapılan tez çalışmasında komşuluk topolojisi tasarlandığı için, Liu ve ark.'nın geliştirdikleri (2017) taksonominin ikinci sınıfına dâhil edilmektedir. Şekil 1.1.'de literatürde topoloji üzerinde geliştirilmiş yöntemler gösterilmektedir. Şekilde görülen (b-e) anizotropik bilgiler, (f-l) yerel farklar veya büyüklükler, (m-x) mikro ve makro yapıları çıkarmaktadır.



Şekil 1.1. Farklı topolojileri kullanan LBP türleri (Liu ve ark., 2017)

Yaptıkları deneyler sonucunda ayırıcılık, gürbüzlük ve hesapsal karmaşıklık açısından en iyi yöntemin MRELBP (Medyan Gürbüz Geliştirilmiş LBP) (Liu ve ark., 2016) olduğunu gözlemlemişlerdir. Mikro ve makro yapıların doku tanımlamada önemli bilgiler taşıdığı belirtilmiştir. Ayrıca tamamlayıcı özelliklerin dahil edilmesiyle çok daha iyi tanıma oranlarına ulaşıldığı tespit edilmiştir.

Zhang ve arkadaşları (2017) öznitelik vektörlerinin ayırt edici özelliğini artırabilmek amacıyla; kodlama aşamasında, etiketlenmiş datalar kullanarak bir dönüşüm matrisi elde etmişlerdir. Bu işlem sonucunda kodlanmış ikili dizilerin ayırt edici özelliği önemli ölçüde artırılmıştır. Histogram oluşturma aşamasında ise, farklı bölgelere ait piksellerin katkılarını dikkate alabilmek için adaptif ağırlık stratejisi kullanmışlardır. Önerdikleri yöntemi Outex, CURet ve UIUC doku veritabanlarında test etmişler ve tanıma oranlarında başarıyı artırmışlardır.

Kabbai ve arkadaşları (2017) üst ve alt LBP'yi önermişlerdir. 8 komşuluğa sahip bir örüntüyü alt ve üst olmak üzere ikiye bölmüşlerdir. Her bir kısmı ayrı ayrı hesaplamışlardır. Daha sonra bu histogramlar birleştirilerek global öznitelik hesaplanır. Yerel öznitelikler için ise SIFT (Scale Invariant Feature Transform) kullanılmışlardır. Son olarak yerel ve global öznitelikleri birleştirerek tanımlayıcılarını oluşturmuşlardır. Görüntü bulup getirme ve görüntü sınıflandırma problemlerinde uygulamışlardır. Doku tanımlamada alt ve üst LBP'nin etkinliğini ölçmek amacıyla Brodatz doku verisetini kullanmışlardır. Geliştirdikleri yöntemle orijinal LBP'den elde edilen öznitelik boyutunu azaltmışlardır.

Alaei ve arkadaşlarının (2016) yaptıkları çalışmanın amacı doküman görüntüsü alıp getirme (retrieval) için doku özniteliklerinin etkinliğini incelemektir. Bu nedenle, ikili doku metodu kullanılarak segmentasyonsuz doküman görüntüsü alıp getirilmesi önerilmiştir. Önerilen yaklaşımda, yerel öznitelikler çıkarılır, yerel gri-seviye yapılar özetlenir ve dağılımları global öznitelikler kullanılarak karakterize edilir. Varsayım, belge görüntülerinin metin bölgeleri ve metin dışı bölümlerindeki doku özelliklerinin farklı olmasıdır. Bu varsayım, kullanılabilir belge görüntülerini sıralamak ve yalnızca belirli bir sorguyla en fazla görsel benzerliğe sahip olanları alıp getirmek için kullanılır. Önerilen yöntem, LBP temelli medyan LBP ve geliştirilmiş LBP gibi öznitelik çıkarım yöntemleri ile görüntü alıp getirme probleminde karşılaştırıldığında %72,9 ile en iyi sonucu vermiştir.

Doku tanımanın ikinci adımı sınıflandırma sürecidir. Doku sınıflandırma temel olarak bilinmeyen bir doku imgesini daha önceden bilinen bir imge kategorisine atamaktır.

LBP kodundan elde edilen öznitelik vektörleri aslında histogramlar olduğundan genellikle histogram benzerliğini ölçen istatistiksel testler ile en yakın komşu sınıflandırıcısı kullanılır. Ayrıca, sınıflandırma yapılırken altuzay tabanlı yöntemler de kullanılmaktadır. Histogram benzerliğini ölçerek en yakın komşu yöntemi ile sınıflandırma yapan istatistiksel testlerden bazıları Maenpaa'nın da kullandığı log-likelihood istatistiği (2003) ve çoğunlukla histogram karşılaştırmalarında kullanılan χ^2 testidir (Zhao ve ark., 2013). Sınıflandırma aşamasında destek vektör makineleri (SVM) (Liao ve ark., 2009), doğrusal ayırtaç analizi (LDA) (Shan ve ark., 2009, Kazak ve ark., 2016) gibi altuzay tabanlı yöntemler LBP ile birlikte kullanılmıştır.

Doğrusal regresyon sınıflandırıcı (LRC) yöntemi Naseem ve arkadaşları tarafından yüz tanıma problemine başarılı bir şekilde uygulanmış altuzay tabanlı bir sınıflandırma yöntemidir (2010). Yöntemde her sınıfın eğitim kümesindeki öznitelik vektörleri kullanılarak o sınıf için bir kestirici oluşturulur. Sınıflandırılacak vektörün bu kestiriciler yardımı ile tahminleri elde edilir. Naseem ve arkadaşları, özellikle yüzdeki kapamalardan kaynaklı sınıflandırma başarımının düştüğü durumlar için de basit ama başarılı olan modüler LRC yöntemini önermişlerdir. Koc ve Barkana ise, veri setindeki örnek sayısının veri boyutundan fazla olduğu durumlar için LRC'nin bir varyasyonunu önermişlerdir (2014).

Huang ve Yang yaptıkları çalışmada LRC yöntemine ayırık analiz yaklaşımını getirmişlerdir. İyi bilinen iki adet yüz veritabanında geliştirdikleri yöntemi test etmişlerdir. Elde ettikleri sonuca göre önerilen yöntem LRC'nin gürbüzlüğünü artırmıştır (Huang ve Yang, 2013).

Ayrıca bazı öznitelik çıkarım yöntemleri ile ilgili literatür özeti Tablo 1.1'de karşılaştırmalı olarak gösterilmektedir.

Tablo 1.1. Öznitelik çıkarım yöntemleri literatür özeti

Yöntem	Topoloji	Sınıflandırıcı	Uygulama Alanı	Veritabanı	Tanıma Oranı
Ojala ve ark., 1992	Kare	Kullback, En yakın komşu	Doku tanıma	Brodatz	87,48
Mäenpää, 2003	Daire	G-test, En yakın komşu	Doku tanıma	VisTex Outex	97,00 80,40
Ahonen ve ark., 2006	Daire	Ki-kare, En yakın komşu	Yüz tanıma	FERET	93,00
Ojala ve ark., 2002	Daire	G-test, En yakın komşu	Doku tanıma	Brodatz Outex	99,70 97,70
Liao ve Chung, 2007	Elips	RBF SVM	Yüz tanıma	ORL FERET	97,00 86,73
Nanni ve ark., 2010	Arşimet spirali, elips, çember, parabol, hiperbol	Doğrusal SVM	Medikal görüntü analizi	2D-HeLa COPE	92,00 91,80
Önerilen S2LBP	2 Arşimet spirali	LRC	Doku tanıma	UIUC CURet	87,28 98,61
Önerilen S4LBP	4 Arşimet spirali	LRC	Doku tanıma	UIUC CURet	88,04 98,82
Önerilen S1LBP_EI	Arşimet spirali	LRC	Doku tanıma	UIUC CURet	89,08 97,92
Önerilen S2LBP_EI	2 Arşimet spirali	LRC	Doku tanıma	UIUC CURet	88,85 98,72
Önerilen S4LBP_EI	4 Arşimet spirali	LRC	Doku tanıma	UIUC CURet	89,84 99,24

1.2. Tezin Literatüre Katkısı

Bu tez çalışmasında literatüre katkı olarak;

- LBP’de kullanılan dairesel topoloji yerine yeni spiral topolojiler üretilerek öznitelik çıkarım yöntemleri geliştirilmiştir.

- İki spiralli ve dört spiralli topoloji yapısı doku tanımada ilk kez uygulanmıştır.
- LRC sınıflandırma yönteminin doku tanıma uygulamalarındaki başarımı ortaya koyulmuştur.
- Kenar bilgilerinin de kullanıldığı LBP temelli yeni bir öznitelik elde edilmiştir.
- Sınıflar arası varyansı maksimum yapmayı hedefleyen yeni bir öznitelik seçim algoritması tasarlanmıştır.

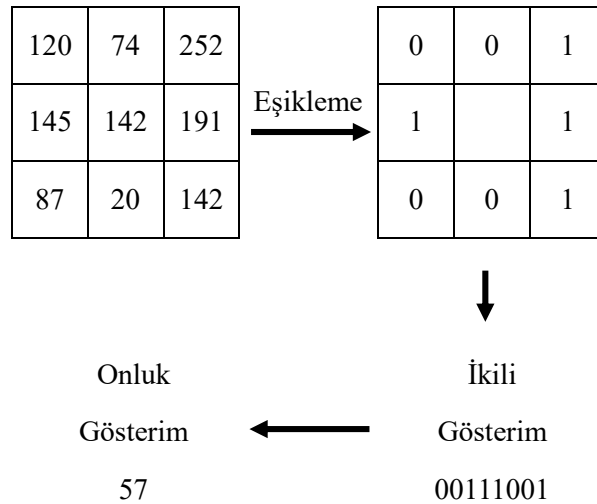
1.3. Tez Organizasyonu

Tez çalışmasının ikinci bölümünde LBP ve LBP tabanlı farklı topolojiler kullanan yöntemler incelenmiştir. Üçüncü bölümde sınıflandırma aşamasında kullanılan istatistiksel testler ve sınıflandırma yöntemleri araştırılmıştır. Farklı spiral topolojiler ile yeniden tasarlanan LBP yöntemleri dördüncü bölümde önerilmiştir. Beşinci bölümde ise kullanılan veritabanları tanıtılarak, spiral topolojide seçilen spiral şeklinin belirlenmesi, probleme en uygun sınıflandırıcının seçilmesi, geliştirilen yöntemlerin etkinliğini göstermek amacıyla doku tanıma ve yüz tanıma problemleri üzerine yapılan deneysel sonuçlar verilmiştir. Ayrıca geliştirilen yöntemler ile kenar bilgilerinin birlikte kullanımı ve yeni bir öznitelik seçim yöntemi üzerinde yapılan çalışmalar anlatılmıştır. Tezin son bölümünde de tez kapsamında yapılan bütün çalışmalar değerlendirilerek, gelecek çalışmalar ile ilgili öneriler verilmiştir.

BÖLÜM 2. YEREL İKİLİ ÖRÜNTÜLER


Ojala ve arkadaşları tarafından önerilen (1996) orijinal yerel ikili örüntü (Local Binary Pattern - LBP) operatörü gri-seviyeden bağımsız görüntü betimlemede kullanılan bir öznitelik çıkarım yöntemidir. Bu operatör görüntü piksellerinin gri-seviye değerleriyle çalışır.

Orijinal LBP, 3×3 kare bloklar kullanır. Blok ortasındaki piksel, merkez piksel olarak nitelendirilir ve blok içerisindeki her bir pikselin gri-seviye değeri, merkez pikselin değeri ile karşılaştırılır. Eğer merkez pikselin yoğunluk değeri ile karşılaştırılan komşu pikselin değeri arasındaki fark sıfırdan büyük veya eşitse komşu piksel değeri ikili olarak 1, diğer durumda ise 0 kodlanır. Yapılan karşılaştırmalar sonucu elde edilen ikili değerler onluk tabana dönüştürülerek ilgili pikselin LBP kodu hesaplanır. Bu işlemler sırasıyla görüntünün tüm pikselleri için gerçekleştirilir. Görüntünün her pikseli için oluşturulan LBP kodlarının histogramı oluşturularak ilgili görüntünün öznitelik vektörü çıkarılır ve algoritma sonlanır. Şekil 2.1.'de orijinal LBP operatörü bir örnek ile gösterilmiştir.



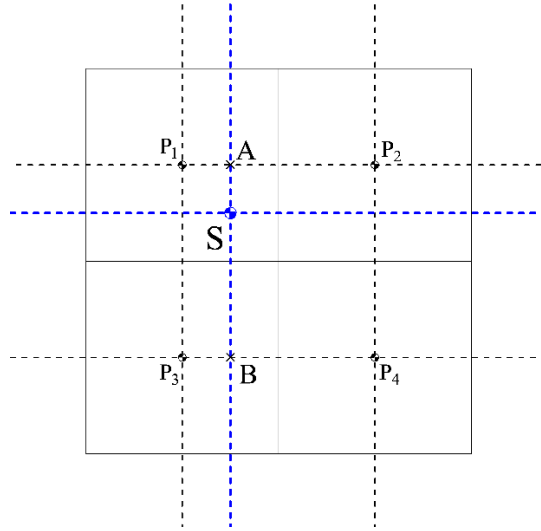
Şekil 2.1. Orijinal LBP operatörü

Orijinal LBP, standart 3×3 karesel komşuluk kullanmasından dolayı, görüntünün dönmesinden bağımsız özniteliklerinin tanımlanmasında dezavantaj oluşturur. Bu sebeple yöntem geliştirilerek, farklı yarıçaplara ve komşu sayısına sahip dairesel topolojiler kullanılmıştır. Dairesel topolojinin kullanılmasıyla, görüntü içindeki farklı boyutlardaki dokuların analizinin daha iyi yapılması sağlanmıştır. Farklı tipteki dairesel simetrik topolojilere örnek olarak, Şekil 2.2. (a)'da 8 komşuluk 1 yarıçapa sahip örüntü, Şekil 2.2. (b)'de 8 komşuluk 2 yarıçapa sahip örüntü ve Şekil 2.2. (c)'de 16 komşuluk 2 yarıçapa sahip örüntü gösterilmektedir.



Şekil 2.2. (a) (8,1) komşuluğa sahip örüntü, (b) (8,2) komşuluğa sahip örüntü, (c) (16,2) komşuluğa sahip örüntü

Merkez pikselin komşu noktaları dairesel olarak konumlandırıldığı için bazı komşu noktalar piksellerin merkezinde bulunmamaktadır. Bu gibi durumlarda, komşu noktanın piksel değeri çiftdoğrusal interpolasyon (bilineer interpolation) kullanılarak elde edilmiştir. Örneğin bir komşu noktanın (S) Şekil 2.3.'deki gibi konumlandırıldığını ve bulunduğu konuma en yakın piksellerin 50, 100, 200 ve 300 yoğunluklarına ($I(P_1)$, $I(P_2)$, $I(P_3)$, $I(P_4)$) sahip P_1 , P_2 , P_3 ve P_4 noktaları olduğunu varsayalım.



Şekil 2.3. Bilineer interpolasyon için örnek bir görüntü

Öncelikle A noktasının yoğunluk değeri aşağıdaki denklem ile hesaplanır.

$$I(A) = (A(x) - P_1(x)) \cdot I(P_2) + (P_2(x) - A(x)) \cdot I(P_1) \quad (2.1)$$

Aynı şekilde B noktasının yoğunluk değeri hesaplanır.

$$I(B) = (B(x) - P_3(x)) \cdot I(P_4) + (P_4(x) - B(x)) \cdot I(P_3) \quad (2.2)$$

A ve B noktalarının yoğunluk değerleri belirlendikten sonra aşağıdaki denklem uygulanarak S komşusunun gri-seviye değeri hesaplanır.

$$I(S) = (S(y) - A(y)) \cdot I(B) + (B(y) - S(y)) \cdot I(A) \quad (2.3)$$

Eğer R yarıçaplı P komşuluk sayısına sahip merkez pikselin koordinatları $(0,0)$ ise, p . komşunun koordinatları $(-R \sin(2\pi p/P), R \cos(2\pi p/P))$ şeklinde belirlenir.

Orijinal LBP'de olduğu gibi dairesel komşuluklara sahip merkez piksellerin LBP kodları aşağıda verilen formül ile oluşturulur:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, \quad s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.4)$$

Burada g_c ve g_p sırasıyla merkez pikselin ve p . pikselin yoğunluk değerlerini ifade etmektedir. Her piksel için LBP kodlar oluşturulduktan sonra elde edilen kodların histogramları öznitelik vektörü olarak kullanılır.

Tekdüze LBP (ULBP), LBP kodlarıyla elde edilen olası örüntü sayısını indirgemek amacıyla Ojala tarafından önerilmiştir. ULBP, örüntüden üretilen ikili koddaki bit geçiş sayılarını dikkate alarak tekdüze ve tekdüze olmayan olarak ikiye ayırır. Tekdüze örüntüler 0'dan 1'e ve 1'den 0'a geçiş sayısı en fazla iki olan örüntülerdir. Tekdüze olmayan örüntüler ise bit geçiş sayısı ikiden fazla olan örüntülerdir. Örneğin 00011000 örüntüsü 2 geçişe, 11111110 örüntüsü 1 geçişe sahiptir. Bu nedenle bu iki örüntü tekdüze örüntülere örnektir. Fakat 10101000 örüntüsü 4 geçişe sahip olduğu için tekdüze olmayan bir örüntüye örnektir. ULBP ile gerekli olmayan örüntüler göz ardı edilerek öznitelik boyutu azaltılmıştır.

8 komşuluğa sahip LBP kodları toplamda 256 adet olası örüntüye sahiptir. Tüm olası örüntüler içerisinde 00000000, 00000001, 00000011, 00000111, 00001111, 00011111, 00111111, 01111111 ve 11111111 örüntülerinin dairesel olarak döndürülmesiyle toplam 58 adet tekdüze örüntü elde edilir. Tekdüze olmayan tüm örüntüler, histogramda tek bir çubuğa sahiptir. Dolayısıyla bu durumda LBP histogram boyutu 59'a indirgenmiştir.

Orijinal LBP karesel topoloji kullandığından dolayı dönmeden bağımsız örüntüler üretemez. Dairesel topolojinin uygulanmasıyla dönmeye karşı duyarlı hale getirilmiştir. Örneğin; bir görüntünün 8 bitlik ikili kodunun 00001111 olduğunu varsayalım. 00011110, 00111100, 01111000, 11110000, 11100001, 11000011, 10000111 örüntüleri 00001111 örüntüsünün döndürülmüş versiyonlarıdır. Dolayısıyla tüm döndürülen örüntüler aslında tek bir örüntüye denktir. Bu örüntü seçilirken tüm olası örüntüler içinde onluk tabanda minimum olan örüntü dikkate alınır. Görüntüye dönmeden bağımsız LBP özelliği aşağıdaki şekilde tanımlanmaktadır:

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i) \mid i = 0, \dots, P - 1\} \quad (2.5)$$


Denklem 2.5’de P , komşu sayısını, R , yarıçap değerini ve $ROR(x, i)$, örüntüdeki her bir komşunun dairesel olarak, en büyük değerin en sağda olacak şekilde minimum değere döndürülmesini ifade etmektedir.

$LBP_{P,R}^{riu2}$ ise tekdüze dönmeden bağımsız örüntüleri temsil etmektedir. Dönmeden bağımsız $LBP_{P,R}^{ri}$ örüntüleri 8 komşuluğa sahip örüntüler için toplamda 36 tanedir. İçlerinde tekdüze özelliği bulunan 9 örüntü ve tekdüze olmayan örüntüler için 1 örüntü seçilerek bu sayı 10’ a düşürülmüştür. $LBP_{P,R}^{riu2}$ aşağıdaki formül ile hesaplanır.

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{if } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{otherwise} \end{cases} \quad (2.6)$$

Bazı problemlerde dönmeden bağımsız özelliklere ihtiyaç yoktur. Anizotropik (eş yönsüz, yönlere bağımlı) yapısal bilgilerin çok önemli özellikler olduğu problemlere rastlanabilir. Özellikle yüz tanıma problemlerinde göz ve dudak bölgeleri gibi anizotropik bilgiler önem kazanmaktadır. Bu tür bilgileri yakalayabilmek amacıyla Liao ve Chung’ın geliştirdikleri yöntem yüz tanımda oldukça başarılı olmuştur (2007).

Yöntemde, yüz görüntüsü 6 bölgeye ayrılarak her bir bölgeye önemine göre ağırlıklar verilmektedir. LBP yönteminde, dairesel topoloji yerine eliptik komşuluk topolojisi kullanılarak her bir bölgenin histogramı çıkarılmaktadır (Uzatılmış LBP - ELBP). Uyguladıkları eliptik topolojide, U_y , uzun yarıçap bilgisini, K_y kısa yarıçap bilgisini, N ise kullanılan komşu sayısını temsil etmektedir. Şekil 2.4.’de kullanılan eliptik topolojilere örnekler gösterilmektedir.



Şekil 2.4. Eliptik topoloji örnekleri

Histogramların elde edilme aşamasından sonra, öznitelik vektörü $[-1 \ 1]$ aralığında normalize edilerek her bölgenin ağırlığı ile çarpılır. Elde edilen vektörler birleştirilerek global bilgi elde edilir. Elde edilen öznitelige ek olarak ortalama maksimum uzaklık gradyan büyüklüğü (Average maximum distance gradient magnitude) adını verdikleri bir öznitelik geliştirmişlerdir. Uzaklık gradyan büyüklüğünü aşağıdaki denklem ile elde etmişlerdir.

$$|\nabla_d I(g_i, g_c)| = \frac{|I_{g_i} - I_{g_c}|}{|v_i - v_c|^2} \quad (2.7)$$

Denklemden $v = (x, y)$ pikselin konumunu, I_{g_i} ve I_{g_c} komşu pikselin ve referans pikselin yoğunluğunu ifade etmektedir. Her komşu pikselin uzaklık gradyan büyüklüğü hesaplanarak en büyüğü öznitelige eklenir. Geliştirdikleri öznitelikleri temel bileşen analizi (PCA), LDA ve Gauss RBF (radyal temelli fonksiyon) kerneli kullanarak SVM ile sınıflandırmışlardır. LBP öznitelikleri ile karşılaştırdıklarında geliştirdikleri öznitelikler daha başarılı sonuçlar vermiştir.

Nanni ve arkadaşlarının komşuluk topolojileri üzerine yaptıkları çalışmada Arşimet spirali, elips, çember, parabol ve hiperbol gibi farklı geometrik şekilleri medikal görüntüler üzerinde test edilmiştir (2010). Komşuların merkez pikselle karşılaştırılmasında farklı kodlama yöntemleri denenerek 2,1,0,-1,-2 değerlerinin

atandığı yeni bir kodlama tekniđi geliştirilmiştir. Yaptıkları deneyler sonucunda en iyi performans, geliştirdikleri kodlama yönteminin elips komşuluk üzerinde gerçekleşmesi ile elde edilmiştir.

BÖLÜM 3. SINIFLANDIRICILAR

Bu bölümde doku tanımada kullanılan sınıflandırıcılar özetlenmiştir. Sınıflandırma aşamasında doğrusal regresyon sınıflandırıcı, doğrusal ayırtaç analizi ve destek vektör makinaları gibi altuzay tabanlı yöntemler test edilmiştir. Ayrıca, LBP ve LBP'ye dayalı öznelik çıkarım yöntemlerinden elde edilen özneliklerin histogram olması sebebiyle G-test ve Ki-kare (χ^2) testi gibi histogramların benzerliğini ölçen testler de kullanılarak doku tanımada önerilen öznelik çıkarım yöntemine en uygun sınıflandırıcı belirlenmiştir. Bölüm 5.1.2.'de bazı doku veritabanları üzerinde test edilen sonuçlar analiz edilmiştir. Yapılan deneyler sonucunda geliştirilen öznelik çıkarım yöntemine en uygun sınıflandırıcının yüz tanıma uygulamalarında başarılı bir şekilde kullanılan doğrusal regresyon sınıflandırıcı yöntemi olduğu gözlemlenmiştir.

3.1. Doğrusal Regresyon Sınıflandırıcı (LRC)

Doğrusal Regresyon Sınıflandırıcı (LRC), genellikle yüz tanıma problemlerinde kullanılan altuzay tabanlı bir sınıflandırma yöntemidir (Naseem ve ark., 2010, Koç ve Barkana, 2014) LRC yönteminde bir sınıftaki öznelik vektörlerinin doğrusal bir alt uzayda olduğu varsayılır.

N adet eğitim imgesine sahip C adet sınıf olduğunu ve öznelik uzay boyutunun n olduğunu varsayalım. x_i^j , i . sınıfın j . öznelik vektörünü temsil etmekte olup, i . sınıfın öznelik vektörlerini gösteren W_i 'nin sütununa yerleştirilmeden önce her bir öznelik vektörünün maksimum değeri 1 olacak şekilde normalize edilir. W_i matrisi Denklem 3.1 ile ifade edilebilir.

$$W_i = [x_i^1 : \dots : x_i^j : \dots : x_i^N] \quad (3.1)$$

Eğer y , i . sınıfa ait ise aynı sınıftaki eğitim imgelerinin doğrusal kombinasyonu olarak gösterilmelidir ve aşağıdaki şekilde tanımlanmalıdır:

$$\mathbf{y} = \mathbf{W}_i \boldsymbol{\beta}_i + \varepsilon \quad (3.2)$$

Denklem 3.2'de $\boldsymbol{\beta}_i$ en küçük kareler tahmini ile hesaplanan parametre vektörünü ifade eder. Dolayısıyla aşağıdaki gibi tanımlanır:

$$\widehat{\boldsymbol{\beta}}_i = (\mathbf{W}_i^T \mathbf{W}_i)^{-1} \mathbf{W}_i^T \mathbf{y} \quad (3.3)$$

Daha sonra i . sınıf için \mathbf{y} tahmini Denklem 3.4 ve Denklem 3.5 ile yapılmaktadır:

$$\widehat{\mathbf{y}}_i = \mathbf{W}_i (\mathbf{W}_i^T \mathbf{W}_i)^{-1} \mathbf{W}_i^T \mathbf{y} \quad (3.4)$$

$$\widehat{\mathbf{y}}_i = \mathbf{H}_i \mathbf{y} \quad (3.5)$$


Burada \mathbf{H}_i şapka matrisi olarak adlandırılmaktadır. Aşağıda verilen kritere göre orijinal vektör ile tahmin edilen vektör arasındaki minimum uzaklık Öklit uzaklık ölçütüne bağlı olarak hesaplanarak \mathbf{y} 'nin sınıflandırılması gerçekleşir:

$$\underset{i}{\operatorname{argmin}} \{ \|\mathbf{y} - \widehat{\mathbf{y}}_i\| \}, i = 1, 2, \dots, C \quad (3.6)$$

3.2. Destek Vektör Makineleri (SVM)

SVM'in çalışma prensibi iki sınıfı birbirinden en uygun şekilde ayırabilen hiperdüzlemin tanımlanması esasına dayanmaktadır (Cortes ve Vapnik, 1995). Verilerin doğrusal olarak ayrılabilir bir yapıda olması sınıflandırmayı kolaylaştırır. İki ya da daha fazla sınıfı birbirinden ayıracak bir çizgi belirlenir. Bu çizgi belirlenirken, sınırı, yani çizgi ile sınıfların çizgiye en yakın olan üyeleri arasındaki mesafeyi maksimum yapmak amaçlanır. Şekil 3.1.'de doğrusal olarak ayrılabilir iki sınıfı ayıran çizginin belirlenmesi örneklendirilmiştir. Fakat sınıflar doğrusal olarak birbirinden

ayrılması mümkün olmayan durumlarda sınıflandırma yapılırken, bu veriler öncelikle doğrusal olarak ayrılabilirleri farklı bir uzaya aktarılmalıdır. Ardından bu yeni uzayda sınıflandırılırlar.



Şekil 3.1. SVM'de hiper düzlemin seçilmesi

Giriş uzayındaki eğitim örneklerini bir H Öklit uzayına taşıyan Φ fonksiyonu göz önüne alınırsa, $\Phi: \mathcal{R}^d \rightarrow H$ olur (Fletcher, 2009). Artık, Destek Vektör Makinelerinin eğitim aşaması, H uzayındaki verilerin $\Phi(x_i)$, $\Phi(x_j)$ iç çarpımlarına bağlı olacaktır. Bu iç çarpım K , yani çekirdek fonksiyonu aşağıdaki denklemde gösterilmiştir:

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (3.7)$$

Sonuç olarak karar fonksiyonu Denklem 3.8'in işareti ile Denklem 3.9'da belirlenir:

$$f(x) = \sum_{i=1}^{ls} \alpha_i y_i \Phi(x_i) \cdot \Phi(x) + b \quad (3.8)$$

$$\text{sign}(f(x)) = \text{sign}\left(\sum_{i=1}^{ls} \alpha_i y_i K(x_i, x) + b\right) \quad (3.9)$$

Burada ls destek vektörlerinin sayısını, x_i ise destek vektörünü temsil etmektedir. Eğitim verileri kullanılarak hiperdüzlem bulunduktan sonra, test verileri sınırın hangi tarafında kalmışsa o sınıfa dahil edilir.

3.3. Doğrusal Ayırtaç Analizi (LDA)

LDA, veri içerisinde bulunan farklı sınıflara ait grupların doğrusal ayrılabilirliğini maksimize ederek boyut azaltması yapan bir yöntemdir. Her sınıf içerisindeki varyansı minimum ve sınıfların ortalamalarını birbirlerinden maksimum düzeyde uzak tutar (Martinez ve Kak, 2001).

N adet eğitim imgesine sahip C adet sınıf olduğunu varsayalım. Sınıflar içi saçılım matrisi \mathbf{S}_W aşağıdaki denklemlerle hesaplanır:

$$\mathbf{S}_W = \sum_{i=1}^C \mathbf{S}_i \quad (3.10)$$

$$\mathbf{S}_i = \sum_{\mathbf{x} \in W_i} (\mathbf{x} - \boldsymbol{\mu}_i)(\mathbf{x} - \boldsymbol{\mu}_i)^T \quad (3.11)$$

$$\boldsymbol{\mu}_i = \frac{1}{N} \sum_{\mathbf{x} \in W_i} \mathbf{x} \quad (3.12)$$

$\boldsymbol{\mu}_i$, W_i sınıfındaki \mathbf{x} örneklerin ortalamasını, \mathbf{S}_i , i . sınıfın kovaryans matrisini ifade etmektedir. Sınıflar arası saçılım matrisi \mathbf{S}_B aşağıdaki şekilde hesaplanır.

$$\mathbf{S}_B = \sum_{i=1}^C N(\boldsymbol{\mu}_i - \boldsymbol{\mu})(\boldsymbol{\mu}_i - \boldsymbol{\mu})^T \quad (3.13)$$

burada $\boldsymbol{\mu}$, tüm sınıflara ait \mathbf{x} örneklerinin ortalamasını ifade etmektedir. LDA izdüşümü, aşağıdaki genelleştirilmiş özdeğer probleminin çözümü olarak hesaplanır:

$$\mathbf{S}_W^{-1} \mathbf{S}_B \mathbf{w}_i = \lambda_i \mathbf{w}_i \quad (3.14)$$

Denklem 3.14'ün çözümünden $\mathbf{S}_W^{-1} \mathbf{S}_B$ matrisinin sıfırdan farklı $C - 1$ özdeğerine karşılık gelen özvektörlerden oluşan \mathbf{W} izdüşüm matrisi elde edilir.

\mathbf{y} test vektörü aşağıdaki karar kuralına göre sınıflandırılır:

$$\operatorname{argmin}_i \{W \|\mathbf{y} - \boldsymbol{\mu}_i\|\}, i = 1, 2, \dots, C \quad (3.15)$$

3.4. Log-likelihood İstatistiği

Örnek ve model histogramların benzerliğini ölçmek için genellikle parametrik olmayan istatistiksel testler kullanılır. Log-likelihood istatistiği, G-test adı verilen bir ölçümden elde edilir.

$$G(\mathbf{S}, \mathbf{M}) = 2 \sum_{b=1}^B S_b \log \frac{S_b}{M_b} \quad (3.16)$$

$$= 2 \sum_{i=1}^B (S_b \log S_b - S_b \log M_b) \quad (3.17)$$

Burada B , dağılımdaki çubuk sayısını, S_b ve M_b sırasıyla b . ikilideki ilgili örnek ve model olasılıklarını temsil etmektedir. G-test, sınıflandırma yapılırken $S_i \log S_i$ her model için aynı olması sebebiyle aşağıdaki şekilde sadeleştirilebilir:

$$L(\mathbf{S}, \mathbf{M}) = \sum_{b=1}^B S_b \log M_b \quad (3.18)$$

Test örneği S , log-likelihood istatistiğini maksimize eden M sınıf modeline atanır.

3.5. χ^2 Testi

χ^2 testi, histogramların benzerliklerini ölçmek amacıyla geliştirilmiş istatistiksel bir yöntemdir.

Karşılaştırılacak olan histogramların H ve K histogramları olduğunu ve histogramların çubuk sayısının toplamda B olduğunu varsayalım:

$$H = \sum_{i=1}^B \mathbf{h}_i \quad i = 1, 2 \dots B \quad (3.19)$$

$$K = \sum_{i=1}^B \mathbf{k}_i \quad i = 1, 2 \dots B \quad (3.20)$$


χ^2 testi ařađıdaki denklem ile hesaplanır.

$$d_{\chi^2}(H, K) = \sum_{i=1}^B \frac{(h_i - k_i)^2}{h_i + k_i} \quad (3.21)$$

denklemdede, h_i ve k_i sırasıyla H ve K histogramlarının i . çubuktaki deđerini ifade etmektedir.

BÖLÜM 4. SİRALLİ YEREL İKİLİ ÖRÜNTÜLER

Doku imgelerinin sınıflandırılması amacıyla öznelik çıkarımı aşamasında geliştirilen yöntem bu bölümde açıklanmıştır. Yöntemde, komşu noktalar ile merkez nokta arasındaki gri seviye farklılıkları hesaplanırken Arşimet spirali yapısı kullanılmıştır. Arşimet spirali kutupsal koordinat sisteminde, sabit bir açısal hız ile orijin etrafında dönen bir noktanın açısal hareketinden türetilmiştir. Kutupsal koordinat sistemi noktaların, Kartezyen koordinat sistemindeki orijine olan uzaklığı ve bir açı ile ifade edildiği iki boyutlu bir koordinat sistemidir. Bir P noktasının kutupsal koordinat sistemindeki tanımı Şekil 4.1.'de tanımlanmıştır.




Şekil 4.1. Kutupsal koordinat sistemi

Kutupsal koordinat sisteminde; P noktasının kutupsal koordinatları (r, θ) olarak gösterilmektedir. Burada r , P noktasının merkeze olan uzaklığı, θ ise kutupsal eksen ile pozitif yönde yaptığı açı olarak tanımlanmaktadır. Arşimet spirali kutupsal koordinat sisteminde aşağıdaki denklemle ifade edilir:

$$r = a + b\theta \quad (4.1)$$

Burada a ve b gerçel sayılardır. Spiralin başlangıç noktası a değeri ile belirlenir. b parametresi ise, spiralin kolları arasındaki mesafeyi değiştirerek spiralin daha geniş ya da dar açıda döndürülmesini sağlar. Önerilen topolojide, spiralin LBP kodu hesaplanacak pikselin merkezinden başlaması gerektiğinden $a = 0$ seçilmiştir. Şekil 4.2.'de farklı b parametreleri ile oluşturulan spiraller gösterilmektedir.



Şekil 4.2. İki farklı b değeri (a) $b = 0,3$ (b) $b = 0,6$ için çizilen spiral örnekleri

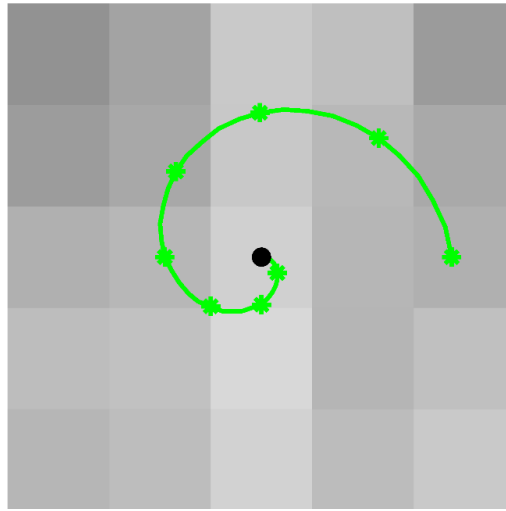
Şekil 4.2. (a)'da b parametresi 0,3 ve Şekil 4.2 (b)'de b parametresi 0,6 olarak ayarlandığında b parametresinin spiral üzerindeki etkisi açıkça görülmektedir. Parametrenin değeri artırıldığında spiral daha geniş açılarla dönmekte, azaltıldığında daha dar açılarla dönmektedir. Başka bir ifadeyle, Arşimet spiralini oluştururken b değerinin daha yüksek seçilmesi spiralin daha geniş açıda döndürülmesini sağlamaktadır.

4.1. Tek Spiralli Yerel İkili Örüntüler (S1LBP)

Bu alt bölümde LBP kodunun oluşturulmasında spiral komşuluk kullanımı irdelenmiştir. Spiral komşuluk kullanılması ile ilgili merkez piksel çevresinde daha geniş bir tarama yapılarak, spiralin yapısı gereği daha anlamlı bilgiler elde edildiği öngörülmektedir. Ayrıca LBP'de referans piksel ile merkez piksele en yakın komşu arasındaki uzaklığın en az 1 pikselden oluşmasından dolayı merkez piksele 1 pikselden daha yakın bölgeler dikkate alınmamıştır.

Nanni ve ark. Arşimet spirali ve parabol, hiperbol gibi birçok şekli topoloji kullanımında test etmişlerdir (2010). Fakat kullandıkları şekiller ile ilgili detaylı bir bilgi vermemiş ve gerekli analizleri yapmamışlardır. Yaptıkları testler sonucunda en iyi topolojinin eliptik topoloji olduğuna karar vermişlerdir. Doğruluk oranları karşılaştırmalı bir şekilde raporlanmıştır. Deneysel sonuçlara göre topoloji kullanımında elips ile Arşimet spirali arasında ciddi bir tanıma oranı artışı kaydedememişlerdir. Bu sebeple Arşimet spiralinin topoloji olarak kullanılmasının daha iyi analiz edilmesi gerekmektedir. Yapılan bu çalışma, tez çalışmasının motivasyonu açısından etkili olmuştur.

Değınilen bu avantajlar ve literatürdeki eksiklikler dolayısıyla, yapılan çalışmada çember yerine spiral komşuluk kullanılarak, LBP kodları oluşturulmuş ve görüntünün daha iyi tanımlanması sağlanmıştır. Şekil 4.3.'de görüntü üzerinde kullanılan spiral topolojiye bir örnek gösterilmektedir.



Şekil 4.3. 8 komşuluğa sahip 1 spiralli yapı (S1LBP)

LBP yönteminde görüntüde bulunan her bir piksel sırayla merkez piksel olarak seçilmektedir. Şekil 4.3.'de siyah daire ile temsil edilen bir merkez piksel ve yeşil yıldızlarla temsil edilen merkez piksele komşu 8 adet noktaya sahip bir örüntü gösterilmektedir. Kullanılan spiral 2π kadar döndürülmüştür. Spiral üzerinde bulunan

komşu sayısı 8 olarak seçilmiştir. Komşu pikseller $\pi/4$ aralıklarla yani eşit açılarla konumlandırılmıştır.

Spiral üzerindeki komşuların eşit açılarla konumlandırılması, komşular arası uzaklığın farklı olmasına neden olmuştur. Spiralin yay uzunluğu hesaplanarak komşu sayısına bölüldüğünde her bir komşunun açısal olarak konumu belirlenmiş ve buna göre konumlandırılmıştır. Yapılan deneyler sonucunda bu durum analiz edilerek komşuların eşit uzaklıkta seçilmesinin bir avantaj sağlamadığı, tanıma oranlarının %2 civarında düştüğü tespit edilmiştir. Bu sebeple yapılan tez çalışması kapsamında spiral üzerindeki komşular açısal olarak eşit dağıtılmıştır. Spiral üzerindeki herhangi bir komşu noktanın, bir pikselin merkezi ile çakışmaması durumunda komşu noktanın intensity (yoğunluk) değeri çiftdoğrusal interpolasyon ile hesaplanmıştır.

Önerilen yöntemde, öznitelik oluşturulurken LBP ile aynı adımlar izlenir. Bu adımlar sırasıyla:

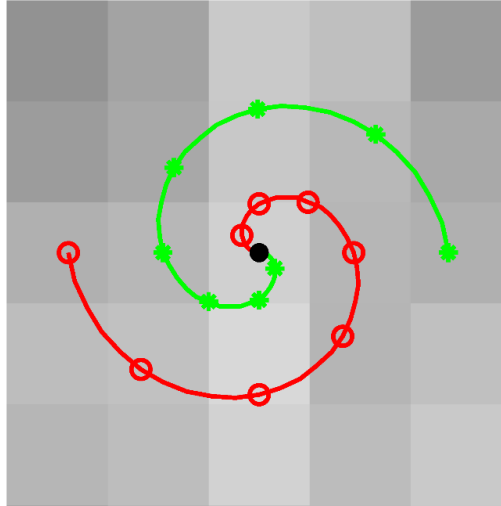
- Adım 1: Uygulanacak olan spiral şekli belirlenir.
- Adım 2: Komşu sayısına göre, merkez piksel etrafında komşu noktalar spiral üzerinde konumlandırılır.
- Adım 3: Piksellerin merkezinde bulunmayan komşu noktaların yoğunluk değeri çiftdoğrusal interpolasyon ile hesaplanır.
- Adım 4: Merkez piksel ile spiral üzerinde merkez piksele en yakın konumda bulunan komşu noktanın yoğunluk değerleri karşılaştırılır. Merkez piksel değerinin büyük olması durumunda 0, diğer durumlarda 1 ikili değeri atanır.
- Adım 5: Komşu nokta sayısı sona erene kadar adım 4'e dönülür.
- Adım 6: Tüm karşılaştırmalar sonucunda komşu sayısı uzunluğunda bir ikili kod elde edilir.

- Adım 7: Oluşturulan ikili kod onluk tabana çevrilir ve merkez piksel bu değer ile etiketlenir.
- Adım 8: Görüntüdeki tüm pikseller tamamlanana kadar adım 2'ye geri dönlür.
- Adım 9: Her bir piksel için etiketler tamamlandıktan sonra bu etiketlerin histogramı oluşturulur ve algoritma tamamlanır.

Tekdüze spiral yerel ikili örüntüler (S1ULBP), ULBP' de olduğu gibi 0-1 veya 1-0 bit geçiş sayısına bağlı olarak belirlenir. İkili kod oluşturulurken, spiral üzerindeki komşulardan merkez piksele en yakın komşudan en uzak komşuya doğru gidilerek karşılaştırma yapılır. Eğer komşu piksel değeri, merkez piksel değerinden küçük ise 0, büyük ya da eşit ise 1 kodlanır. 0-1 veya 1-0 geçişleri ikiden fazla ise örüntü tekdüze değildir, en fazla iki geçiş var ise örüntü tekdüze bir örüntüdür. Tekdüze olmayan bütün örüntüler histogramdaki bir çubuğa karşılık gelecek şekilde, elde edilen tüm tekdüze örüntülerin histogramı öznitelik olarak kullanılır. Örneğin, 8 örnekleme noktası alındığında elde edilen S1LBP histogramı 59 boyutlu olur.

4.2. Çift Spiralli Yerel İkili Örüntüler (S2LBP)

Kutupsal koordinat sisteminde spiral denklemi bu bölümün başında tanımlanmıştır. Bu denklemde θ açısına π eklendiğinde birbirinin açısız olarak simetriği olan iki spiral oluşur. Her iki spiral üzerinde ayrı ayrı komşu noktaların konumu belirlenir. Bu işlem yapılırken her bir spiralın üzerindeki komşu noktalar açısız olarak eşit aralıklarla konumlandırılır. Oluşturulan spiral topolojisi LBP kodu hesaplanırken kullanılır. Şekil 4.4.'de çift spiralli yapıya ait bir örüntü verilmiştir.



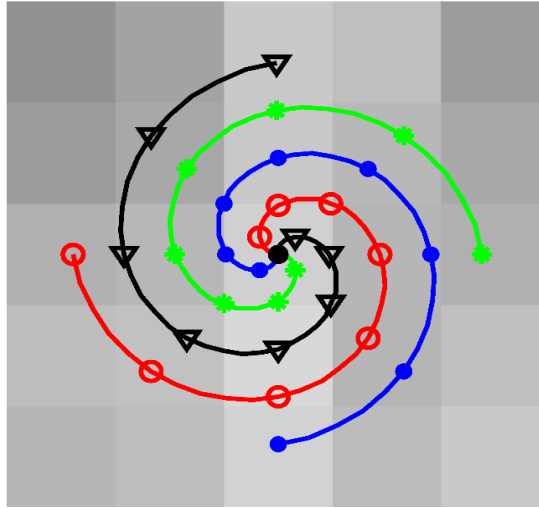
Şekil 4.4. 8 komşuluğa sahip 2 spiralli yapı (S2LBP)

İki spiralli yapıda her bir spiral için ayrı ayrı LBP histogramları hazırlanır. Elde edilen iki histogram birleştirilerek öznitelik olarak kullanılmaktadır. Örneğin Şekil 4.4.'de siyah daire ile gösterilen merkez piksel değeri, öncelikli olarak yeşil spiraldeki komşu piksellerin değerleri ile kıyaslanır. Karşılaştırma, merkez piksele en yakın komşudan en uzak komşuya doğru yapılmaktadır. Bunun sonucunda 8 bitlik bir ikili kod üretilir. Daha sonra kırmızı renkli spiral üzerindeki komşuluklar ile karşılaştırma yapılarak buradan da bir ikili kod üretilir. Elde edilen ikili kodlar onluk tabana dönüştürülür. Sonuç olarak her merkez piksel iki adet etikete sahip olur. Her piksel merkez piksel olarak seçildiği için görüntüdeki toplam piksel sayısının iki katı kadar etiket oluşturulmuş olur. Fakat nihai histogram oluşturulurken yeşil renkteki spiraller için oluşturulan etiketlerin histogramı ile kırmızı spiraller ile elde edilen histogram birleştirilir. Böylelikle 8-8 komşuluk kullanan S2LBP için bir görüntünün öznitelik boyutu $2^8 + 2^8 = 512$ olmaktadır.

Tekdüze S2LBP (S2ULBP), çift spiralli topoloji yapısından elde edilen tekdüze örüntüleri ifade etmektedir. 8 komşuluğa sahip tek spiralli bir S1LBP'de, elde edilen histogramın çubuk sayısı tekdüze örüntüler için 58 ve tekdüze olmayan örüntüler için 1 olmak üzere toplamda 59'dur. Çift spiralli yapıda ise her bir spiral için ayrı ayrı histogramlar hesaplanmaktadır. Bu nedenle S2ULBP'de öznitelik iki histogramın birleştirilmesi sonucu öznitelik boyutu 118'e çıkmaktadır.

4.3. Dört Spiralli Yerel İkili Örüntüler (S4LBP)

Gri seviye farklılıklarının hesaplanması aşamasında, spiral denkleminde belirtilen θ açısına her seferinde $\pi/2$ eklenerek oluşturulan 4 spiralli yapı kullanılmaktadır. Şekil 4.5.'de bu yapıya sahip bir örüntü gösterilmiştir.



Şekil 4.5. 8 komşuluğa sahip 4 spiralli yapı (S4LBP)

4 spiralli komşuluk topolojisinin kullanılması örüntüye ait daha detaylı ve anlamlı bilgiler çıkarılmasını amaçlar. Bir görüntüdeki her bir pikselin tek spiral komşuluğunda k adet komşu noktası bulunuyorsa öznitelik boyutu aşağıdaki denklem ile hesaplanabilir:

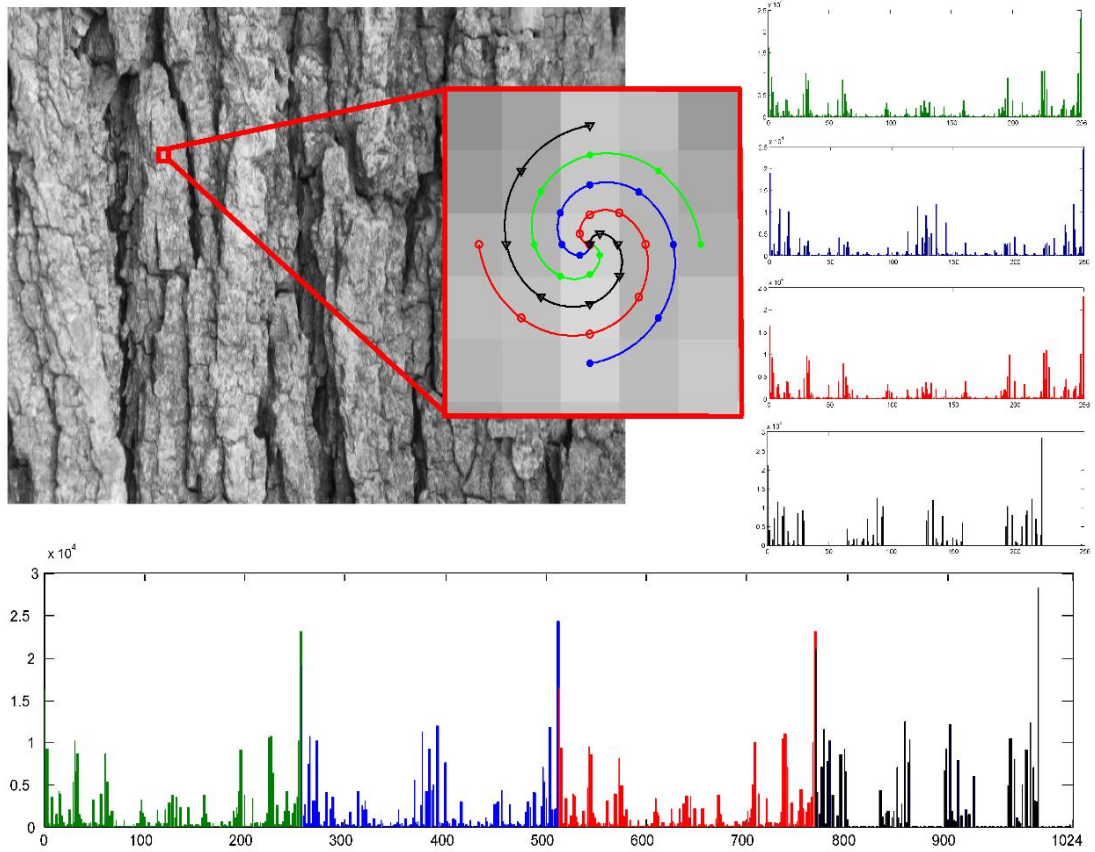
$$B = n * 2^k \quad (4.2)$$

Denklemde n toplam spiral adedini ifade etmektedir. Sonuç olarak elde edilen histogram B adet çubuğa sahiptir.

Şekil 4.6.'da S4LBP ile öznitelik çıkarım süreci örneklenebilir. Şekilde, görüntü üzerinde seçilen bir merkez pikselin komşuları 4 spiralli topoloji kullanılarak konumlandırılmıştır. Örnekte, öncelikle yeşil renkte gösterilen spiral üzerindeki komşular ile merkez piksel karşılaştırılmıştır. Karşılaştırma işlemi diğer spiralli topolojilerde olduğu gibi merkez piksele en yakından en uzak komşuya doğru

yapılmıştır. Komşu piksellerin, merkez pikselle arasındaki farklar göz önüne alınarak ikili bir kod üretilir. Son olarak bu ikili kod onluk tabana çevrilerek, seçilen merkez pikselin yeşil renk ile gösterilen spiral için bir etiketi oluşturulmaktadır. Görüntü üzerindeki diğer tüm pikseller için aynı işlem tekrar edilerek, her pikselin yeşil renkli spirali için etiketleri tamamlanır. Elde edilen etiketlerin histogramı oluşturularak ilk aşamadaki öznitelik belirlenmiş olur.

İlk spiral için görüntünün histogramı elde edildikten sonra mavi renk ile gösterilen spiral için süreç başlatılır. Merkez piksel ile mavi renkli spiral üzerindeki komşuları karşılaştırılarak ikili kod üretilir. Elde edilen ikili kod onluk tabana çevrilerek merkez pikselin etiketi belirlenir. Görüntü üzerindeki tüm piksellerde aynı işlemler tekrar edilerek mavi spiral için bir histogram oluşturulur.



Şekil 4.6. S4LBP'nin çalışma yapısı

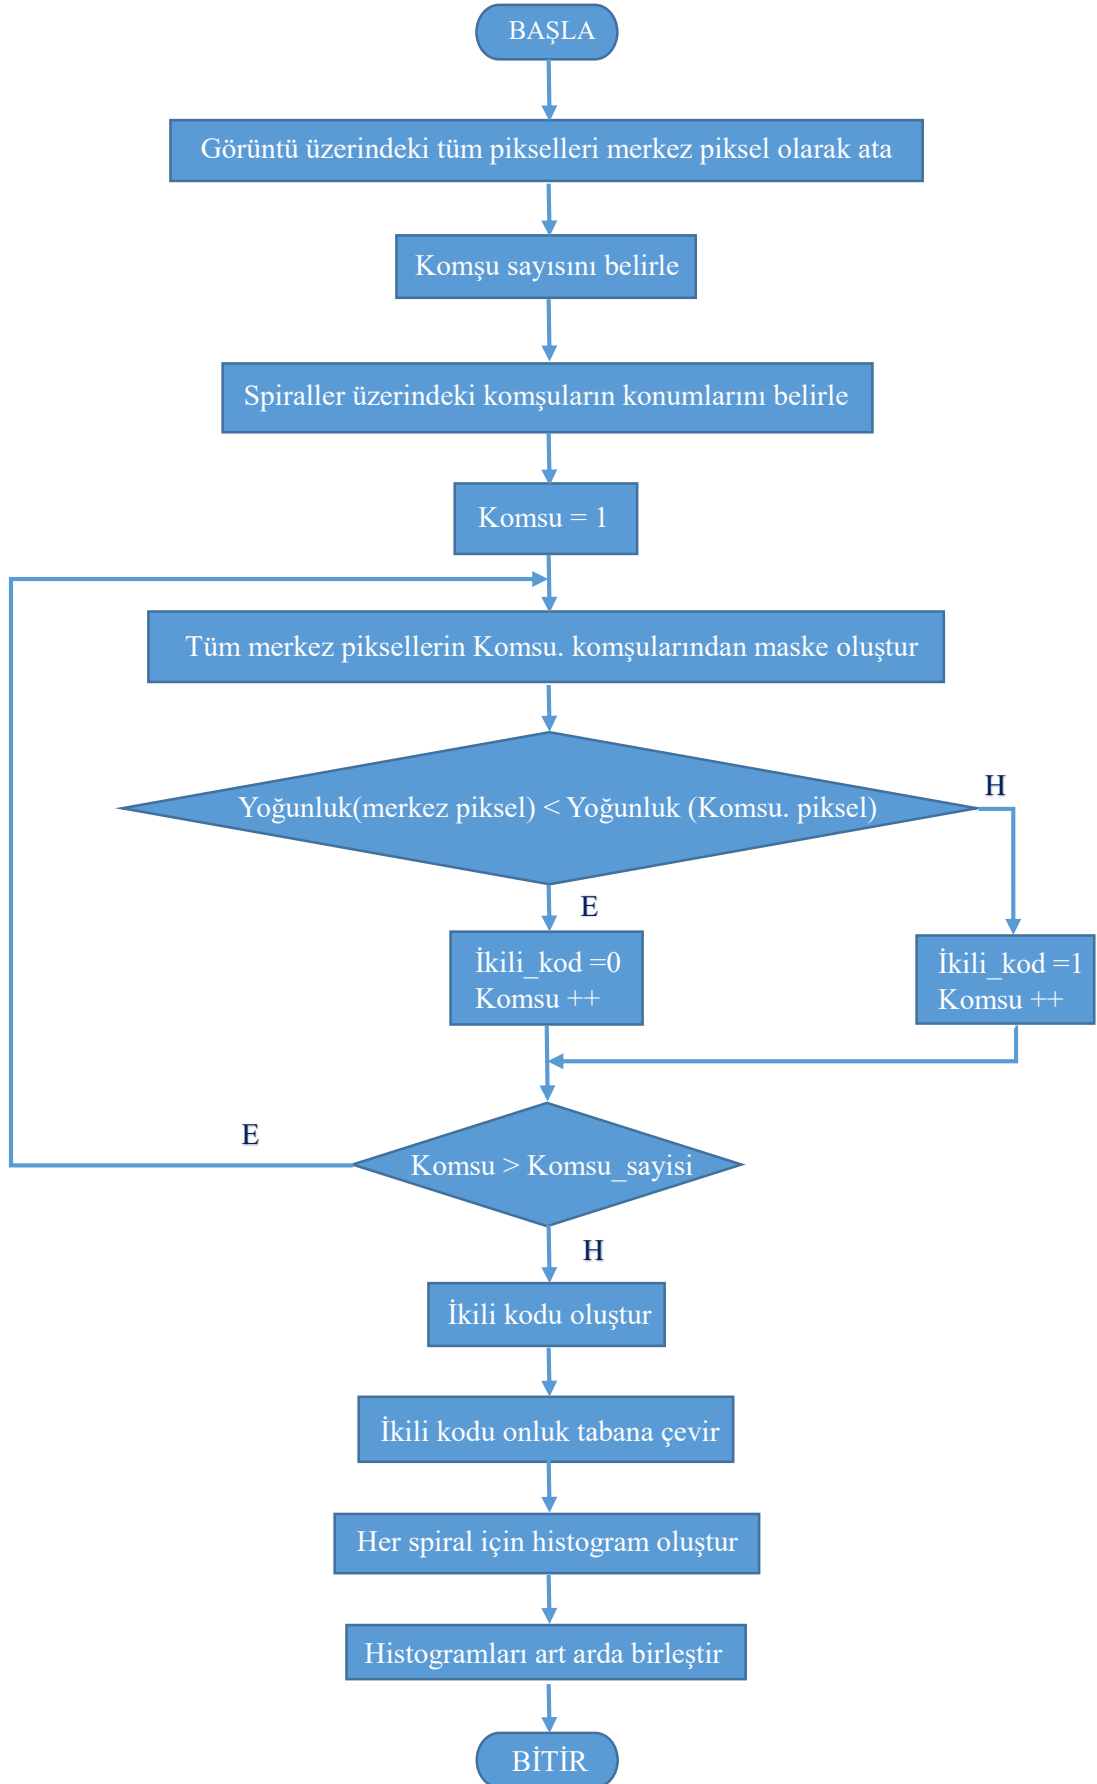
Algoritma, diğer renkteki spiraller için de tekrar edilerek ayrı ayrı histogramlar elde edilir. Son olarak bütün histogramlar birleştirilerek görüntüye ait öznitelik çıkarılmış

olur. Verilen örnekte $2^8 + 2^8 + 2^8 + 2^8 = 1024$ çubuğa sahip tek bir histogram elde edilmektedir.

Tekdüze örüntüler kullanılarak özniteliklerin tanımlanmasında ise Tekdüze S4LBP (S4ULBP) kullanılmıştır. S4ULBP’de, oluşturulan dört spiralin her biri için ayrı ayrı histogramlar hesaplanır. Histogramlar hesaplanırken tekdüze örüntüler dikkate alınmıştır. 8 komşuluğa sahip tek spiralli bir S1LBP’de, elde edilen histogramın çubuk sayısı tekdüze örüntüler için 58 ve tekdüze olmayan örüntüler için 1 olmak üzere toplamda 59’dur. Dört spiralli yapıda ise dört histogramın birleştirilmesi sonucu öznitelik boyutu $59 * 4 = 236$ olmaktadır.

S2LBP ve S4LBP topolojilerinde spiral sayısının fazla olması sebebiyle, LBP kodunun hesaplanması aşamasında çok sayıda karşılaştırma yapılmaktadır. Bu işlem de hesapsal yükün artmasına neden olmaktadır. Yöntemin, bahsedilen dezavantajını ortadan kaldırabilmek için Şekil 4.7.’de verilen algoritma adımları izlenmektedir.

Algoritmaya göre, görüntüde bulunan bütün pikseller aynı anda merkez piksel olarak işaretlenir. Spiral sayısı belirlenerek, merkez piksel etrafındaki spiraller üzerinde bulunan komşu noktaların konumları işaretlenir. İlk olarak, merkez piksele en yakın komşulardan oluşan bir maske oluşturulur. İlk komşular ile karşılaştırma yapılarak ikili kod üretilir. Daha sonra ikinci komşulardan oluşan maske kullanılır. Maske ile merkez piksellerin karşılaştırılması sonucunda ikili kod üretilir. Bu işlemler, bir spiral üzerindeki toplam komşu sayısı kadar tekrar eder. Sonuç olarak, görüntü üzerindeki her pikselin, topolojide kullanılan spiral sayısı kadar ve bir spiral üzerindeki komşu sayısı uzunluğunda ikili kodları oluşur. Örneğin; görüntü üzerindeki bir piksel, 4 spiralli 8 komşuluklu bir örüntü için 4 adet 8 bitlik ikili koda sahip olur. Daha sonra ikili kodlar onluk tabana çevrilerek pikseller üzerindeki etiketler belirlenir. Her spiral için ayrı ayrı histogramlar oluşturulur. Son olarak bu histogramlar art arda birleştirilerek algoritma tamamlanır.



Şekil 4.7. SLBP algoritma adımları

Uygulanan algoritma sayesinde, her spiral için sırasıyla bütün işlemlerin yapılması yerine bir örüntü üzerinde bulunan tüm spiraller için işlemlerin aynı anda yapılması, süreyi ve hesaplama maliyetini azaltmıştır.

S1LBP'nin hesapsal karmaşıklığı şu şekilde tanımlanabilir: Örneğin, dairesel topoloji kullanan ve m tane komşuya sahip, toplamda N adet pikselden oluşan bir görüntü olduğunu varsayarsak, LBP'nin karmaşıklığı $O(mN)$ olmaktadır. Çünkü görüntüdeki N adet piksel için m kadar kaydırılarak hesaplama yapılmaktadır. Yine benzer yaklaşımla bir spiral kullanılan topoloji için hesapsal karmaşıklık $O(mN)$ olmaktadır. S2LBP ve S4LBP topolojilerinde sırasıyla iki spiral ve dört spiral bulunmaktadır. Dolayısıyla hesapsal karmaşıklıkları $O(2mN)$ ve $O(4mN)$ olarak hesaplanmaktadır. $O(mN) = O(2mN) = O(4mN)$ eşitliği sebebiyle S2LBP ve S4LBP yöntemlerinin hesapsal karmaşıklıkları S1LBP ile aynı olmaktadır.

Algoritma çalışma süresi açısından bakıldığında ise spiral topoloji kullanmanın, dairesel topoloji kullanmaya göre tek dezavantajı, spiral üzerindeki komşu noktaların piksel merkezlerine denk gelmemesinden dolayı çiftdoğrusal interpolasyon kullanılmasıdır. LBP, S1LBP, S2LBP, S4LBP ve literatürde bulunan bazı yöntemlerin çalışma süreleri Bölüm 5'de karşılaştırmalı olarak verilmektedir.

BÖLÜM 5. DENEYSEL SONUÇLAR


Bu bölüm doku tanıma uygulamaları, yüz tanıma uygulamaları ve öznitelik seçimi olmak üzere üç ana başlık altında incelenmiştir. Doku tanıma uygulamaları ana başlığının altında; kullanılan doku veritabanları, topolojide uygulanan spiral şeklinin belirlenmesi, sınıflandırıcı seçimi, geliştirilen öznitelik çıkarımı yöntemlerinin testi ve spiral topoloji tabanlı LBP yöntemleri ile görüntülerin kenar bilgilerini kullanan yeni bir öznitelik çıkarım algoritması ile yeni bir öznitelik seçim algoritması detaylı olarak anlatılmıştır. Yöntemlerin başarımları çeşitli deneyler ile ölçülmüştür. Yüz tanıma uygulamaları ana başlığının altında, geliştirilen spiral topoloji tabanlı LBP yöntemleri belirlenen yüz veritabanları üzerinde test edilerek, doğruluk oranları karşılaştırmalı olarak verilmiştir. Son olarak öznitelik seçimi ana başlığının altında ise yeni bir öznitelik seçim algoritması tanımlanarak, doku veritabanları üzerinde yapılan testler sonucunda doğruluk oranlarının değişimi incelenmiştir.

5.1. Doku Tanıma Uygulamaları

Bu bölümde, geliştirilen spiral komşuluk topolojileri tabanlı yöntemler ve tekdüze versiyonlarının etkinliğini ölçmek amacıyla bazı bilinen doku veritabanları üzerinde uygulanmış ve eliptik topoloji tabanlı ELBP, dairesel topoloji tabanlı orijinal LBP gibi bilinen popüler LBP yöntemleri ile karşılaştırılmıştır.

Öznitelik çıkarım yöntemlerinin etkinliğini ölçmek amacıyla üzerinde çalışılan veritabanlarından ilki doku tanıma problemlerinde yaygın olarak kullanılan CURet (Columbia-Utrecht Reflectance and Texture Database) doku veritabanıdır. 61 farklı malzeme dokusuna sahip sınıf ve her sınıfa ait farklı görüş açıları ve ışık yönelimlerine sahip 205 doku imgesi kontrollü bir laboratuvar ortamında geliştirilmiştir (Dana ve ark., 1999). 60 derecenin altında çekilen 118 adet doku imgesi bulunmaktadır.


Varma ve Zisserman da orijinal CUREt veritabanını temel olarak sınıflandırma performansını ölçmek amacıyla yaygın olarak kullanılan bir alt set oluşturmuşlardır (2005). Yaptıkları çalışmada, her sınıfta bulunan imgelerin 92 tanesini seçilmiş ve 200×200 boyutunda kırılmıştır. Daha sonra gri-seviyeye dönüştürülerek veritabanı hazırlanmıştır. Yapılan tez çalışması kapsamında Varma ve Zisserman'ın hazırladıkları CUREt doku veritabanı kullanılmıştır. Şekil 5.1.'de her sınıftan rasgele seçilen bir örnek gösterilmektedir.



Şekil 5.1. CUREt doku veritabanından örnekler

Kullanılan diğer bir veritabanı ise UIUC doku veritabanıdır. UIUC (University of Illinois Urbana-Champaign) tarafından hazırlanan doku veritabanı 25 sınıftan oluşmaktadır. Her bir sınıfta 40 adet doku görüntüsü bulunmaktadır (Lazebnik ve ark., 2005). Doku görüntülerinin çözünürlüğü 640×480 pikseldir. Veritabanı; farklı aydınlık derecesine sahip yüzeyler, 3D şekiller ve ikisinin karışımına ait sınıfları kapsamaktadır. Sınıf içerisindeki görüntüler, değişik görüş açlarına, farklı ölçeklendirmelere ve deformasyonlarda önemli değişikliklere sahiptir. Ancak CURET

doku veritabanından daha az şiddetli aydınlatma varyasyonlarına sahiptir. Bu veritabanının zorlukları, sınıf başına düşen görüntülerin az sayıda olması ve sınıf içerisindeki az sayıda bulunan görüntülerin birbirlerine göre önemli derecede değişkenlik göstermesidir. Şekil 5.2.'de UIUC doku veritabanındaki her sınıftan birer örnek gösterilmektedir.




Şekil 5.2. UIUC doku veritabanından örnekler

5.1.1. Spiral şeklinin belirlenmesi

Bu tez çalışması kapsamında LBP kodunun hesaplanması aşamasında, dördüncü bölümde değinilen Arşimet spirali kullanılarak bir topoloji oluşturulmuştur. Topolojinin tasarım aşamasında uygulanacak olan Arşimet spirali şeklinin belirlenmesi dokuyu daha iyi tanımlayabilmek için önemli bir adımdır. Spiralin, başlangıç noktasından itibaren daha geniş açılarla ya da daha dar açılarla döndürülmesi ile merkez piksel etrafındaki komşu noktaların konumlandırılmasında farklılık yaratmaktadır. Dolayısıyla Arşimet spiralinin kutupsal koordinat sistemi denklemindeki parametrelerin iyi belirlenmesi gerekmektedir. Bu bölümde, uygulanan spiral şeklinin belirlenmesinde izlenen adımlar anlatılmaktadır.

Arşimet spirali denklemindeki a parametresi 0 seçilerek, spiral, görüntü üzerinde seçilen herhangi bir referans pikselin merkezinden başlatılmıştır. Denklemde bulunan b parametresi ise $[0,2 \ 0,5]$ aralığında 0,1 adımlarla test edilmiştir. b parametresinin optimum değerine karar verebilmek amacıyla 1 spiral topoloji üzerinde 8 komşuluk kullanılmıştır.

Sınıflandırma aşamasında LRC yöntemi seçilmiştir. Deneyler UIUC doku veritabanı üzerinde yapılmıştır. Sınıflandırma işlemi yapılırken eğitim aşamasında her sınıftan rastgele seçilen 30 imge kullanılmıştır. Her sınıftan geriye kalan 10 imge kullanılarak da test işlemi gerçekleştirilmiştir. Doğruluk oranları, 10 kez sınıflandırma sonucu elde edilen doğruluk oranlarının ortalaması alınarak hesaplanmıştır. S1LBP ve S1ULBP için elde edilen sonuçlar Şekil 5.3.'de gösterilmiştir.



Şekil 5.3. Farklı b parametreleri ile elde edilen doğruluk oranları


Şekil 5.3.'den de gözlemlenebileceği gibi S1LBP ve S1ULBP için en yüksek tanıma oranlarına 0,3 değerinde ulaşılmıştır. Bu tez çalışması kapsamında kullanılan bütün spiraller için b değeri 0,3 olarak seçilmiştir.

5.1.2. Sınıflandırma yönteminin belirlenmesi


Doku tanıma 2 ana süreçten oluşmaktadır. İlki öznitelik çıkarımı, diğeri ise sınıflandırma sürecidir. Dokuyu en iyi özniteliklerle tanımlama en büyük problemlerden biriyken, elde edilen özniteliklerin en uygun sınıflandırıcı seçilerek sınıflandırılması da, tanıma problemlerinde yüksek doğruluk oranlarına ulaşabilmek adına büyük önem taşır. Bu bölümde, doku tanımada geliştirdiğimiz yöntemlere en uygun sınıflandırıcının belirlenmesi iki adımda incelenecektir.

İlk olarak, zor bir veritabanı olan UIUC doku veritabanında, LBP ve ULBP yöntemleri ile altuzay tabanlı sınıflandırıcıların doku tanıma başarımına etkisi incelenmiştir. LBP tabanlı bir öznitelik çıkarım yöntemi ile elde edilen öznitelikler histogramlardır. Bu sebeple literatürde, histogramların birbirine benzerliğini ölçmek amacıyla genellikle G-test, χ^2 testi gibi istatistiksel testler kullanılmıştır. Yapılan tez kapsamında altuzay tabanlı sınıflandırma yöntemlerinin, histogram öznitelikleri üzerindeki başarımını ölçmek amacıyla LRC, LDA ve doğrusal SVM yöntemleri doku tanımada kullanılmıştır. Daha sonra da χ^2 ve G-test gibi istatistiksel testler ile karşılaştırılmıştır. Deneyler, CURet doku veritabanına göre daha zor bir veritabanı olan UIUC doku veritabanı üzerinde uygulanmıştır.

Yapılan deneylerde her sınıftan rastgele seçilen 10, 15, 20, 25 ve 30 adet doku imgesi eğitim, geriye kalanlar ise test süreci için kullanılmıştır. Şekil 5.4. ve Şekil 5.5.'de sırasıyla LBP ve ULBP yöntemlerinde 8 komşuluk ve 1 yarıçaplı dairesel topoloji kullanılarak Bölüm 3.'de değinilen sınıflandırma yöntemlerinin başarısı gösterilmektedir. Doğruluk oranları, 10 kez sınıflandırma sonucu elde edilen doğruluk oranlarının ortalaması alınarak hesaplanmıştır

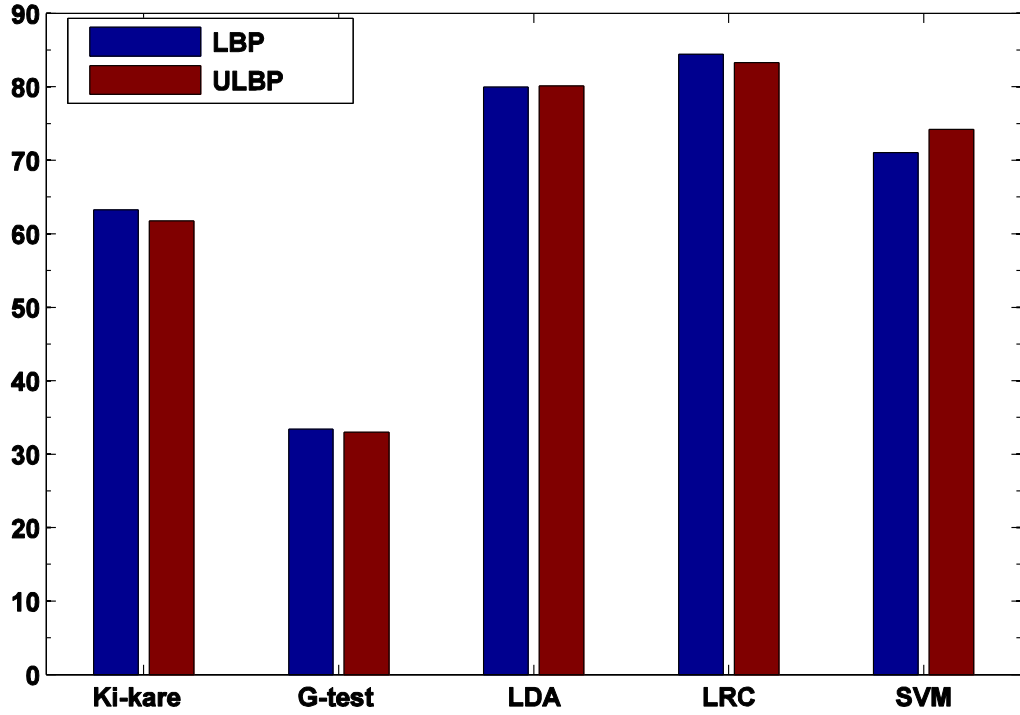


Şekil 5.4. LBP ile sınıflandırma oranları



Şekil 5.5. ULBP ile sınıflandırma oranları

En iyi sınıflandırıcıyı daha iyi gözlemleyebilmek amacıyla her sınıftan rasgele seçilen 30 adet eğitim imgesi için LBP ve ULBP yöntemleri ile çıkarılan öznitelikler; χ^2 , G-test, LDA, LRC ve doğrusal SVM ile sınıflandırılarak elde edilen tanıma oranları Şekil 5.6.'daki grafikte karşılaştırmalı olarak verilmiştir.




Şekil 5.6. Sınıflandırma yöntemlerinin 30 eğitim imgesi için ortalamaları

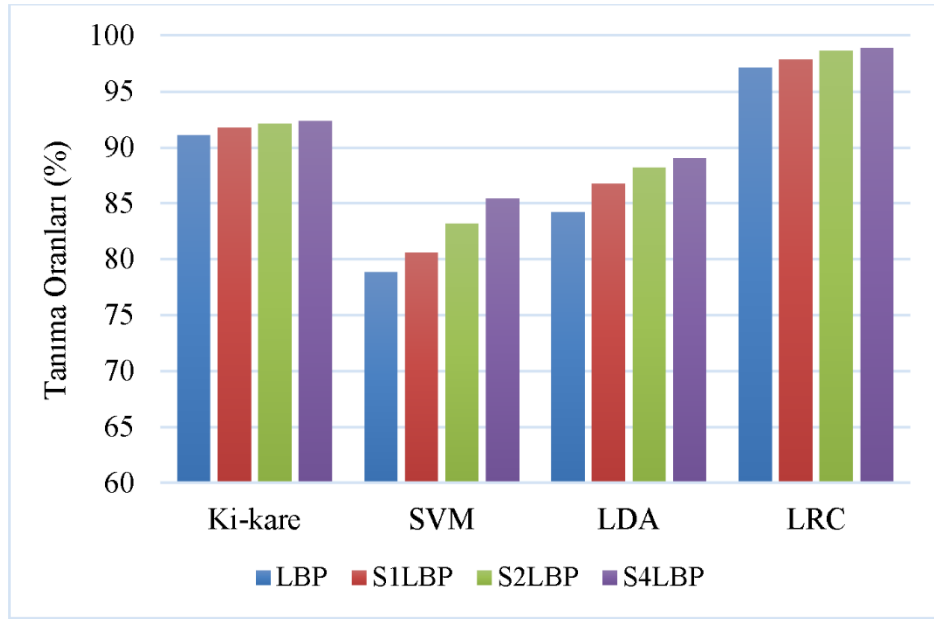
Yapılan deneysel çalışmalarda literatürde genellikle χ^2 gibi benzerlik ölçütü tabanlı istatistiksel testlerle sınıflandırılan LBP'nin, LRC gibi altuzay tabanlı yöntemlerde daha iyi sonuçlar verdiği görülmüştür. Ayrıca yapılan deneylerde altuzay tabanlı yöntemlerin benzerlik ölçütü kullanan sınıflandırma yöntemlerine göre %41'e varan oranlarda daha başarılı sonuçlar verdiği gözlemlenmiştir. Çalışmalar kapsamında elde edilen diğer bir bulgu ise G-Test ve χ^2 gibi benzerlik tabanlı sınıflandırıcılara ait başarımların eğitim örnek sayısının artmasıyla çok fazla değişmemesidir. Bu sınıflandırıcıların aksine altuzay tabanlı sınıflandırıcılarda eğitim örnek sayısı arttıkça sınıflandırma başarısı da önemli ölçüde artmaktadır. Bunun nedeni altuzay tabanlı sınıflandırıcıların eğitim örnek sayısı arttıkça veri sınıfını daha iyi ve kapsamlı bir şekilde modellemeleri olduğu düşünülmektedir.

Dairesel topoloji kullanımı ile elde edilen öznitelikler χ^2 , G-test, LDA, LRC ve doğrusal SVM ile sınıflandırıldığında, başta LRC olmak üzere altuzay tabanlı yöntemlerin daha uygun olduğu yapılan testler sonucunda belirlenmişti. En uygun sınıflandırıcının seçilmesi için yapılan çalışmalardan ikincisi ise; LRC yönteminin, spiral topoloji uygulanarak geliştirilen S1LBP, S2LBP ve S4LBP öznitelik çıkarım yöntemleri ile birlikte kullanımının tanıma oranları üzerindeki etkisini görmek amacıyla da bir dizi test işlemleri gerçekleştirilmiştir.

Yapılan deneylerde, LBP yöntemi ile birlikte uygulanan sınıflandırıcılardan en kötü doğruluk oranına sahip G-test çıkarılarak χ^2 , LDA, doğrusal SVM ve LRC yöntemleri kullanılmıştır. Deneyler UIUC ve CUREt doku veritabanları üzerinde uygulanmıştır. Eğitim seti olarak UIUC doku veritabanında her sınıftan rasgele seçilen 30 doku imgesi, CUREt doku veritabanında her sınıftan rasgele seçilen 46 doku imgesi kullanılmıştır. Eğitim setinde olmayan diğer imgeler ise test seti olarak belirlenmiştir. LBP ve spiral topoloji ile geliştirilen S1LBP, S2LBP ve S4LBP yöntemi ile öznitelikler üretilmiştir. Öznitelik çıkarım esnasında her bir yöntem için 8 komşuluk uygulanmıştır. Doğruluk oranları, 10 kez sınıflandırma sonucu elde edilen doğruluk oranlarının ortalaması alınarak hesaplanmıştır. Şekil 5.7. ve Şekil 5.8. sırasıyla UIUC ve CUREt doku veritabanları üzerinde elde edilen sonuçları göstermektedir.



Şekil 5.7. UIUC doku veritabanında doğruluk oranları



Şekil 5.8. CURet doku veritabanında doğruluk oranları

Yapılan deneyler sonucunda UIUC doku veritabanında; her bir öznitelik çıkarım yönteminde altuzay tabanlı sınıflandırma yöntemlerinin daha başarılı olduğu gözlemlenmektedir. CURet doku veritabanında ise χ^2 testinin tanıma oranının doğrusal SVM ve LDA'ya göre daha yüksek, LRC'ye göre daha düşük olduğu gözlemlenmektedir.

En uygun sınıflandırıcıyı seçmek amacıyla yapılan iki çalışma sonucunda da elde edilen doğruluk oranlarına dayanarak, tez çalışması kapsamında, sınıflandırma yöntemi olarak LRC seçilmiştir.

5.1.3. Geliştirilen yöntemlerin testi

Bu bölümde, farklı tip topoloji kullanan LBP türlerinden, dairesel topoloji kullanan standart LBP, eliptik topoloji kullanan ELBP ve spiral topoloji kullanan S1LBP, S2LBP, S4LBP ve bu yöntemlerin tekdüze versiyonları karşılaştırmalı olarak verilmiştir.

Yapılan çalışmalarda; öznitelik çıkarım yöntemlerinde topoloji üzerinde tanımlanan komşu sayıları 8 ve 16 olarak seçilmiştir. Dairesel topoloji kullanan LBP yönteminde

8 komşuluk tanımlandığında dairenin yarıçapı 1, 16 komşuluk tanımlandığında dairenin yarıçapı 2 olarak belirlenmiştir. ELBP yönteminde ise, uzun yarıçapı 3, kısa yarıçapı 2 olan elips şekli kullanılmıştır. Bölüm 5.1.2.'de yapılan deneyler sonucunda LRC yöntemi ile sınıflandırma gerçekleştirilmiştir.

Yöntemlerin etkinliklerini ölçmek amacıyla deneyler UIUC ve CURet doku veritabanları üzerinde uygulanmıştır. Eğitim seti için UIUC doku veritabanı sınıflarının her birinden rasgele seçilen 10, 15, 20 ve 30 doku imgesi, CURet doku veritabanı sınıflarının her birinden rasgele seçilen 46, 23 ve 12 adet doku imgesi kullanılmıştır. UIUC doku veritabanında geriye kalan 30, 25, 20 ve 10 adet doku imgesi ile CURet doku veritabanından geriye kalan 46, 69 ve 80 adet doku imgesi de test için kullanılmıştır.

Tablo 5.1. ve Tablo 5.2.'de sırasıyla UIUC ve CURet doku veritabanları üzerinde elde edilen tanıma oranları verilmiştir. Tablolarda bulunan P_N notasyonunda; P, komşuluk sayısını, N ise eğitim için kullanılan imge sayısını temsil etmektedir. Doğruluk oranları, 10 kez sınıflandırma sonucu elde edilen tanıma oranlarının ortalaması alınarak hesaplanmıştır. Tablolarda, ulaşılan en yüksek doğruluk oranları koyu gösterilmiştir.

Yapılan tez çalışmasında tüm deneyler 2.7 GHz Intel Quad CPU, 8 GB RAM, Windows 10 dizüstünde ve MATLAB versiyon 7.14 (2014a) ile gerçekleştirilmiştir. Geliştirdiğimiz spiral topoloji tabanlı yöntemler literatürde tanınan ve sıklıkla kullanılan, İkileştirilmiş İstatistiksel Görüntü Öznitelikleri (Binarized Statistical Image Features - BSIF) (Kannala ve Rahtu, 2012), Yerel Enerji Örneği (Local Energy Pattern - LEP) (Zhang ve ark., 2013), Gürültü Dayanıklı LBP (Noise-Resistant LBP - NRLBP^{riu2}) (Ren ve ark., 2013), Çok Ölçekli Ortak Kodlanmış LBP (Multi-Scale Joint encoding of LBP - MSJLBP) (Qi ve ark., 2013), Çiftli Dönme Değişmez Birliktelik (Pairwise Rotation Invariant Cooccurrence LBP - PRICoLBP) (Qi ve ark., 2014), Genişletilmiş Yerel Grafik Yapısı (Extended Local Graph Structure - ELGS) (Bashier ve ark., 2016) ve Baskın Döndürülmüş LBP (Dominant Rotated LBP - DRLBP) (Mehta ve Egiazarian, 2016) ile karşılaştırılmıştır. Merkez piksel etrafındaki

komşu sayısı 8'e sabitlenmiştir. UIUC doku veritabanının her sınıfından rasgele seçilen 20 imge, CUREt doku veritabanının her sınıfından rasgele seçilen 46 imge eğitim ve geriye kalanlar test için kullanılmıştır. Elde edilen doğruluk oranları Tablo 5.3.'de rapor edilmiştir.

Öznitelik çıkarım süresi ve öznitelik vektör boyutu, hesapsal karmaşıklığı ölçmek amacıyla kullanılan iki önemli parametredir. Geliştirdiğimiz yöntemin etkinliğini ölçmek amacıyla bahsedilen parametreler açısından birçok öznitelik çıkarım yöntemi ile karşılaştırılarak Tablo 5.4.'de rapor edilmiştir. Deneylerde 128×128 boyutunda 480 adet doku görüntüsüne sahip veri seti kullanılmıştır. Öznitelik çıkarım süresi 480 görüntünün öznitelik çıkarım esnasında harcanılan sürelerin ortalaması alınarak hesaplanmıştır. Tablolarda elde edilemeyen sonuçlar (-) ile gösterilmiştir.

Tablo 5.1. UIUC doku veritabanı üzerinde elde edilen doğruluk oranları

P_N	LBP	ULBP	ELBP	UELBP	S1LBP	S1ULBP	S2LBP	S2ULBP	S4LBP	S4ULBP
8_30	85,60 ± 2,01	83,28 ± 1,45	84,12 ± 3,04	78,72 ± 2,57	85,92 ± 1,76	84,32 ± 2,26	87,28 ± 2,56	87,20 ± 1,92	88,04 ± 1,88	88,08 ± 1,67
16_30	85,08 ± 3,40	85,08 ± 3,38	84,88 ± 2,27	84,44 ± 2,21	87,24 ± 2,51	87,48 ± 2,59	87,80 ± 2,70	87,76 ± 2,37	89,52 ± 2,59	88,84 ± 2,46
8_20	78,14 ± 2,36	77,22 ± 1,98	77,66 ± 2,09	74,06 ± 1,94	80,08 ± 2,20	78,76 ± 2,32	81,48 ± 1,96	81,44 ± 1,64	81,92 ± 2,39	81,74 ± 1,91
16_20	77,44 ± 2,11	76,60 ± 2,17	78,52 ± 1,91	77,86 ± 1,82	80,20 ± 1,66	79,58 ± 1,63	80,86 ± 1,75	80,72 ± 1,89	81,16 ± 1,89	81,12 ± 1,62
8_15	72,59 ± 2,42	71,92 ± 2,43	69,26 ± 2,87	65,93 ± 2,34	74,48 ± 2,24	73,50 ± 2,54	75,47 ± 1,89	74,75 ± 2,17	75,72 ± 2,19	75,26 ± 2,29
16_15	71,18 ± 1,98	70,89 ± 2,01	71,36 ± 2,84	70,16 ± 2,63	74,84 ± 1,80	74,27 ± 1,55	75,16 ± 1,99	74,91 ± 2,15	75,29 ± 2,02	75,12 ± 1,52
8_10	61,94 ± 2,06	61,96 ± 2,17	56,16 ± 1,47	53,16 ± 1,59	64,01 ± 1,77	63,25 ± 2,08	64,44 ± 1,89	63,73 ± 1,71	64,61 ± 2,08	64,22 ± 2,16
16_10	60,98 ± 2,26	60,18 ± 2,03	58,34 ± 1,57	56,01 ± 1,49	63,92 ± 1,56	63,29 ± 1,36	64,36 ± 1,45	64,02 ± 1,29	64,61 ± 1,39	64,08 ± 1,27

Tablo 5.2. CURet doku veritabanı üzerinde elde edilen doğruluk oranları

P_N	LBP	ULBP	ELBP	UELBP	S1LBP	S1ULBP	S2LBP	S2ULBP	S4LBP	S4ULBP
8_46	97,14 ± 0,36	87,59 ± 0,88	97,64 ± 0,34	79,41 ± 0,93	97,80 ± 0,17	88,45 ± 0,70	98,61 ± 0,13	98,17 ± 0,11	98,82 ± 0,17	98,68 ± 0,17
16_46	98,45 ± 0,41	98,40 ± 0,21	97,71 ± 1,02	88,11 ± 0,78	98,74 ± 0,33	97,81 ± 0,24	98,84 ± 0,48	97,97 ± 0,28	99,61 ± 0,24	98,86 ± 0,27
8_23	95,26 ± 0,52	94,38 ± 0,55	95,53 ± 0,51	92,73 ± 0,71	95,98 ± 0,36	95,20 ± 0,44	96,68 ± 0,49	96,53 ± 0,39	96,83 ± 0,40	96,82 ± 0,38
16_23	96,12 ± 0,70	95,98 ± 0,42	94,75 ± 0,52	94,71 ± 0,50	96,44 ± 0,36	95,28 ± 0,33	96,95 ± 0,52	95,50 ± 0,46	97,11 ± 0,42	95,89 ± 0,50
8_12	89,52 ± 0,92	89,00 ± 0,88	89,39 ± 0,64	87,23 ± 0,65	90,54 ± 0,93	90,19 ± 0,98	91,14 ± 0,88	90,98 ± 0,86	91,32 ± 0,86	91,31 ± 0,91
16_12	90,33 ± 0,77	89,82 ± 0,80	71,36 ± 2,84	87,82 ± 0,93	90,12 ± 0,82	88,57 ± 1,02	90,46 ± 0,39	88,80 ± 0,94	92,45 ± 0,80	89,92 ± 0,74

Tablo 5.3. Geliştirilen yöntemler ile bilinen diğer yöntemlerin doğruluk oranları

	LBP	ELBP	BSIF	LEP	NRLBP ^{riu2}	MSJLBP	PRICoLBP	ELGS	DRLBP	S1LBP	S2LBP	S4LBP
UIUC	78,14	77,66	73,39	81,80	81,10	83,00	80,38	78,18	71,40	80,08	81,48	81,92
CURet	97,14	97,64	96,83	88,31	94,00	97,20	96,25	–	91,23	97,80	98,61	98,82

Tablo 5.4. Geliştirilen yöntemler ile bilinen diğer yöntemlerin öznitelik boyutları ve öznitelik çıkarım süreleri

	LBP	ELBP	BSIF	LEP	NRLBP ^{riu2}	MSJLBP	PRICoLBP	ELGS	DRLBP	S1LBP	S2LBP	S4LBP
Öznitelik çıkarım süresi (ms)	3,4	3,5	55,6	1088,9	356,9	854,6	380,4	-	17,2	4,7	9	18,5
Öznitelik boyutu	256	256	1024	520	50	3540	3540	256	44	256	512	1024

Tablo 5.1. ve Tablo 5.2.'deki deneysel sonuçlar incelendiğinde aşağıdaki yargılar çıkarılabilmektedir:

- 8 komşuluk kullanımı yerine 16 komşuluk kullanımı arasında çoğu öznitelik çıkarım yönteminde tanıma oranları açısından gözle görülür bir fark yaratmadığı tespit edilmiştir.
- CURet doku veritabanının, UIUC doku veritabanına göre daha kolay bir veritabanı olması sebebiyle tanıma oranları daha yüksek çıkmıştır.
- Öznitelik yöntemlerinin tekdüze versiyonları kullanıldığında tanıma oranları daha düşük çıkmıştır.
- Spiral topolojide, spiral sayısı arttıkça merkez piksel etrafındaki etkin komşu sayısı artmış ve dolayısıyla tanıma oranları artmıştır.
- En iyi tanıma oranına UIUC doku veritabanında S4ULBP, 16 komşuluk ve 30 adet görüntüden oluşan eğitim setiyle, CURet doku veritabanına S4LBP, 16 komşuluk 46 adet görüntüden oluşan eğitim setiyle ulaşılmıştır.
- En düşük tanıma oranına UIUC doku veritabanında tekdüze ELBP (EULBP), 8 komşuluk ve 10 adet görüntüden oluşan eğitim setiyle, CURet doku veritabanına ELBP, 16 komşuluk 12 adet görüntüden oluşan eğitim setiyle ulaşılmıştır.
- Eğitimde kullanılan imge sayısı arttıkça tanıma oranları her iki veritabanında da artmıştır.
- Spiral topoloji kullanımı diğer eliptik ve dairesel topoloji kullanımlarına göre daha etkili olmuştur.

Öznitelik çıkarım süreleri ve öznitelik boyutu açısından deneysel sonuçlar analiz edildiğinde aşağıdaki yargılara ulaşılabilir:

- Öznitelik çıkarım süresi açısından değerlendirildiğinde LBP yönteminin diğer yöntemlere oranla çok daha iyi olduğu gözlemlenmiştir.
- ELBP, DRLBP, BSIF, S1LBP, S2LBP ve S4LBP yöntemlerinin performansı ile LBP yönteminin performansı öznitelik çıkarım süresi açısından göz ardı edilebilir bir farka sahiptir.
- LEP ve MSJLBP öznitelik çıkarımında en çok süre harcayan öznitelik çıkarım yöntemleridir. Bu yöntemleri PRICoLBP ve NRLBP^{riu2} yöntemleri izlemektedir.
- MSJLBP ve PRICoLBP yöntemleri ile diğer yöntemler kıyaslandığında öznitelik vektörü boyutlarının çok yüksek olduğu gözlemlenmektedir.

Ayrıca son olarak, geliştirdiğimiz spiral tabanlı LBP yöntemleri diğer yöntemler ile karşılaştırıldığında CUREt doku veritabanında diğer tüm öznitelik çıkarım yöntemlerinden daha iyi tanıma oranlarına ulaştığı, UIUC doku veritabanında ise MSJLBP hariç çoğu öznitelik çıkarım yöntemleri ile kıyaslandığında başarı oranlarının daha yüksek olduğu görülmektedir.

5.1.4. Doku tanımda kenar bilgilerinin kullanımı

Bu bölümde, S1LBP, S2LBP ve S4LBP ile görüntünün kenar bilgilerinin kullanıldığı yeni bir öznitelik çıkarım yöntemi tanıtılmıştır.

Bir görüntünün kenarları, görüntünün içeriği ile ilgili çok önemli bilgiler taşımaktadır. Bu bilgiler, ayırt edici bir öznitelik olarak kullanılabilir. Bu çalışmada, spiral topoloji kullanan LBP kodları ile görüntünün kenarlarına uygulanan SLBP varyantları birleştirilerek daha ayırıcı bir öznitelik vektörü üretilmesi amaçlanmıştır.

S1LBP_EI (S1LBP with edge information) yönteminde, ilk olarak orijinal görüntüye S1LBP uygulanarak bir histogram elde edilir. Bir sonraki adımda, görüntünün kenar haritası, Canny kenar bulma yöntemi uygulanarak çıkarılır. Canny kenar bulma yöntemi ilk olarak 1986'da F. Canny tarafından geliştirilmiştir . Temel olarak 4 adımdan oluşmaktadır:

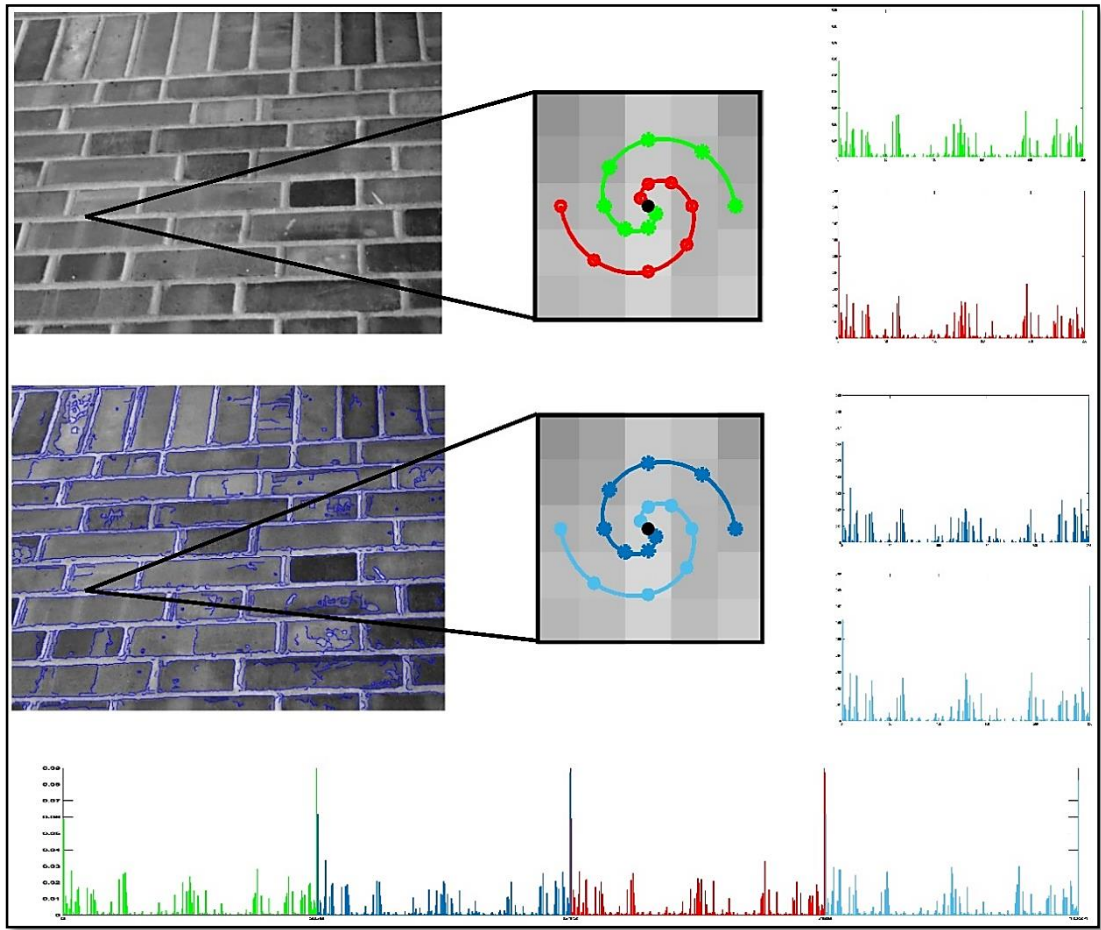
- Gürültü azaltma: Görüntünün gürültüsü Gaussian filtre kullanılarak azaltılmaktadır. Gaussian filtrenin yanı sıra yumuşatma filtrelerinden, Mean ya da Medyan filtre de uygulanabilmektedir.
- Görüntünün gradyanını hesaplama: Türevsel kerneller kullanılarak, yatay ve dikey türevler, görüntünün Gradyan yönünü elde etmek için türetilmektedir. En çok kullanılan türevsel kernellerden biri Sobel filtresidir.
- Non-Maximum baskılama: Görüntüdeki en keskin yoğunluk değeri değişikliklerini bulmak için, Non-Maximum baskılama, yerel maksimum değerleri dışındaki tüm gradyan değerlerine uygulanır.
- İkili eşikleme: Bu adımda, asıl kenarlar asıl olmayanlardan ayrılmaktadır. Bu işlem ikili eşikleme uygulanarak ve blob analizleri ile kenarların bağlanabilirliği kontrol edilerek yapılmaktadır (Canny, 1986).

Geliştirilen yöntemin bir sonraki aşaması, kenar haritası elde edilen görüntünün kenara denk gelen pikselleri üzerinden S1LBP uygulanmasıdır. Bu işlem sonucunda da bir histogram daha elde edilmektedir. Böylelikle bir görüntüye ait toplamda iki histogram üretilmektedir. Son adımda ise, orijinal doku görüntüsü üzerindeki tüm pikseller üzerinden S1LBP uygulanarak elde edilen histogram ile görüntünün kenarlarına denk gelen pikseller üzerinden S1LBP ile elde edilen histogram normalize edilerek art arda birleştirilmektedir. Sonuç olarak görüntünün öznitelik vektörü elde edilmektedir.

Geliştirilen bu yaklaşım, daha ayırıcı bir öznelik vektörü elde edebilmek amacıyla S2LBP ve S4LBP yöntemi ile genişletilmiştir. Temel olarak, çoklu spiral kullanılan LBP topolojisinde her bir spiral için S1LBP uygulanmaktadır. Daha sonra elde edilen her bir histogram birleştirilerek görüntünün öznelik vektörü üretilmektedir. Kenar bilgileri ile elde edilen histogramlar da dahil edildiğinde S2LBP için öznelik vektörünün boyutu 1024, S4LBP için ise 2048 olmaktadır.

Şekil 5.9.'da kenar bilgileri ile S2LBP yönteminin birlikte kullanımına (S2LBP_EI, S2LBP with edge information) bir örnek gösterilmektedir. Örnekte, orijinal görüntü üzerinde seçilen bir merkez piksele uygulanan S2LBP topolojisi, kırmızı ve yeşil renkli spiraller ile temsil edilmektedir. Kenar haritası çıkarılmış görüntüdeki, kenara denk gelen bir merkez piksele uygulanan S2LBP topolojisi, açık mavi ve koyu mavi renkle gösterilmektedir. Öncelikle merkez piksel, yeşil spiral üzerindeki komşuları ile karşılaştırılarak LBP kodu oluşturulur. Daha sonra kırmızı spiral üzerindeki komşular arasındaki fark ile LBP kodu hesaplanır. Görüntü üzerindeki kenar bilgileri Canny kenar bulma yöntemi ile çıkarılır. Eğer, ilgili merkez piksel kenara denk gelir ise yeşil ve kırmızı spiraller için oluşturulan LBP kodları kopyalanır. Böylelikle S2LBP yöntemi ile elde edilen dört adet etikete sahip olur. Fakat merkez pikselin, kenara denk gelmediği durumlarda sadece S2LBP kodu hesaplanır ve dolayısıyla merkez piksel iki etikete sahip olur. Sonuç olarak, görüntü üzerindeki tüm piksellere ve görüntünün kenarları üzerindeki piksellere S2LBP uygulanarak dört adet histogram hesaplanır. Daha sonra bu histogramlar art arda birleştirilerek nihai öznelik vektörü elde edilir.

S4LBP_EI (S4LBP with edge information) yöntemi ile öznelik elde etme prosedürü S2LBP_EI ile aynı şekildedir. Orijinal görüntü üzerindeki her piksel için S4LBP uygulanır ve bu işlem sonucunda dört adet histogram hesaplanır. Daha sonra görüntünün kenar haritası çıkarılarak, kenarlar üzerindeki S4LBP hesaplanır. Böylelikle dört histogram daha elde edilir. Dolayısıyla son öznelik vektörünün boyutu 2048 olmaktadır.



Şekil 5.9. S2LBP ile kenar bilgilerinin birlikte kullanımı

Geliştirilen yöntemlerin performanslarını ölçmek amacıyla UIUC ve CUREt doku veritabanları kullanılmıştır. Ayrıca LBP, S1LBP, S2LBP ve S4LBP yöntemleri ile karşılaştırılmıştır. Tüm LBP ve varyantlarında komşu sayısı sekize sabitlenmiştir. Sınıflandırıcı olarak χ^2 ve LRC yöntemleri seçilmiştir. Eğitim kümesi, UIUC doku veritabanından sırasıyla 30, 20, 15, 10 adet doku görüntüsü rasgele seçilerek oluşturulmuştur. CUREt doku veritabanında ise sırasıyla 46, 23 ve 12 adet doku görüntüsü rasgele seçilmiştir. Geriye kalanlar ise test için kullanılmıştır. Tanıma oranları, 10 kez sınıflandırma sonucu elde edilen doğruluk oranlarının ortalaması alınarak hesaplanmıştır. Tablo 5.5. ve Tablo 5.6.'da sırasıyla UIUC ve CUREt doku veritabanı için χ^2 yöntemi ile tanıma oranları verilmiştir. Tablo 5.7. ve Tablo 5.8.'de ise sırasıyla UIUC ve CUREt doku veritabanları için LRC yöntemi ile tanıma oranları gösterilmektedir.

Tablo 5.5. UIUC doku veritabanında χ^2 ile elde edilen doğruluk oranları

Yöntem	30	20	15	10
LBP	64,60 ± 2,61	58,72 ± 1,77	53,66 ± 1,69	47,86 ± 1,88
LBP_EI	65,72 ± 2,66	62,02 ± 1,75	58,53 ± 1,71	52,82 ± 1,20
S1LBP	63,84 ± 2,87	57,04 ± 1,94	52,19 ± 1,67	46,46 ± 1,18
S1LBP_EI	66,06 ± 2,58	63,68 ± 1,92	58,70 ± 1,64	52,24 ± 1,73
S2LBP	64,44 ± 2,76	57,46 ± 2,04	52,49 ± 1,84	46,73 ± 1,21
S2LBP_EI	66,12 ± 2,84	63,05 ± 2,11	58,71 ± 1,72	53,65 ± 1,97
S4LBP	63,84 ± 2,77	57,02 ± 1,96	52,32 ± 1,85	46,69 ± 1,38
S4LBP_EI	67,01 ± 2,45	63,56 ± 1,82	58,72 ± 1,79	53,67 ± 2,03

Tablo 5.6. CURet doku veritabanında χ^2 ile elde edilen doğruluk oranları

Yöntem	46	23	12
LBP	91,09 ± 0,43	85,28 ± 0,51	77,83 ± 0,54
LBP_EI	92,86 ± 0,20	85,97 ± 0,45	78,91 ± 0,60
SLBP	91,73 ± 0,36	86,20 ± 0,42	78,61 ± 0,64
SLBP_EI	93,61 ± 0,63	87,02 ± 0,51	79,08 ± 0,41
S2LBP	92,11 ± 0,32	86,66 ± 0,43	78,98 ± 0,64
S2LBP_EI	94,80 ± 0,89	87,98 ± 0,48	81,54 ± 0,56
S4LBP	92,33 ± 0,38	87,03 ± 0,42	79,45 ± 0,59
S4LBP_EI	96,34 ± 0,58	89,59 ± 0,46	82,17 ± 0,99

Tablo 5.7. UIUC doku veritabanında LRC ile elde edilen doğruluk oranları

Yöntem	30	20	15	10
LBP	85,60 ± 2,01	78,14 ± 2,36	72,59 ± 2,42	61,94 ± 2,06
LBP_EI	88,80 ± 2,30	81,42 ± 1,84	76,22 ± 2,88	65,84 ± 2,46
SLBP	85,92 ± 1,76	80,08 ± 2,20	74,48 ± 2,24	64,01 ± 1,77
SLBP_EI	89,08 ± 1,33	83,44 ± 1,90	78,62 ± 2,02	68,25 ± 1,85
S2LBP	87,28 ± 2,56	81,48 ± 1,96	75,47 ± 1,89	64,44 ± 1,89
S2LBP_EI	88,85 ± 1,92	82,90 ± 2,07	78,69 ± 2,16	68,96 ± 1,98
S4LBP	88,04 ± 1,88	81,92 ± 2,39	75,72 ± 2,19	64,61 ± 2,08
S4LBP_EI	89,84 ± 1,65	83,50 ± 1,67	78,80 ± 1,79	69,08 ± 2,20

Tablo 5.8. CUREt doku veritabanında LRC ile elde edilen doğruluk oranları

Yöntem	46	23	12
LBP	97,14 ± 0,36	95,26 ± 0,52	89,52 ± 0,92
LBP_EI	97,76 ± 0,24	95,31 ± 0,38	89,11 ± 0,69
SLBP	97,80 ± 0,17	95,98 ± 0,36	90,54 ± 0,93
SLBP_EI	97,92 ± 0,24	95,58 ± 0,31	89,71 ± 0,65
S2LBP	98,61 ± 0,13	96,68 ± 0,49	91,14 ± 0,88
S2LBP_EI	98,72 ± 0,56	96,84 ± 0,47	91,40 ± 0,72
S4LBP	98,82 ± 0,17	96,83 ± 0,40	91,32 ± 0,86
S4LBP_EI	99,24 ± 0,70	97,59 ± 0,42	91,97 ± 0,88

Her iki veritabanından da elde edilen deneysel sonuçlara göre;

- LRC yöntemi ile χ^2 karşılaştırıldığında, LRC'nin sınıflandırma başarısının daha yüksek olduğu,
- S4LBP'nin, diğer LBP topolojilerine göre görüntüyü daha iyi tanımladığı,
- Kenar bilgilerinin entegre edilmesi ile doğruluk oranlarının arttığı gözlemlenmektedir.

5.2. Yüz Tanıma Uygulamaları

Bu bölümde dairesel topoloji kullanan LBP ve spiral topoloji kullanan LBP türlerinin yüz tanımadaki başarısını incelenmiştir. Yöntemlerin performansını ölçmek amacıyla ORL ve AR yüz veritabanları kullanılmıştır.

AR veritabanı, 126 kişiden oluşur ve her bir kişinin 26 adet, farklı ışıklandırmalarda, farklı yüz ifadelerine sahip, güneş gözlüğü, atkı gibi materyaller ile kapalı yüz görüntüleri bulunmaktadır (Martinez ve Benavente, 1998). Her bir görüntünün orijinal boyutu 768 × 576'dır. Yapılan çalışmada, Çevikalp ve ark. çalışmalarında kullandığı AR veritabanının altkümüsi kullanılmıştır (2005). Yapılan önışleme adımlarından

sonra bir görüntünün boyutu 115×87 olmuştur. Bu altküme, 30 erkek ve 20 kadının yüz görüntülerinden oluşmaktadır. Şekil 5.10.'da her sınıfa ait bir görüntü gösterilmektedir. Yapılan deneysel çalışmalarda, bir sınıftaki yüzün güneş gözlüğü ve kaşkol ile kapatılmamış 14 yüz görüntüsü kullanılmıştır.



Şekil 5.10. AR yüz veritabanının deneylerde kullanılan altkümesindeki sınıflardan rastgele seçilen örnekler

ORL yüz veritabanı; Nisan 1992 ve Nisan 1994 arasında Cambridge Üniversitesi bilgisayar laboratuvarında alınan yüz görüntülerinden oluşmaktadır (<http://www.uk.research.att.com/facedatabase.html>). Veritabanında, toplamda 40 sınıf ve her sınıfa ait 10 adet görüntü bulunmaktadır. Yüz görüntüleri; farklı zamanlarda, farklı yüz ifadeleri (gözün açık / kapalı olma durumu, gülümseme / gülümsememe) ve yüz detayları (gözlüklü / gözlüksüz) ile farklı ışıklandırmalarda alınmıştır. Tüm görüntüler, koyu homojen arka plana sahiptir. Ayrıca dik (bazı yan hareketler tolere edilmiştir) ve ön pozisyondan çekilmiştir. Her görüntünün çözünürlüğü 112×92 'dir. Şekil 5.11.'de ORL yüz veritabanındaki her sınıftan birer örnek gösterilmiştir.



Şekil 5.11. ORL yüz veritabanındaki sınıflardan seçilen örnekler

Yöntemde öncelikli olarak, yüz görüntüleri Şekil 5.12.'de resmedildiği gibi, 2×2 , 3×3 , 4×4 , 5×5 veya 7×7 parçalara ayrılır. Daha sonra, ayrılan her bir alt parçaya ayrı ayrı LBP veya S1LBP uygulanarak her bir parçanın histogramı hesaplanır. Dolayısıyla görüntünün bölündüğü parça sayısı kadar histogram elde edilir. Son adımda ise elde edilen tüm histogramlar art arda birleştirilerek, öznitelik vektörü oluşturulur. Örneğin; görüntü 3×3 bölgelere ayrıldığında toplamda dokuz adet alt imge oluşmaktadır. İlk parçanın bütün pikselleri üzerinde spiral ya da dairesel topoloji kullanan LBP uygulanır. Referans piksellerin komşu sayıları sekiz olarak alındığında, ilk parçanın histogram boyutu 256 olmaktadır. Diğer sekiz parça için de aynı işlemler tekrar edilir. Sonuç olarak 9 adet 256 boyutlu histogramlar elde edilir. Nihai öznitelik vektörünü oluşturabilmek için tüm histogramlar art arda birleştirilir. Bu işlem sonucunda 3×3 bölgelere ayrılan bir görüntünün öznitelik vektör boyutu 2304'e ulaşmaktadır.



Şekil 5.12. Yüz görüntüsünün alt imgelere bölünmesi

Sınıflandırıcı olarak LRC ve histogramların benzerliğini ölçen χ^2 testi kullanılmıştır. Eğitim aşamasında, AR ve ORL yüz veritabanları için sırasıyla 7 ve 5 görüntü rastgele seçilmiştir. Geri kalanlar ise test için kullanılmıştır. Sınıflandırma oranları, 10 kez çalıştırma sonucu ortalama alınarak hesaplanmıştır. Tablo 5.9.'da ORL ve Tablo 5.10.'da AR yüz veritabanı için tanıma oranları karşılaştırmalı olarak verilmiştir. En iyi doğruluk oranları kalın ve altı çizili olarak gösterilmiştir.

Tablo 5.9. ORL yüz veritabanı için tanıma oranları (%)

Alt - İmge	LRC		χ^2	
	LBP	S1LBP	LBP	S1LBP
2 × 2	% 96,15	% 96,50	% 93,74	% 95,62
3 × 3	<u>% 97,90</u>	% 97,65	% 95,96	% 96,35
4 × 4	% 97,85	% 97,35	% 96,08	<u>% 97,11</u>
5 × 5	% 95,80	% 95,40	% 92,67	% 92,90
7 × 7	% 95,25	% 94,65	% 94,12	% 94,89

Tablo 5.10. AR yüz veritabanı için tanıma oranları (%)

Alt - İmge	LRC		χ^2	
	LBP	S1LBP	LBP	S1LBP
2 × 2	% 89,91	% 91,34	% 78,65	% 79,54
3 × 3	% 93,31	% 94,57	% 84,74	% 85,17
4 × 4	% 95,15	% 96,57	% 91,74	% 92,08
5 × 5	% 95,40	% 96,68	% 94,40	% 94,74
7 × 7	% 96,45	<u>% 97,37</u>	% 96,01	<u>% 96,02</u>

Yapılan deneylerle, 3 sonuca ulaşılabilir:

- LRC, S1LBP öznitelikleri ile yüz tanımda, χ^2 yönteminden daha iyi bir sınıflandırıcıdır.
- S1LBP, yüz tanımda LBP'ye göre daha iyi bir tanımlayıcıdır.
- AR yüz veritabanında, görüntü parça sayısı arttığında tanıma başarımı da artmıştır.

5.3. Öznitelik Seçimi

Bu bölümde; geliştirdiğimiz spiral topoloji tabanlı öznitelik çıkarım yöntemlerinden elde edilen histogram boyutlarını azaltmak amacıyla önerilen öznitelik seçim algoritması anlatılacaktır. Öznitelik seçim algoritmasının uygulanması ile öznitelik boyutunun düşürülür ve bu işlem sonunda hem büyük boyutlu öznitelikler içerisinde bulunan gereksiz bilgilerden kurtulmak, hem de çalışma süresi açısından avantaj sağlamak amaçlanmaktadır.

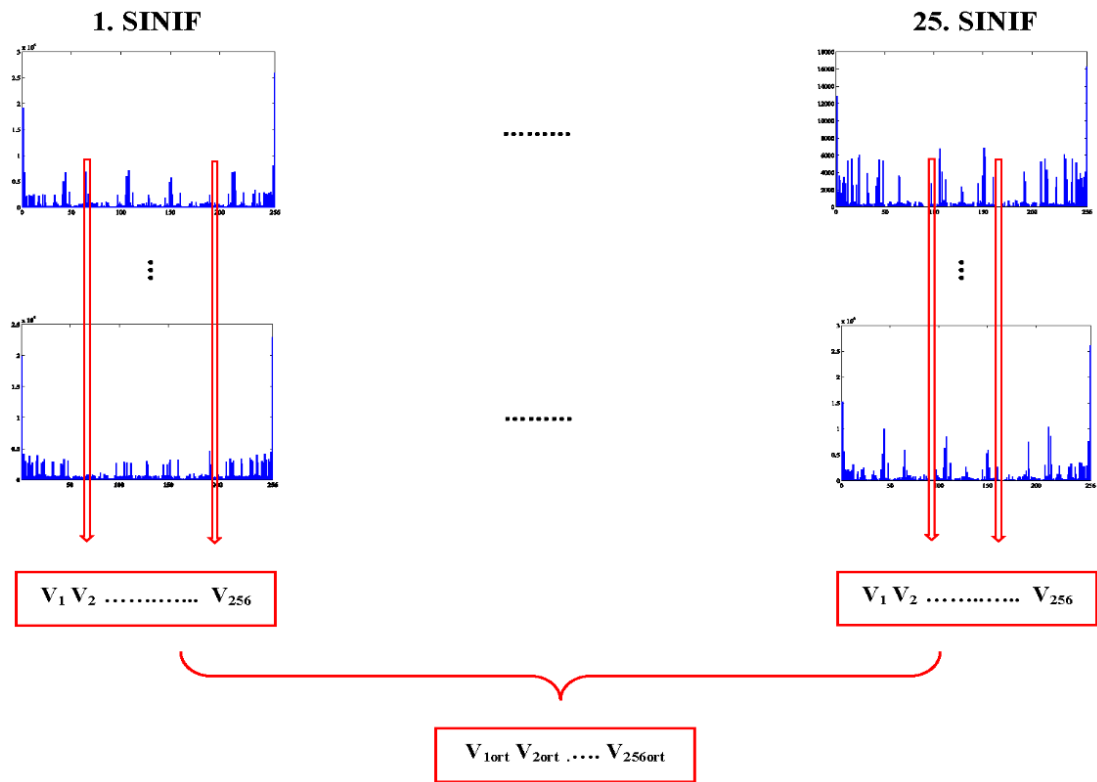
Tez çalışması kapsamında spiral topoloji tabanlı LBP yöntemleri geliştirilmiştir. Dairesel topoloji yerine 1 spiral, 2 spiral ve 4 spiralli topoloji uygulanmıştır. Kullanılan her topolojide eklenen spiraller tanıma oranını artırmakla birlikte öznitelik boyutunu da artırmıştır. Örneğin, 8 komşuluğa sahip 4 spiralli yapıda öznitelik boyutu $2^8 \cdot 4 = 1024$ ' e kadar ulaşmıştır. Geliştirilen yöntemlerin değinilen dezavantajları göz önüne alındığında öznitelik boyutunun azaltılması gerektiği düşünülmüştür. Bu sebeple, varyansa bağlı öznitelik seçim algoritması tasarlanmıştır.

Seçilen herhangi LBP yöntemi için aşağıdaki üç adımlı algoritma aşağıdaki gibidir.

- Her sınıftaki eğitimde kullanılan histogramların bütün binleri için varyansları hesapla,

- Varyansların ortalamalarını küçükten büyüğe sırala,
- Varyansları küçük olan binleri histogramdan çıkar.


Öznitelik seçiminde öncelikle, eğitim ve test veri kümelerindeki her bir görüntüye LBP yöntemlerinden biri seçilerek uygulanır. Böylelikle her bir görüntünün öznitelik vektörü elde edilir. Sınıf içerisindeki eğitim öznitelik vektörlerinin her bir boyutu için sırasıyla varyans hesaplanır. Bu işlem her sınıf için ayrı ayrı tekrarlanır. Bir sonraki adımda, tüm sınıflardan elde edilen varyans vektörlerinin ortalaması alınarak tek bir matrise ulaşılır. Şekil 5.13.'de bu işleme bir örnek gösterilmiştir.



Şekil 5.13. Sınıflar arası varyansların hesaplanması


Öznitelik vektörünün bir boyutunun sınıflar arası varyansının büyük olması, farklı sınıfların bu boyutta birbirinden uzak değerler aldığı bir göstergesidir. O halde bu boyut sınıfları birbirinden ayırmak için önemli bilgiler içerebilir ve öznitelik olarak seçilebilir. Bu sebeple hesaplanan varyanslar küçükten büyüğe sıralanır. Şekil 5.14.'de 8 komşuluklu S4LBP öznitelik vektörü için hesaplanan ve küçükten büyüğe

sıralanan varyansların grafiği verilmiştir. Algoritmanın son adımında ise, küçük değere sahip olan boyutlar belirlenerek histogramdan çıkarılır ve algoritma tamamlanır.




Şekil 5.14. 8 komşuluklu S4LBP için hesaplanan varyansların sıralanması

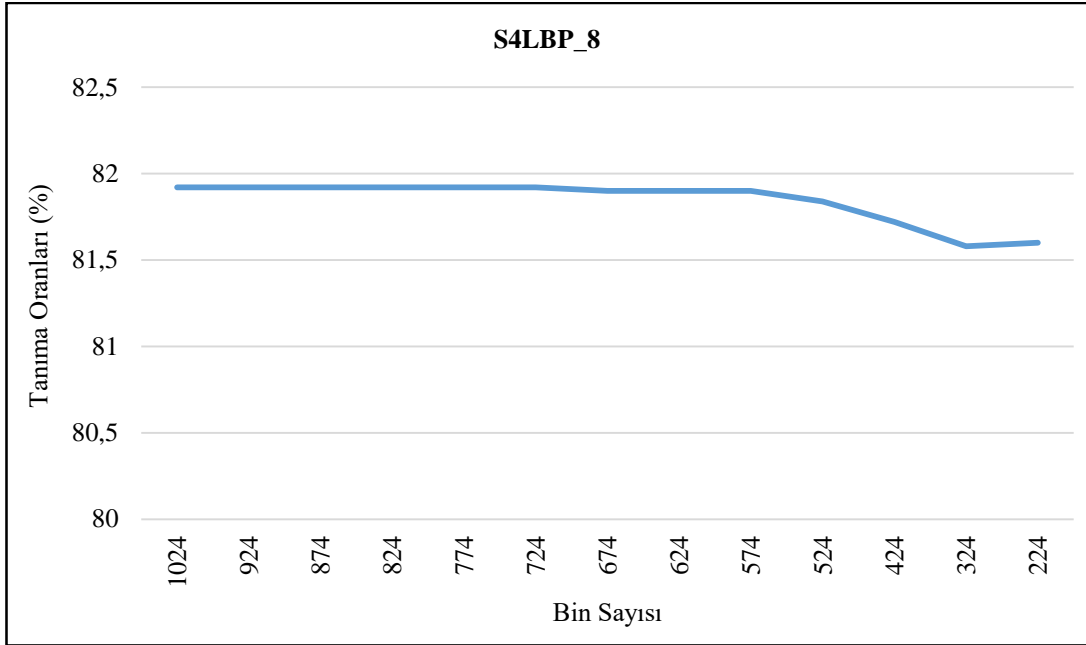
Geliştirilen öznitelik seçimi algoritması UIUC ve CURet doku veritabanları üzerinde test edilmiştir. Öznitelik çıkarım algoritması olarak 8 ve 16 komşuluk kullanan S2LBP ve S4LBP yöntemleri seçilmiştir. Tablo 5.11.'de öznitelik seçim algoritmasının UIUC veritabanı üzerindeki doğruluk oranları verilmiştir. Tabloda S2LBP_8 ve S4LBP_8, 8 komşuluğa sahip S2LBP ve S4LBP'yi, S2LBP_16 ve S4LBP_16 ise 16 komşuluğa sahip S2LBP ve S4LBP yöntemlerini temsil etmektedir. Tablo incelendiğinde histogramlar içerisinde çıkarılan bin sayısı arttıkça doğruluk oranlarında önemli bir değişim olmadığı gözlemlenmiştir. UIUC doku veritabanında S2LBP üzerindeki değişimler Şekil 5.15. ve Şekil 5.16.'da, S4LBP üzerindeki değişimler Şekil 5.17. ve Şekil 5.18.'de grafiksel olarak gösterilmiştir.




Şekil 5.15. UIUC veritabanında 8 komşuluklu S2LBP (S2LBP_8) üzerindeki tanuma oranları değişimi



Şekil 5.16. UIUC veritabanında 16 komşuluklu S2LBP (S2LBP_16) üzerindeki tanuma oranları değişimi



Şekil 5.17. UIUC veritabanında 8 komşuluklu S4LBP (S4LBP_8) üzerindeki tanıma oranları değişimi




Şekil 5.18. UIUC veritabanında 16 komşuluklu S4LBP (S4LBP_16) üzerindeki tanıma oranları değişimi

Tablo 5.11. Öznitelik seçim algoritmasının UIUC veritabanı üzerindeki tanıma oranları

S2LBP_8			S2LBP_16			S4LBP_8			S4LBP_16		
Çıkarılan boyut sayısı	Boyut azaltma (%)	Tanıma oranı (%)	Çıkarılan boyut sayısı	Boyut azaltma (%)	Tanıma oranı (%)	Çıkarılan boyut sayısı	Boyut azaltma (%)	Tanıma oranı (%)	Çıkarılan boyut sayısı	Boyut azaltma (%)	Tanıma oranı (%)
0	0	81,48	0	0	80,86	0	0	81,92	0	0	81,16
20	4	81,48	1000	0,76	80,86	100	10	81,92	10000	4	81,16
50	10	81,48	5000	4	80,86	150	15	81,92	25000	10	81,16
80	14	81,48	7500	6	80,84	200	20	81,92	50000	19	81,16
100	19	81,46	10000	8	80,86	250	24	81,92	75000	29	81,12
120	23	81,48	25000	19	80,86	300	29	81,92	100000	38	81,16
150	29	81,42	50000	38	80,86	350	34	81,90	125000	48	81,16
170	33	81,48	75000	57	80,86	400	39	81,90	150000	57	81,14
200	39	81,44	100000	76	80,86	450	44	81,90	175000	67	81,14
250	49	81,50	105000	80	80,86	500	49	81,84	200000	76	81,16
260	51	81,50	110000	84	80,86	600	59	81,72	225000	86	81,16
300	58	81,32	120000	92	80,88	700	68	81,58	250000	95	81,16
350	68	81	130000	99	80,76	800	78	81,60	260000	99	81,10

CURet doku veritabanında S2LBP üzerindeki öznitelik boyutuna bağlı olarak tanıma oranlarının değişimi Şekil 5.19.'da görülmektedir.



Şekil 5.19. CURet veritabanında 8 komşuluklu S2LBP (S2LBP_8) üzerindeki tanıma oranları değişimi

Öznitelik seçimi algoritmasının uygulanması ile elde edilen deneysel sonuçlara dayanarak aşağıdaki yargılara ulaşılabılır:

- 8 komşuluk kullanan S2LBP yönteminin öznitelik boyutu orijinalde 512 iken, yaklaşık %49'luk bir oranla öznitelik boyutu azaltıldığında, doğruluk oranı %81,48'den %81,5'a çıkmıştır. Tanıma oranları arasındaki bu artış miktarı göz ardı edilebilir. Fakat boyut yaklaşık %68 azaltıldığında, tanıma oranı sadece 0,48 düşerek %81'e düşmüştür.
- S2LBP_16 yönteminde öznitelik boyutu orijinalde 131072 iken doğruluk oranı %80,86'dır. Öznitelik seçimi yöntemi ile boyut yaklaşık %92 azaltıldığında doğruluk oranı %0,02 artışla %80,88'e çıkmıştır. Ayrıca öznitelik boyutu %99 gibi önemli bir oranla azaltıldığında, tanıma oranı %0,1 düşüşle %80,76 olmuştur.

- S4LBP_8'de orijinal öznitelik boyutu 1024 iken doğruluk oranı %81,92, öznitelik boyutu %29 düşürüldüğünde doğruluk oranı değişmeyerek %81,92'de kalmıştır ve %78 azaltıldığında tanıma oranı %3 düşüşle %81,60 olmuştur.
- S4LBP_16 yönteminde ise orijinal öznitelik 262144 gibi çok yüksek boyutlarda iken, öznitelik boyutu %95 azaltıldığında doğruluk oranı sabit kalarak %81,16, %99 azaltıldığında ise sadece %0,06 düşerek %81,10 olmuştur.
- Öznitelik seçimi algoritmasının öznitelik boyutunu azaltmasının yanı sıra doğruluk oranlarındaki tüm bu değişimler göz ardı edilebilir boyutta olması, önerilen algoritmanın doku tanıma problemine uygun olduğunu göstermektedir.

BÖLÜM 6. SONUÇ VE ÖNERİLER

Bu tez çalışması kapsamında, özellikle doku tanıma problemlerinde başarılı bir şekilde kullanılan Yerel İkili Örüntüler (Local Binary Pattern - LBP) yöntemi temel alınarak yeni öznelik çıkarım yöntemleri geliştirilmiştir. Geliştirilen öznelik çıkarım yöntemlerinden elde edilen özneliklerin boyutunu azaltmak amacıyla yeni bir öznelik seçim algoritması önerilmiştir. Ayrıca, geliştirilen öznelik çıkarım yöntemleri ile görüntünün kenar bilgileri birleştirilerek yeni bir öznelik çıkarım yöntemi sunulmuştur.

Tezde ayrıca alt-uzay tabanlı sınıflandırma yöntemlerinin literatürde yoğun bir şekilde kullanılan istatistiksel tabanlı testlere karşı başarımı, doku tanıma problemlerinde incelenmiştir. Yapılan testlerde alt-uzay tabanlı sınıflandırıcılardan SVM, LDA ve LRC, istatistiksel testlerden ise G-test ve Ki-Kare testi kullanılmıştır. Deneysel çalışmalar LRC yönteminin doku tanımada daha başarılı olduğunu göstermektedir.

LBP'de pikseller arasındaki gri-seviye değişimi hesaplarında uygulanan dairesel topoloji yerine Arşimet spirali kullanılarak öznelikler oluşturulmuş ve çift spiralli LBP (S2LBP) geliştirilmiştir. S2LBP'nin tanıma oranlarında artış sağladığı gözlemlendiğinden, yapı, dört spiral topolojiye (S4LBP) genişletilmiştir. Tanıma problemlerinde öznelik çıkarım yöntemleri, görüntüyü en iyi temsil eden özneliklerin üretilmesi açısından önemli bir yere sahiptir. Bu sebeple, geliştirilen yöntemler UIUC ve CURet doku veritabanları üzerinde test edilmiştir. Ayrıca bilinen öznelik çıkarım yöntemleri ile karşılaştırılarak, uygulanan topolojiler ile daha ayırt edici bir özneliğe ulaşıp ulaşılmadığı analiz edilmiştir. Geliştirilen yöntemlerin tanıma problemlerindeki başarımı öznelik boyutu, hesapsal yük ve tanıma oranları açısından ele alınmıştır. Yapılan deneysel çalışmalar sonucunda yöntemlerin, tanıma

oranlarında diğer yöntemlere göre daha başarılı, öznelik boyutu ve hesapsal yükte çoğu öznelik çıkarım yöntemlerine göre daha iyi olduğu gözlemlenmiştir.

Ayrıca, geliştirilen yöntemler yüz tanıma problemlerinde sıkça kullanılan AR ve ORL yüz veritabanları üzerinde test edilmiştir. Yüz görüntüleri alt görüntülere bölünerek her bir parçaya önerilen öznelik çıkarım yöntemleri uygulanmıştır. Elde edilen öznelikler art arda eklenerek nihai histogram elde edilmiştir. Deneysel çalışmalar yorumlandığında geliştirilen yöntemlerin yüz tanıma oranlarında daha başarılı olduğu söylenebilmektedir.

Topolojide konumlandırılan komşu noktaların sayısındaki artış ile öznelik boyutu katlanarak artmaktadır. Geliştirilen öznelik çıkarım yöntemleri ile elde edilen öznelik boyutlarının çok yüksek olması önemsiz bilgilerin artmasına yol açmıştır. Bu durumdan yola çıkarak öznelik boyutunu azaltmak amacıyla yeni bir öznelik seçim algoritması tasarlanmıştır. Yöntemde sınıflar arası varyansı maksimum tutmak hedeflenmiştir. Önerilen öznelik seçimi yöntemi bilinen doku veritabanlarında test edilmiştir. Deneysel sonuçlar incelendiğinde; öznelik seçimi algoritmasının öznelik boyutunu önemli derece azaltmasının yanı sıra doğruluk oranlarındaki küçük değişimlerin göz ardı edilebilir boyutta olması, önerilen algoritmanın doku tanıma problemine uygun olduğunu göstermiştir.

Bir görüntünün kenar bilgileri görüntüyü tanımlayabilecek yüksek ayırt edici özelliklere sahiptir. Bu sebeple kenar bilgilerinin özneliklere entegre edilmesiyle ayıricılığın artacağı düşünülmüştür. Yapılan tez kapsamında, önerilen spiral topolojiler ile elde edilen özneliklere ek olarak doku görüntüleri üzerinde yer alan kenar bilgileri kullanılmıştır. Önerilen öznelik çıkarım yöntemi farklı sınıflandırma yöntemleriyle doku tanıma sıklıkla kullanılan veritabanları üzerinde test edilmiştir. Yapılan deneysel çalışmalar sonucunda kenar bilgilerinin entegre edilmesi ile doğruluk oranlarının arttığı gözlemlenmiştir.

Öznelik çıkarımı yönteminde, referans alınan bir piksel ile etrafındaki komşu noktaların hangi düzende konumlandırılacağı konusu haricinde, aralarındaki gri-

seviye deęişimlerinin nasıl kodlanacağı konusu da ayrı bir çalışma alanıdır. Gelecek çalışmalarda, LBP kodu ikili sayılardan farklı bir kod ile üretilebilir. Dönmeden, ölçekten veya ışıklandırma deęişimlerinden bağımsız yeni bir öznitelik çıkarım yöntemi üzerinde çalışılabilir. Ayrıca LBP ile uyumlu ve tamamlayıcı öznitelikler geliştirilerek yeni bir hibrit yöntem önerilebilir. Geliştirilen yöntemler doku tanıma ve yüz tanıma problemlerinden başka bir çalışma alanında uygulanabilir.

Ayrıca gelecek çalışmalarda, öznitelik seçimi algoritmasında, sınıflar arası saçılımı maksimum tutma prensibi ile birlikte sınıf içi deęişimleri en aza indirgeyecek bir iyileştirme yapılabilir.

KAYNAKLAR

- Ahonen, T., Hadid, A., Matti, P. 2006. Face description with local binary patterns. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 28(12): 2037-2041.
- Alaei, F., Alaei, A., Pal, U., Blumenstein, M. 2016. Document image retrieval based on texture features: a recognition-free approach. 2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA), Gold Coast, QLD, Australia, 1-7.
- Anwer, R. M., Khan, F. S., van de Weijer, J., Molinier, M., Laaksonen, J. 2018. Binary patterns encoded convolutional neural networks for texture recognition and remote sensing scene classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 138: 74-85.
- Bashier, H.K., Hoe, L.S., Hui, L.T., Azli, M.F., Han, Y., Kwee, W.K., Sayeed, M. S. 2016. Texture classification via extended local graph structure. *Opt.—Int. J. Light Electron Opt.*, 127: 638–643.
- Canny, J. 1986. A computational approach to edge detection. *IEEE Trans. Pattern Anal. Machine Intell.*, PAMI-8: 679-698.
- Chakraborty, S., Singh, S. K., Chakraborty, P. 2018. Local gradient hexa pattern: a descriptor for face recognition and retrieval. *IEEE Transactions on Circuits and Systems for Video Technology*, 28(1): 171-180.
- Cortes, C., Vapnik, V. 1995. Support-vector networks. *Mach. Learn.*, 20(3): 273-297.
- Çevikalp, H., Neamtu, M., Wilkes, M., Barkana, A. 2005. Discriminative common vectors for face recognition. *IEEE Trans. on PAMI*, 27(1): 4-13.
- Dana, K. J., Van-Ginneken, B., Nayar, S. K., Koenderink, J. J. 1999. Reflectance and texture of real world surfaces. *ACM Transactions on Graphics (TOG)*, 18(1): 1-34.
- Dubey, S. R., Singh, S., Singh R. K. 2016. Local bit-plane decoded pattern: a novel feature descriptor for biomedical image retrieval. *IEEE Journal of Biomedical and Health Informatics*, 20(4): 1139-1147.
- Fan, K., Hung, T. 2014. A novel local pattern descriptor - local vector pattern in high-order derivative space for face recognition. *IEEE Transactions on Image Processing*, 23(7): 2877-2891.

- Fletcher, T. 2009. Support vector machines explained: introductory course. Internal Report, University College London, UCL, London.
- Guo, Z., Zhang, L., Zhang, D. 2010. A completed modeling of local binary pattern operator for texture classification. *IEEE Trans. Image Processing*, 19(6): 1657-1663.
- Guo, Z., Zhang, L., Zhang, D., Mou, X. 2010. Hierarchical multiscale lbp for face and palmprint recognition. *IEEE 17th International Conference on Image Processing*, Hong Kong, 4521-4524.
- Guo, Z., Zhang, L., Zhang, D., Zhang, S. 2010. Rotation invariant texture classification using adaptive lbp with directional statistical features. *IEEE 17th International Conference on Image Processing*, Hong Kong, 285-288.
- Gupta, N., Pillai, G. V., Ari, S. 2018. Change detection in optical satellite images based on local binary similarity pattern technique. *IEEE Geoscience and Remote Sensing Letters*, 15(3): 389-393.
- Huang, S. M., Yang, J. F. 2013. Linear discriminant regression classification for face recognition. *IEEE Signal Processing Letters*, 20(1): 91-94.
- Huang, W., Yin, H. 2017. Robust face recognition with structural binary gradient patterns. *Pattern Recognition*, 68: 126-140.
- Huang, X., Zhao, G., Zheng, W., Pietikäinen, M. 2012. Spatiotemporal local monogenic binary patterns for facial expression recognition. *IEEE Signal Processing Letters*, 19(5): 243-246.
- Jeong, K., Choi, J., Jang, G. 2015. Semi-local structure patterns for robust face detection. *IEEE Signal Processing Letters*, 22(9): 1400-1403.
- Jia, S., Hu, J., Zhu, J., Jia, X., Li, Q. 2017. Three-dimensional local binary patterns for hyperspectral imagery classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(4): 2399-2413.
- Kabbai, L., Abdellaoui, M., Douik, A. 2017. Hybrid local and global descriptor enhanced with colour information. *IET Image Processing*, 11(2): 109-117.
- Kannala, J., Rahtu, E. 2012. Bsif: binarized statistical image features. *International Conference on Pattern Recognition (ICPR)*, Tsukuba, Japan, 1363-1366.
- Kazak, N., Koc, M., Benligiray, B., Topal, C. 2016. A comparison of classification methods for local binary patterns. *24th Signal Processing and Communication Application Conference (SIU)*, Zonguldak, Türkiye, 805-808.
- Kazak, N., Koc, M. 2018. Some variants of spiral LBP in texture recognition. *IET Image Processing*, 12(8): 1388-1393.

- Kazak, N., Koc, M. 2019. Improved multi-spiral local binary pattern in texture recognition. *Advances in Intelligent Systems and Computing III*, Springer, 871: 28-37.
- Kır, B., Kurt, M., Urhan, O. 2015. Local binary pattern based fast digital image stabilization. *IEEE Signal Processing Letters*, 22(3): 341-345.
- Koc, M., Barkana, A. 2014. Application of linear regression classification to low dimensional datasets. *Neurocomputing*, 131: 331-335.
- Lazebnik, S., Schmid, C., Ponce, J. 2005. A sparse texture representation using local affine regions. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 27(1): 1265-1278.
- Li, W., Chen, C., Su, H., Du, Q. 2015. Local binary patterns and extreme learning machine for hyperspectral imagery classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7): 3681-3693.
- Liao, S., Chung, A. 2007. Face recognition by using elongated local binary patterns with average maximum distance gradient magnitude. *Computer Vision – ACCV 2007. Lecture Notes in Computer Science*, 4844: 672-679.
- Liao, S., Law, M., Chung, A. 2009. Dominant local binary patterns for texture classification. *IEEE Transactions on Image Processing*, 18 (5): 1107-1118.
- Liu, L., Fieguth, P., Guo, Y., Wang, X., Pietikainen, M. 2017. Local binary features for texture classification: Taxonomy and experimental study. *Pattern Recognition*, 62: 135-160.
- Liu, L., Lao, S., Fieguth, P. W., Guo, Y., Wang, X., Pietikäinen M. 2016. Median robust extended local binary pattern for texture classification. *IEEE Transactions on Image Processing*, 25(3): 1368-1381.
- Liu, Y.Y., Chen, M., Ishikawa, H., Wollstein, G., Schuman, J. S., Rehg, J. M. 2011. Automated macular pathology diagnosis in retinal oct images using multi-scale spatial pyramid and local binary patterns in texture and shape encoding. *Medical Image Analysis*, 15(5): 748-759.
- Maenpaa, T. 2003. The local binary pattern approach to texture analysis-extensions and applications. Infotech Oulu and Department of Electrical and Information Engineering, University of Oulu, PhD thesis.
- Martinez, A.M., Benavente, R. 1998. The AR face database. CVC Technical Report #24.
- Matrinez, A.M., Kak, A.C. 2001. PCA versus LDA. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(2), 228-233.
- Mehta, R., Egiazarian, K. 2016. Dominant rotated local binary patterns (DRLBP) for texture classification. *Pattern Recogn. Lett.*, 71(1): 16-22.

- Menp, T. Ojala, T., Pietikinen, M., Soriano, M. 2000. Robust texture classification by subsets of local binary patterns. Proc. 15th Int'l Conf. Pattern Recognition, 3: 947-950.
- Morales, S., Engan, K., Naranjo, V., Colomer, A. 2017. Retinal Disease Screening Through Local Binary Patterns. IEEE Journal of Biomedical and Health Informatics, 21(1): 184-192.
- Murala, S., Wu, Q. M. 2014. Local mesh patterns versus local binary patterns: biomedical image indexing and retrieval. IEEE Journal of Biomedical and Health Informatics, 18(3): 929-938.
- Nanni, L., Lumini, A., Brahnam, S. 2010. Local binary patterns variants as texture descriptors for medical image analysis. Artificial Intelligence in Medicine, 49: 117-125.
- Naresh, Y. G., Nagendraswamy, H. S. 2016. Classification of medicinal plants: An approach using modified LBP with symbolic representation. Neurocomputing, 173(3): 1789-1797.
- Naseem, I., Togneri, R., Bennamoun, M. 2010. Linear regression for face recognition. IEEE Trans. Pattern Analysis and Machine Intelligence, 32(11): 2106-2112.
- Ojala, T., Pietikainen, M., Harwood, D. 1996. A comparative study of texture measures with classification based on feature distributions. Pattern Recognition, 29 (1), 51-59.
- Ojala, T., Pietikainen, M., Maenpaa, T. 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Trans. Pattern Analysis and Machine Intelligence, 24(7): 971-987.
- Qi, X., Qiao, Y., Li, C., Guo, J.J. 2013. Multiscale joint encoding of local binary patterns for texture and material classification. Proceedings of British Machine Vision Conference (BMVC), 1-11.
- Qi, X., Xiao, R., Li, C., Qiao, Y., Guo, J., Tang, X. 2014. Pairwise rotation invariant cooccurrence local binary pattern. IEEE Trans. Pattern Anal. Mach. Intell., 36(11): 2199-2213.
- Pietikainen, M., Hadid, A., Zhao, G., Ahonen, T. 2011. Computer vision using local binary patterns. USA, NY, New York: Springer-Verlag, 40.
- Raju, J., Durai, C. 2013. A survey on texture classification techniques. International Conference on Information Communication and Embedded Systems (ICICES), Chennai, India, 180-184.
- Ren, J., Jiang, X., Yuan, J. 2013. Noise-resistant local binary pattern with an embedded error-correction mechanism. IEEE Trans. Image Process., 22(10): 4049-4060.

- Satpathy, A., Jiang, X., Eng, H. 2014. Lbp based edge texture features for object recognition. *IEEE Transactions on Image Processing*, 23(5): 1953-1964.
- Schaefer, G., Doshi, N. P. 2012. Multi-dimensional local binary pattern descriptors for improved texture analysis. *21st International Conference on Pattern Recognition (ICPR 2012)*, Tsukuba, Japan, 2500-2503.
- Shan, C., Gong, S., McOwan, P. W. 2009. Facial expression recognition based on local binary patterns: A comprehensive study. *Image and Vision Computing*, 27: 803-816
- Tan, X., Triggs, B. 2010. Enhanced local texture feature sets for face recognition under difficult lighting conditions. *IEEE Trans. Image Processing*, 19(6): 1635-1650.
- The ORL Face Database, <http://www.uk.research.att.com/facedatabase.html>., Erişim Tarihi: 15.09.2017.
- Thompson, E. M., Biasotti, S. 2018. Description and retrieval of geometric patterns on surface meshes using an edge-based LBP approach. *Pattern Recognition*, 82: 1-15.
- Varma, M., Ray, D. 2007. Learning the discriminative power-invariance trade-off. *IEEE 11th International Conference on Computer Vision*, Rio de Janeiro, Brazil, 1-8.
- Varma, M., Zisserman, A. 2005. A statistical approach to texture classification from single images. *International Journal of Computer Vision*, 62(1-2): 61-81.
- Wan, S., Lee, H.C., Huang, X., Xu, T., Xu, T., Zeng, X., Zhang, Z., Sheikine, Y., Connolly, J. L., Fujimoto, J. G., Zhou, C. 2017. Integrated local binary pattern texture features for classification of breast tissue imaged by optical coherence microscopy. *Medical Image Analysis*, 38: 104-116.
- Zhang, B., Gao, Y., Zhao, S., Liu, J. 2010. Local derivative pattern versus local binary pattern: face recognition with high-order local pattern descriptor. *IEEE Trans. Image Processing*, 19(2): 533-544.
- Zhang, J., Liang, J., Zhao, H. 2013. Local energy pattern for texture classification using self-adaptive quantization thresholds. *IEEE Trans. Image Process.*, 22(1): 31-42.
- Zhao, Y., Jia, W., Hu, R.-X., Min, H. 2013. Completed robust local binary pattern for texture classification. *Neurocomputing*, 106: 68-76.

ÖZGEÇMİŞ

Nihan Kazak Çerçevik, 17.07.1987'de Denizli'de doğdu. İlk, orta ve lise eğitimini Denizli'de tamamladı. 2005 yılında Denizli Anadolu Lisesi'nden mezun oldu. 2005 yılında başladığı Abant İzzet Baysal Üniversitesi Bilgisayar Öğretmenliği Bölümü'nü 2009 yılında bitirdi. Aynı yıl, Bilecik Şeyh Edebali Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine kabul edildi ve Bilecik Şeyh Edebali Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaya başladı. 2011 yılında yüksek lisans eğitimi tamamlayarak, Sakarya Üniversitesi Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Halen Bilecik Şeyh Edebali Üniversitesi'nde Araştırma Görevlisi olarak görev yapmaktadır.