

T.C.
SIIRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÜZÜM TÜRÜNÜN TESPİTİ İÇİN ÇOK KATMANLI YEREL İKİLİ
ÖRÜNTÜLER

YÜKSEK LİSANS TEZİ
BURHAN ÖZDEMİR
(163111004)

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

TEZ DANIŞMANI: DR. ÖĞRETİM ÜYESİ YILMAZ KAYA

MART-2018
SIIRT

TEZ KABUL VE ONAYI

Burhan ÖZDEMİR tarafından hazırlanan “Üzüm Türünün Tespiti İçin Çok Katmanlı Yerel İkili Örüntüler” adlı tez çalışması 20/03/2018 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Dr. Öğretim Üyesi Ramazan Tekin

Danışman

Dr. Öğretim Üyesi Yılmaz Kaya

Üye

Dr. Öğretim Üyesi Mehmet Recep MİNAZ

İmza



Yukarıdaki sonucu onaylarım.

Doç. Dr. Fevzi HANSU
Fen Bilimleri Enstitüsü Müdürü



ÖN SÖZ

Bu tez çalışması esnasında sürekli yol gösteren ve yardımlarını esirgemeyen danışman hocam Dr. Yılmaz Kaya'ya ve Murat Akdemir'e teşekkürlerimi sunarım.

Burhan ÖZDEMİR
SİİRT-2018



İÇİNDEKİLER

Sayfa

ÖN SÖZ	iii
İÇİNDEKİLER	iv
TABLolar LİSTESİ	v
ŞEKİLLER LİSTESİ	vi
KISALTMALAR VE SİMGELER LİSTESİ.....	vii
ÖZET	viii
ABSTRACT.....	ix
1. GİRİŞ	1
2. LİTERATÜR BİLDİRİŞLERİ	7
2.1. Tohum ile İlgili Çalışmalar	7
2.2. LBP ile ilgili Çalışmalar	10
3. MATERYAL VE METOT	19
3.1. Materyal	19
3.2. Metot	20
3.2.1. Yerel İkili Örüntüler.....	20
3.3. RGB Renk Katmanlı LBP'ler	22
3.4. Sınıflandırma.....	25
3.5. Performans Ölçütleri	25
3.5.1. Doğruluk (Accuracy)	26
3.5.2. Hata Oranı (Error rate).....	26
3.5.3. Kesinlik(Precision).....	26
3.5.4. Hatırlama (Recall).....	26
3.5.5. Duyarlılık (Sensitivity)	26
3.5.6. F-measure (F).....	27
3.6. Çalışma Diyagramı.....	27
4. SONUÇLAR	29
4.1. LBP ve LBP _{RGB} Sonuçları	29
4.2. Uniform LBP ve Uniform LBP _{RGB} Sonuçları	42
4.3. Yöntemlerin Karşılaştırılması	52
5. TARTIŞMA	55
6. KAYNAKLAR	59
ÖZGEÇMİŞ	63

TABLolar LİSTESİ

Sayfa

Tablo 3. 1. Üzüm türleri ve kodları.....	20
Tablo 3. 2. Performans ölçütleri.....	25
Tablo 4. 1. LBP _{RR} özelliklerin YSA ile başarı oranları	33
Tablo 4. 2. LBP _{RR} özelliklerin YSA ile performans sonuçları	33
Tablo 4. 3. LBP _{RG} özelliklerin YSA ile başarı oranları	34
Tablo 4. 4. LBP _{RG} özelliklerin YSA ile performans sonuçlar	34
Tablo 4. 5. LBP _{RB} özelliklerin LMT ile başarı oranları.....	35
Tablo 4. 6. LBP _{RB} özelliklerin LMT ile performans sonuçlar	35
Tablo 4. 7. LBP _{GR} özelliklerin YSA ile başarı oranları	36
Tablo 4. 8. LBP _{GR} özelliklerin YSA ile performans sonuçlar	36
Tablo 4. 9. LBP _{GG} özelliklerin YSA ile başarı oranları.....	37
Tablo 4. 10. LBP _{GG} özelliklerin YSA ile performans sonuçlar	37
Tablo 4. 11. LBP _{GB} özelliklerin LMT ile başarı oranları.....	38
Tablo 4. 12. LBP _{GB} özelliklerin LMT ile performans sonuçlar	38
Tablo 4. 13. LBP _{BR} özelliklerin LMT ile başarı oranları.....	39
Tablo 4. 14. LBP _{BR} özelliklerin LMT ile performans sonuçlar	39
Tablo 4. 15. LBP _{BG} özelliklerin LMT ile başarı oranları.....	40
Tablo 4. 16. LBP _{BG} özelliklerin LMT ile performans sonuçlar	40
Tablo 4. 17. LBP _{BB} özelliklerin YSA ile başarı oranları	41
Tablo 4. 18. LBP _{BB} özelliklerin YSA ile performans sonuçlar.....	41
Tablo 4. 19. LBP özelliklerin YSA ile başarı oranları.....	42
Tablo 4. 20. LBP özelliklerin YSA ile performans sonuçlar	42
Tablo 4. 21. LBP _{RR} ^{U2} özelliklerin YSA ile başarı oranları.....	43
Tablo 4. 22. LBP _{RR} ^{U2} özelliklerin YSA ile performans sonuçları.....	43
Tablo 4. 23. LBP _{RG} ^{U2} özelliklerin YSA ile başarı oranları	44
Tablo 4. 24. LBP _{RG} ^{U2} özelliklerin YSA ile performans sonuçları.....	44
Tablo 4. 25. LBP _{RB} ^{U2} özelliklerin LMT ile başarı oranları	45
Tablo 4. 26. LBP _{RB} ^{U2} özelliklerin LMT ile performans sonuçları	45
Tablo 4. 27. LBP _{GR} ^{U2} özelliklerin YSA ile başarı oranları	46
Tablo 4. 28. LBP _{GR} ^{U2} özelliklerin YSA ile performans sonuçları.....	46
Tablo 4. 29. LBP _{GG} ^{U2} özelliklerin YSA ile başarı oranları	47
Tablo 4. 30. LBP _{GG} ^{U2} özelliklerin YSA ile performans sonuçları.....	47
Tablo 4. 31. LBP _{GB} ^{U2} özelliklerin LMT ile başarı oranları	48
Tablo 4. 32. LBP _{GB} ^{U2} özelliklerin LMT ile performans sonuçları	48
Tablo 4. 33. LBP _{BR} ^{U2} özelliklerin LMT ile başarı oranları	49
Tablo 4. 34. LBP _{BR} ^{U2} özelliklerin LMT ile performans sonuçları	49
Tablo 4. 35. LBP _{BG} ^{U2} özelliklerin LMT ile başarı oranları	50
Tablo 4. 36. LBP _{BG} ^{U2} özelliklerin LMT ile performans sonuçları	50
Tablo 4. 37. LBP _{BB} ^{U2} özelliklerin YSA ile başarı oranları	50
Tablo 4. 38. LBP _{BB} ^{U2} özelliklerin YSA ile performans sonuçları.....	51
Tablo 4. 39. LBP ^{U2} özelliklerin YSA ile başarı oranları.....	52
Tablo 4. 40. LBP ^{U2} özelliklerin YSA ile performans sonuçları.....	52
Tablo 4. 41. Yöntemlerin Karşılaştırılması.....	53

ŞEKİLLER LİSTESİ

Sayfa

Şekil 3. 1. Çalışmada kullanılan üzüm türlerine ait görüntüler	19
Şekil 3. 2. LBP dairesel komşu şeması.....	21
Şekil 3. 3. Bir piksel için LBP değerin elde edilmesi.....	21
Şekil 3. 4. Farklı P ve R parametrelerine göre LBP tanımlayıcıları.....	22
Şekil 3. 5. R-G kanalları için LBP_{RGB}	23
Şekil 3. 6. G-B kanalları için $YİÖ_{RGB}$	24
Şekil 3. 7. B-R kanalları için LBP_{RGB}	24
Şekil 3. 8. Çalışma Diyagramı.....	27
Şekil 4. 1. Üzüm Çekirdeği	29
Şekil 4. 2. RGB kanallar ve kombinasyonlar için elde edilen LBP görüntüler.....	30
Şekil 4. 3. LBP görüntü ve Histogramları. (1) LBP_{RR} , (2) LBP_{RG} , (3) LBP_{RB} , (4) LBP_{GR} , (5) LBP_{GG} görüntü ve histogramlar.....	31
Şekil 4. 4. LBP görüntü ve histogramlar. (6) LBP_{GB} , (7) LBP_{BR} , (8) LBP_{BG} , (9) LBP_{BB} , (10) LBP_{Klasik} görüntü ve histogramlar	32

KISALTMALAR VE SİMGELER LİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
CoLBP	: Compass Local Binary Battern
DLBP	: Dominant Local Binary Pattern
FLBP	: Feature Local Binary Pattern
GLCM	: Grey Level Co-occurrence Matrix
GSP	: Generalized Softmax Perceptron
HSI	: Hyperspectral Imaging
IPGRI	: International Plant Genetic Resources Institute
KDV	: Karar Destek Vektörleri
LBP	: Local Binary Pattern
LDA	: Linear Discriminant Analysis
LMT	: Logistic Model Tree
LR	: Lojistik Regresyon
LSP	: Local Similarity Patterns
LSSVM	: Least Squares Support Vector Machine
MBP	: Median Binary Pattern
OIV	: Office International de la Vigne et du Vin
PPMS	: Posterior Probability Model Selection
YİÖ	: Yerel İkili Örüntü

ÖZET

YÜKSEK LİSANS TEZİ

Üzüm Türünün Tespiti İçin Çok Katmanlı Yerel İkili Örüntüler

Burhan ÖZDEMİR

**Siirt Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğretim Üyesi Yılmaz Kaya

2018, 63 Sayfa

Çok fazla sayıda çeşide sahip üzüm bütün dünyada yetiştirilen en önemli tarımsal ürünler arasında yer almaktadır. Gözlem yapılarak üzüm türlerinin sınıflandırılması çok güçlü bir botanik bilgisi gerektirmektedir. Bu durum çoğu zaman botanik bilimcileri için bile çok zor bir alan olmuştur. Ayrıca alanında uzman botanikçilerin sayısındaki azalma bitki türlerinin tanımlanması için görüntü işleme ve ilişkilerin tanımlanmasına dayalı teknikler gibi farklı yöntemlerin kullanımını zorunlu hale getirmiştir. Ayrıca kamera sistemlerinin ve diğer portatif cihazların geliştirilmesi gibi konuyla ilgili farklı alanlardaki gelişmeler bu düşüncenin uygulanabilirliğini artırmıştır. Üzümlerin tanımlanması ve çeşitlerin doğru olarak belirlenmesi sistematik açıdan önem arz etmektedir. Bu çalışmada, üzüm türlerinin tespiti için klasik teşhis yöntemlerine alternatif olarak bilgisayar görü tabanlı bir yöntem önerilmiştir. Üzüm türlerinin sınıflandırılması için karakteristik özelliklere sahip üzüm çekirdek görüntüleri kullanılmıştır. Çalışmada renkli çekirdek görüntülerinden etkili özellikler çıkarmak için yerel ikili örüntüler (Local Binary Pattern=LBP) tabanlı yeni bir yaklaşım önerilmiştir. Önerilen yöntemde renkli görüntüler için kullanılmaktadır. Üzüm türlerin tespiti iki aşamada gerçekleştirilmiştir. Birinci aşamada öznitelikler elde edilmiş, ikinci aşamada ise bu öznitelikler farklı makine öğrenmesi yöntemleri kullanılarak 10-katlı çapraz geçerlilik testi ile sınıflandırma işlemi gerçekleştirilmiştir. Çalışma sonunda sınıflandırma başarısı %82,10 olarak bulunmuştur.

Anahtar Kelimeler: Yerel İkili Örüntüler, Görüntü İşleme, Üzüm Türü Tahmini, Örüntü Tanıma

ABSTRACT

MS THESIS

**MULTILAYER LOCAL BINARY PATTERNS FOR GRAPE TYPES
DETECTION**

BURHAN ÖZDEMİR

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE
OF SİİRT UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL-ELECTRONICS ENGINEERING**

SUPERVISOR: DR. INSTRUCTOR YILMAZ KAYA

2018, 63 Pages

Grapes with a large number of varieties are among the most important agricultural products grown all over the world. Observation and classification of grape species requires very robust botanical knowledge. This has often been a very difficult area for botanical scientists too. In addition, the reduction in the number of botanists has made it necessary to use different methods for identification of plant species, such as techniques based on image processing and identification of relationships. In addition, developments in different areas related to the subject, such as the development of camera systems and other portable devices, have increased the applicability of this idea. The identification of grapes and the correct identification of grape varieties are of systematic importance. In this study, a computer vision-based method was proposed as an alternative to classical diagnostic methods for the detection of grape varieties. Grape seed images with characteristic features were used for the classification of grape species. In the study, A new approach based on Local Binary Pattern (LBP) has been proposed to produce effective features from color kernel images. Recommended method is used for color images. The detection of grape varieties was carried out in two stages. Attributes were obtained in the first stage, and in the second stage, classification by 10-fold cross validity test was performed by using different machine learning methods through these attributes. At the end of the study, the classification success was obtained as 82,10%.

Keywords: Local Binary Pattern, Image processing, Pattern Recognition, Grape Type Forecast

1. GİRİŞ

Üzüm (*Vitis vinifera*) tüm dünyada yetiştirilen en önemli tarımsal ürünler arasında yer almaktadır. Dünya genelinde 7,5 milyon hektar (ha) alanda yetiştiriciliği yapılan üzüm toplamda 73,7 milyon tonluk bir üretime sahiptir (OIV 2015). Bu üretim miktarıyla yaklaşık olarak 25,6 milyar Euro kadar bir pazar hacmine sahiptir. Türkiye ise 4.175.356 tonluk üretim miktarıyla dünyada 6. sırada yer almaktadır (Anonim 2015).

Üzümün kültüre alınmasına yönelik ilk gelişmeler yakın doğuda ve 6000-8000 yıl öncesine dayanmaktadır. Daha sonra buradan farklı rotalarla Avrupa, Kuzey Afrika ve Doğu'daki ülkelere yayılmıştır. Çok sayıda ve farklı üzüm çeşitlerinden üzüm suyu üretimi ve şarap üretimi gibi farklı amaçlarla yararlanılırken, üzümün çekirdek ve kabuk kısmı ise fonksiyonel gıda bileşeni ve antioksidant eldesi için kullanılmaktadır (Li ve ark., 2008).

Çok fazla sayıda çeşide sahip olan üzümde sınıflandırmaya yönelik ilk çalışmalar 19. yy'da başlamıştır. Bir grup araştırmacı üzüm çeşitlerini aromatik olan ve olmayan şeklinde iki gruba ayırmaya çalışmışlardır. Ancak bazı aromatik olan ve olmayan çeşitlerin benzer isimlerle tanımlanması sonucu bu sınıflandırmadan istenilen sonuç alınamamıştır (Vialà ve ark., 1909). Son derece karışık bir genetik ve popülasyon yapısına sahip olan üzüm çeşitlerinde sınıflandırma süreci morfolojik karakterlere dayalı morfolojik yöntemlerle devam etmiştir. Morfolojik karakterlere dayalı karakterizasyon bitki türlerinin sınıflandırılmasında en çok başvurulan yöntemlerden biridir. Bu anlamda OIV (Office International de la Vigne et du Vin) ve IPGRI (International Plant Genetic Resources Institute) gibi uluslararası kuruluşlar ampelografik ve karşılaştırmalı çalışmalarda kullanılmak üzere bir dizi belirteç yayınlamıştır (OI).

Yirminci yüzyılın ikinci yarısında laboratuvar tekniklerinde meydana gelen ilerlemelerle birlikte, biyolojik anlamda önemli olan moleküllerin analiziyle türler arası ve tür içi genetik çeşitliliğin kategorize edilmesi ve sınıflandırılması mümkün olmuştur. Bu anlamda çeşitli yöntemler olmakla birlikte farklı organizmalara ait DNA sekanslarının kıyaslanması sonucu elde edilen sonuçların en güçlü ve en kullanışlı olduğu söylenebilir.

Klasik sınıflandırma ve tanımlama yöntemlerinde bitkilerin çeşitli karakteristikleri kullanılmaktadır. Bununla birlikte tür ayırımında hangi karakteristiğin daha tanımlayıcı olduğu gibi sorular hep sorula gelmiştir. Ayrıca gözlem yapılarak bitki

türlerinin sınıflandırılması çok güçlü bir botanik bilgisi gerektirmektedir. Bu durum çoğu zaman botanik bilimcileri için bile çok zor bir alan olmuştur. Ayrıca alanında uzman botanikçilerin sayısındaki azalma bitki türlerinin tanımlanması için görüntü işleme ve ilişkilerin tanımlanmasına dayalı teknikler gibi farklı yöntemlerin kullanımını zorunlu hale getirmiştir. Ayrıca kamera sistemlerinin ve diğer portatif cihazların geliştirilmesi gibi konuyla ilgili farklı alanlardaki gelişmeler bu düşüncenin uygulanabilirliğini artırmıştır.

Bu tez çalışmasında üzümlerin sınıflandırılması için klasik yöntemlere alternatif bilgisayar görü tabanlı bir yöntem önerilmiştir. Bu amaçla üzüm türlerinin çekirdek görüntüleri kullanıldı. Çalışmada üzüm çekirdek görüntülerini kullanan otomatik makine görme sistemi tasarlanmıştır. Bu sistem ile üzüm çekirdek görüntülerinden üzümün türü tespit edilmiş ve sınıflandırılmıştır. Çalışmada ilk olarak üzüm çekirdek görüntülerinden doku ve renk özellikleri elde edilmiştir. Elde edilen bu özellikler kullanılarak makine öğrenmesi yöntemleri ile sınıflandırma işlemi gerçekleştirilmiştir.

Doku görüntünün yüzeyine ait özelliklerdir (Kaya ve ark., 2013). Bilgisayar tabanlı doku analizi biyolojik görüntü üzerindeki dokuların matematiksel olarak ifade edilmesidir. Üzüm çekirdek görüntüleri için görüntüdeki dokular, türlere göre farklılık gösterebilir ve dokular görüntü hakkında bilgiye/detaya ulaşmamızı sağlayabilecek bilgiler içerebilir.

Doku bir görüntünün ilgili alanlarının veya bölgelerinin tanımlanmasında kullanılan benzer yapıların topluluğu şeklinde ifade edilir (Ala ve Forqui, 2011). Dokular nesnelerin, varlıkların boyut şekli, parlaklık, renk ve karakteristik gibi özelliklerini ifade eden desenlerdir. Görüntülerin dokusu, görüntü içindeki bir nesnenin parçalarının görünüşü, yapısı ve düzenini ifade eder (Castellano ve ark., 2004; Zang, 2017).

Bilgisayar görü sistemlerinde ve görüntü işlemede doku analizi önemli bir yer tutar. Doku analizinin tıbbi görüntü analizi, yüz tanıma, parmak izi tanıma, medikal sistemler, uzaktan algılama gibi uygulamalarda geniş bir kullanım alanı bulunmaktadır. Doku sınıflandırmanın uygulama aşamaları şunlardır (1) Görüntüyü sonraki aşamaya uygun hale getirmek için görüntü üzerinde dönüşüm, (2) görüntüyü bir özellik vektörüne dönüştürme diğer bir deyişle özellik çıkarımı, (3) çıkarılan özellikleri kullanarak görüntülerin ilgili sınıfa atama işlemi (Caputo ve ark., 2010; Nguyen ve ark., 2016). Genel olarak doku sınıflandırma gri tonlu görüntüler için gerçekleştirilmektedir. Renkli doku görüntüler gri renklere dönüştürüldükten sonra kullanılmaktadırlar. Bu

durumda renk bilgisinin kullanılmaması bilgi kaybına neden olabilir. Günümüzde renkli görüntülerde renk bilgisinin genel sınıflandırma performansına katkısının olduğuna dair çalışmalar mevcuttur (Drimbarean, 2001; Palm, 2004; Kandaswamy, 2011; Carnedas, 2017). Renkli dokuların sınıflandırılması son yıllarda önem kazanmıştır. Renkli dokulu görüntüler kameranın ışık, doku yüzeyi ve açı değerlerine bağlıdır. Görüntülerdeki renk bilgisi ışık değişimlerinden kaynaklanan değişimleri açıklamak için kullanılabilir. Görüntülerdeki renk ve doku bilgilerini analiz etme yaklaşımları, paralel ve bütünleşmiş yaklaşımlar olarak iki gruba ayrıştırılabilir (Carnedas, 2017). Paralel yaklaşımlar görüntünün renk özellikleri ile birlikte gri seviye doku özelliklerini birleştiren metotlardır. Bütünleşmiş (entegrative) metotlar her renk kanalındaki gri özelliklerin birleşimini kullanır. Genel doku sınıflandırma için yapılan çalışmalar ya direk gri seviye görüntü üzerinde ya da görüntüye ait her renk kanalından elde edilen gri seviye özellikleri üzerinde analiz ederler. Drimbarean ve ark. (2001) renk kullanımının gri seviye doku sınıflandırma performansını geliştirdiğini kanıtlamak için VisTex veri kümesindeki 16 görüntü üzerine deneyler gerçekleştirdiler. Yaptıkları çalışmada ayırık kosinüs dönüşümü (DCT), Gabor filtreleri ve Eş-oluşum matris yaklaşımı olmak üzere 3 adet doku özellik yöntemi ve beş renk uzayı (RGB, HSI, CIE-XYZ, CIE-LAB ve YIQ) ve bu renk uzayından elde edilen özellikler test edildi. En iyi renk uzayının YIQ renk uzayının bütünleştirici yaklaşımı olduğunu gösterdiler. Paschos (2001), renkli dokuların sınıflandırılması için (RGB, Lab ve HSV) renk uzaylarına ait Gabor filtrelerini kullandı. HSV'nin en iyisi olduğu ve bunu RGB'nin izlediği sonucuna varılmıştır. İyi bir metot, dokuları ayırt etmek için etkili özellikler sağlamasına ek olarak görüntüye karşı da sağlam olmalıdır.

Son yıllarda doku analizi için çeşitli yaklaşımlar önerilmiştir. Bu yaklaşımların çoğu yapısal, model temelli, istatistiksel (histogram, mutlak gradyan, çalışma uzunluğu matrisi, ortak oluşum matrisi, oto-regresif model, dalgacıklar) ve dönüşüm bazlı yöntemlere (Castellano ve ark. 2004; Maani ve ark., 2013; Zhu ve ark., 2015) dayanıyor.

Uygulamada en yaygın kullanılan yöntemler local binary pattern (LBP), Grey level co-occurrence matrix (GLCM), Gabor filreleri (Hadizadeh, 2015) ve Wavelet yöntemleridir. LBP, Ojala ve ark. (1996) tarafından önerilmiş doku sınıflandırma için kullanılan etkili en basit istatistiksel yaklaşımlardan biridir. Bir görüntünün veya görüntüdeki bir yerel yapının istatistiksel olarak yoğunluğunu belirtir. LBP, görüntüdeki

her pikseli, pikselin etrafında dairesel olarak oluşan komşu pikseller ile karşılaştırır (Pan ve ark., 2017).

LBP yaklaşımı, merkez pikselin ve komşularının yerel farklılıklarının merkezi pikselin kendisinden bağımsız olduğu varsayımına dayanmaktadır. Pikseller arasındaki ilişkiler ikili örüntüler ile ifade edilir. LBP'nin başlıca avantajları: (1) güçlü bir ayırt edici, (2) diğer yöntemlere göre daha hesaplama maliyeti daha az, (3) basit uygulanabilir olmasıdır.

Bu avantajlardan dolayı, LBP doku analizi (Ojala ve ark., 1996 ve 1999), yüz ve yüz ifadesi tanıma (Ahonen ve ark., 2006; Zhao ve Pietikainen, 2007; Zhou ve ark., 2013; Liu ve ark., 2013), çevre modelleme (Pietikäinen ve ark., 2004), biyomedikal görüntü işleme (Nanni ve ark., 2004), uzaktan algılama (Lucieer ve ark., 2005), parmak izi tanıma (Nanni ve Lumini, 2008), gerçek dış mekan sınıflandırma (García ve Puig, 2008), gıda sınıflandırma (Cernadas, 2005; Zheng, 2006) gibi sayısız uygulamalarda kullanılmaktadır.

LBP'nin bilgisayar gözü uygulamalarındaki başarısına rağmen geleneksel LBP'nin bazı dezavantajları da bulunmaktadır. (1) uzun dengesiz dağılmış histogramlar üretilmektedir. (2) görüntü dönmeye bağımlıdır, (3) gürültüye duyarlı ve büyük ölçekli dokuların algılanması zor olmaktadır. Bu durum etkili özelliklerin elde edilmesini zorlaştırmaktadır (Lian, 2015). Bu yüzden farklı geliştirilmiş çeşitli LBP yöntemler önerilmiştir.

Bu çalışmada renkli görüntüler için LBP tabanlı yeni bir yaklaşım önerilmiştir. Görüntülerin RGB kanallarının birbirleri ile karşılaştırmalarına dayanan renk katmanlı bir yaklaşım önerilmiştir. Önerilen yöntem LBP_{RGB} , klasik LBP yönteminin renkli görüntüler için düzenlenmiş halidir. Önerilen yöntem, RGB renk katmanlı LBP (LBP_{RGB}) yöntemi olarak isimlendirilmiştir. Klasik LBP yönteminde renkli görüntülerdeki renk kanallarındaki bilgiler kullanılamamaktadır. Bu kanallarda ayırt edici özellikleri olduğu düşünülmektedir. Bu yüzden bu çalışmada renkli görüntülere uygulanabilecek bir yöntem önerilmiştir. Önerilen yöntem renkli görüntülerin tüm kanallarında ayırt edici özellikleri taramaktadır. Oluşturulan bu yeni yaklaşım ile klasik yerel ikili örüntülerin kullanıldığı gri renklere ek olarak kırmızı, yeşil ve mavi renk kümelerinden yararlanılmıştır. Uygulanması, klasik yerel ikili örüntülerden farklılık göstermektedir. Bu yöntemde resmin renk kanallarından (R (red), G (green), B (blue)) öznitelikler çıkarılmaktadır. Her resim için R, G, B kanalları ayrı düşünüldüğünde bir resmin üç (3) farklı görüntüsü elimizde bulunmuş olacaktır. Bu yaklaşımda her piksel

kendi resmi içindeki komşular veya farklı resimdeki aynı yerdeki komşular ile karşılaştırılarak LBP özellikleri elde edilmektedir. Bu işlem sonucunda seçtiğimiz merkez pikseli, resmin farklı filtrelenmiş hallerindeki aynı konumdaki pikselleri ile kıyaslıyoruz ve kıyaslama sonucunda ikili örüntüler elde ediyoruz.

Tez çalışmasında kullanılan görüntüler Siirt ilinin farklı lokasyonlarından toplanılmış üzüm türlerinden elde edilmiştir. Araziden toplanan üzüm örnekleri laboratuvar ortamına getirilmiştir. Üzüm çekirdekleri pens yardımı ile çıkarılmış etil alkol (%70) ile temizlenerek kurutulmuştur. Üzüm çekirdek görüntüleri Olympus marka SZ 61 model mikroskop ve DP 20 model kamera ile elde edilmiştir. Bu çalışmada Aşkar, Bınetati, C Nator, Cevzane, Gadüv, Gozane Siyah, Hazirani, Heci Mendi, Heseni, Sinciri, Tayfi Siyah ve Tayfi üzüm türlerine ait toplamda 224 görüntü kullanılmıştır. Bu görüntülerden elde edilen özellikler ile en yüksek başarı oranı %82,10 olarak elde edilmiştir.



2. LİTERATÜR BİLDİRİŞLERİ

Üzüm yetiştiriciliği yapılan bütün ülkelerde çeşitlerin tanımlanması ve sınıflandırılmasında, değişik araştırmalarca farklı yöntemler kullanılmıştır. Yapılan çalışmalarda gerek örnek alma gerekse inceleme yöntemlerinin farklı olmasından dolayı bir çeşit değişik şekillerde tanımlanabilmekte, bu da karışıklığa yol açmaktadır. Bu karışıklığın giderilmesi ve çeşitlerin sağlıklı bir şekilde tanımlanabilmesi amacıyla, standart bir metodun bulunması konusunda çalışmalar yapılmıştır. Bu bölümde tohum sınıflandırma ve üzüm çekirdek görüntülerinden öznitelik vektörleri oluşturacak LBP yöntemi ile ilgili çalışmalar verilmiştir.

2.1. Tohum ile İlgili Çalışmalar

Alireza ve ark. (2012) tarafından yapılan bir çalışmada dokuz ortak İran buğday tohum çeşidinin tanımlanmasında faaliyetlerini değerlendirmek için tohum görüntülerinin çeşitli dokusal özellik grupları incelenmiştir. Genel olarak, sabit aydınlatma koşullarında (flüoresan halka ışığı) döküm buğday tohumlarının 1080 gri tonlamalı görüntüsü (her çeşit 120 görüntü) elde edilmiştir. LBP (yerel ikili desenler), LSP (yerel benzerlik kalıpları) ve LSN'den GLRM'den (gri seviyedeki çalışma uzunluğu matrisi) GLCM'den (gri seviyedeki eş oluşum matrisi) Matrislerden 131 dokusal özellikler çıkarılmıştır. LDA (doğrusal diskriminant analizi) sınıflandırma yöntemi sınıflandırıcısı, seçilen en iyi özellikleri kullanarak sınıflandırma için kullanılmıştır. Sınıflandırma yönteminde tüm seçilmiş özelliklerin en iyi 50 tanesi seçildiğinde, ortalama sınıflandırma doğruluğu %98,15 olarak elde edildiği raporlanmıştır.

Pablo M. Granitto ve ark. (2001) tarafından yapılan bir çalışmada ot tohumlarının sınıflandırılmasında Naive Bayes sınıflandırma metodunu kullanarak %92,4 ± 0,4 başarı elde etmişlerdir.

Juan Ignacio Arribas ve ark. (2011) tarafından yapılan çalışmada ise seçici herbisit uygulamalarında kullanılacak sinir ağlarını kullanan ayçiçeği mahsulleri için otomatik yaprak görüntüsü sınıflandırma sistemini kullanmıştır. Sistem dört ana aşamadan oluşmaktadır. İlk olarak, RGB renk alanına dayalı bir segmentasyon gerçekleştirilir. İkincisi, birçok farklı özellik tespit edilmiş ve daha sonra segmente edilmiş görüntüden özellikler çıkarılmıştır. Üçüncüsü, en ayırt edilebilir özellikler seçilmiştir. Son olarak, Genelleştirilmiş Softmax Perceptron (GSP) sinir ağı mimarisi, bir görüntüdeki yaprakları seçmek ve daha sonra bunların ayçiçeği olup olmadığını

sınıflandırmak amacıyla karmaşıklık seçimi için son zamanlarda önerilen Posterior Olasılık Model Seçimi (PPMS) algoritması ile birlikte kullanılmıştır. Deneysel sonuçlar, önerilen sistemin, test kümesi için ortalama doğru sınıflandırma oranı %85 doğruluk seviyesine ulaştığı verilmiştir.

H. K. Mebatsion ve ark. (2013) tarafından yapılan bir çalışmada tahıl tanelerinin sınıflandırılması, yani; arpa, yulaf, çavdar ve buğday (Kanada Batı Amber Durumu (CWAD) ve Kanada Batı Kızılağası (CWRS)) morfolojik ve renk özellikleri kullanılarak gerçekleştirildi. Çekirdek görüntüsü sınır çizgileri, zincir kodlu noktalar olarak ifade edilen çekirdeklerin dijital görüntülerinden çıkarıldı ve daha sonra 13 eliptik Fourier katsayılarıyla yaklaştırıldı. Konturların dönme ve başlangıç noktalarının normalleştirilmesinden sonra, simetrik standart katsayılar belirlendi. Ayrı çekirdeklerin simetrik Fourier indeksi, mutlak simetrik katsayıların toplamı ile dairesellik (yuvarlaklık) indeksinin çarpımından hesaplandı. Üç geometrik özellik; boy oranı, büyük çap ve yuvarlaklık sırasıyla elips ekleme ve Green integrali dönüşümü kullanılarak belirlendi. Morfolojik sınıflandırma modeli simetrik Fourier indeksi, boy oranı, büyük çap ve yuvarlaklık kullanılarak tanımlandı. Renk sınıflandırma modeli, resimlerinin RGB renk değerlerinden hesaplanan ayrı çekirdeklerin renk indekslerini kullanarak tanımlanmıştır. Morfolojik ve renk özellikleri ile tanımlanan kombine model, arpa için %98,5, CWRS için %99,97, yulaf için %99,93 ve çavdar ve CWAD için %100'lük bir sınıflandırma doğruluğuna ulaşmıştır.

Min Huang ve ark. (2016) tarafından yapılan çalışmada mısır tohumlarını sınıflandırma için hiperspektral görüntüleme kullanılmıştır. Farklı yıllara ait dört çeşit mısır tohumunu da içeren toplam 2000 tohum değerlendirildi. Hiperspektral yansıma görüntüleri 400 nm ve 1000 nm arasında elde edildi. Tohumların ortalama spektral özelliklerine dayanan sınıflandırma modelleri, en küçük kareler destek vektör makinesi (LSSVM) kullanılarak geliştirildi. Artımsal destek vektör verileri açıklaması kullanılarak model güncellemesi, LSSVM modelinin çevrimiçi olarak güncellenmesi ve farklı yılların mısır tohumlarının doğru bir şekilde tanımlanmasını sağlamak için de uygulanmıştır. Model güncelleme ile LSSVM modelinin sınıflandırma doğruluğu %94,4'e ulaştı ve güncellenmemiş diğer modellerinkinden %10,3 daha yüksekti.

Olgun ve ark. (2016) tarafından yapılan bir çalışmada yüksek hassasiyet oranı ile buğday tanelerini sınıflandırmaya muktedir bir otomatik sistem önerilmiştir. Ölçekten bağımsız elde ettikleri özellikleri karar destek vektörleri (KDV) sınıflandırma yöntemi

ile deęerlendirdiler. Özel bir veri kümesi üzerinde yaptıkları alıřmada %88,33'lük bir doęruluk oranı elde edildięi raporlanmıřtır.

Archana ve ark. (2016) tarafından yapılan bir alıřmada Yatay-Dikey ve Ön-Arka açılarını elde etmek için bir özellik ıkarım algoritması kullanarak eltik tohumlarının sınıflandırılması için yeni bir özellik ıkarım yöntemi önermişlerdir. Yöntem, sınıflandırma için açılı özelliklerinin füzyonunu kullanmışlar; bunlar daha sonra tohum rengi, řekli ve dokusu gibi özellikler ile karşılaştırıldı. Deneyler, önerilen özelliklerin bazı standart özelliklerle eltik tohumlarını sınıflandırmada daha iyi alıřtığını ve önerilen özelliklerin tohumlar için mükemmel bir ayırmacılık özellięine sahip olduğunu göstermektedir. Bu özelliklerin ayırdedici gücü, dört Paddy (pirin) tanesinin tohumlarının benzersiz tanımlanması için sinir aęı mimarileri kullanılarak deęerlendirilmiştir. Elde edilen Renk-řekil-Dokusunun sınıflandırma doęrulukları %95,2 iken önerilen yöntemin doęruluęu %97,6 idi.

Tzu-Yi Kuo ve ark. (2016) tarafından yapılan alıřmada görüntü işleme ve SRC sınıflandırma yöntemi kullanarak 30 eřit pirin tanesinin bozulmadan ayrıştırılması hedeflenmiştir. Deneylerde, pirin tanesi görüntüleri mikroskopi ile elde edildi. Tahılın gövdesi, kısır başlıkları ve fırçasının morfolojik, renk ve dokusal özellikleri kullanılmıştır. Ardından, nitelikleri girdi olarak kullanan tahıl eřitlerini tanımlamak için bir seyrek tabanlı sınıflandırmacı (SRC) geliştirildi. Önerilen yaklaşım, pirin tane eřitlerini %89,1 hassasiyetle ayırmıştır.

Dongsheng Guo ve ark. (2017) tarafından yapılan alıřmada hiperspektral görüntülemeye dayalı farklı yıllardan mısır tohum eřitlerini ayırmada en küçük kareler destek vektör makinesi kullanılmıştır.

Tohum řirketleri ve çiftiler için, tohumun canlılıęını test etmek ve herhangi bir kayıptan kaçınmak için hayati önem taşımaktadır. Bu bağlamda Ashabahebwa Ambrose ve ark. (2016) yaptıkları bir alıřmada yaşayan ve yaşamayan mısır tohumlarını ayırt etmek için hiperspektral görüntüleme (HSI) teknięini kullanma olasılıęını arařtırmayı amaçlamışlardır. Bir grup mısır örneęi mikrodalga işleme kullanılarak ısıl işleme tabi tutulurken, bir grup tohum kontrol grubu olarak tutuldu (muamele edilmedi). Her iki grubun mısır tohumlarının hiperspektral görüntüleri 400 ve 2500 nm dalga aralıęı boyunca yakalanmıştır. Kısmi en küçük kareler ayırt edici analiz (PLS-DA), yaşlanmış (ısıl işlem görmüş) ve normal (muamele edilmemiş) mısır tohumlarının sınıflandırılması için yapılmıştır. Model HSI SWIR bölgesinde %97,6 (kalibrasyon) ve %95,6 (tahmin)

en yüksek sınıflandırma doğruluğunu gösterdi. Dahası, PLS-DA ve ikili görüntüler, muamele edilmiş ve işlenmemiş mısır tohumlarının görsel bilgilerini sağlayabiliyordu.

Chtioui ve ark. (1996) tarafından yapılan bir çalışmada dört tohum çeşidinin tanımlanması için renkli görüntüler kullanılmışlar. Rumeks, yabani yulaf, lüferen ve fiğın tohum numunelerinden istatistiksel özellikler elde edildi. Tohumların boyutu, şekli (çekirdek yedi değişmeyen anları da dahil olmak üzere) ve doku parametreleri özellik vektörü olarak kullanılmıştır. Sınıflamada iki farklı teknik kullanıldı. Aşamalı diskriminant analizi ve yapay sinir ağı modelleri kullanıldı. Yapay sinir ağının diskriminant analizinden daha iyi olduğu bulunmuştur. Sadece üç girdiyle, basit bir üçlü algılama ağı hem öğrenme hem de test setlerinde %99'u aşan performans sergiledi. Bir özellik karışımının boyut ve şekil parametreleri için %92 ve boyut, şekil ve doku parametreleri için %99'a kadar başarı göstermiştir. En iyi özellikler görüntülerin kırmızı kanaldan elde edildiği görülmüştür.

2.2. LBP ile ilgili Çalışmalar

Bu bölümde Yerel İkili Örüntüler (Local Binary Pattern=LBP) yönteminin kullandığı alanlarla ilgili bir kısım çalışmalar verilmiştir. LBP istatistiksel bir görüntü işleme tekniğidir. Görüntü işleme, Bilgisayar görü uygulamalarında yoğun bir şekilde kullanılmaktadır. LBP genellikle doku analizi için kullanılmaktadır. Bu çalışmada üzüm çekirdek yüzeylerindeki dokuların birbirinden farklı olduğunu düşünerek doku analizi için LBP kullanılmıştır. Son yıllarda doku analizi için çeşitli yaklaşımlar önerilmiştir. Bu yaklaşımların çoğu yapısal, model temelli, istatistiksel (histogram, mutlak gradyan, çalışma uzunluğu matrisi, ortak oluşum matrisi, oto-regresif model, dalgacıklar), dönüşüm ve model bazlı yöntemlere (Castellano ve ark., 2004; Maani ve ark., 2013; Zhu ve ark., 2015) dayanıyor. Uygulamada en yaygın kullanılan yöntemler local binary pattern (LBP), Grey level co-occurrence matrix (GLCM), gabor filreleri (Hadizadeh, 2015) ve Wavelet yöntemleridir. LBP, doku analizi için kullanılan Ojala ve ark. tarafından önerilmiş doku sınıflandırma için kullanılan etkili en basit istatistiksel yaklaşımlardan biridir. Bir görüntünün veya görüntüdeki bir yerel yapının istatistiksel olarak yoğunluğunu belirtir. LBP görüntüdeki her pikseli, pikselin etrafında dairesel olarak oluşan komşu pikseller ile karşılaştırır (Pan ve ark., 2017). LBP yaklaşımı, merkez pikselin ve komşularının yerel farklılıklarının merkezi pikselin kendisinden bağımsız olduğu varsayımına dayanmaktadır. Pikseller arasındaki ilişkiler ikili örüntüler

ile ifade edilir. LBP'nin başlıca avantajları: (1) güçlü bir ayırt edici, (2) GLCM gibi yöntemlere göre daha düşük hesaplama maliyeti, (3) aydınlatma ve gürültüye daha az duyarlı ve basit uygulanabilir olması önemli avantajlardır. Bu avantajlardan dolayı, LBP doku analizi, yüz ve yüz ifadesi tanıma, çevre modelleme, biyomedikal görüntü işleme, uzaktan algılama, parmak izi tanıma, gerçek dış mekân sınıflandırma, gıda sınıflandırma (Cernadas, 2005; Zheng, 2006) gibi sayısız uygulamalarda kullanılmaktadır. LBP'nin bilgisayar görü uygulamalarındaki başarısına rağmen geleneksel LBP'nin bazı dezavantajları da bulunmaktadır. (1) uzun dengesiz dağılmış histogramlar üretilmektedir. (2) görüntü dönmeye bağımlıdır, (3) Gürültüye duyarlı ve büyük ölçekli dokuların algılanması zor olmaktadır. Bu durum etkili özelliklerin elde edilmesini zorlaştırmaktadır (Lian, 2015). Bu yüzden farklı geliştirilmiş çeşitli LBP yöntemler önerilmiştir. Bunlardan biri baskın yerel ikili örüntüler (DLBP) olup doku görüntülerinde dominant yerel yapıların çıkarılmasını amaçlamaktadır. Başka bir çalışmada, LBP tanımlayıcıları Gabor dönüşüm düzleminde (LGBP) kullanılmıştır (Shan ve ark., 2006). Ojala ve ark. (2002) videolardan doku çıkartma için LBP'nin dinamik bir versiyonu ve bunun bir başka versiyonu olan çok çözünürlüklü LBP'yi (MLBP) önerdi. Ayrıca, Ahonen ve ark. (2007) yumuşak histogramları ve Tan ve ark. (2010) ikili yerine üçüncül sayıları kullanarak yerel üçlü modelleri (LTP) önermişlerdir. Guo ve ark. (2010) geleneksel LBP'yi yerel yoğunluk farkı ve merkezi gri seviyesi ölçümleri ile birleştirerek tamamlanmış LBP'yi (CLBP) önerdi. Zhao ve ark. (2013), 3x3 lokal alanındaki her merkez pikselin değerinin, ortalama yerel gri seviyesi ile değiştirildiği tamamlanmış sağlam yerel ikili desen (CRLBP) adlı sağlam bir LBP çerçevesi önerdi. Kaya ve ark. (2015) komşu ve açılı tabanlı iki LBP tanımlayıcısı önerdiler. Önerilen yöntemler farklı veri setleri üzerinde denenerek başarılı sonuçlar raporlanmıştır. LBP ve uzantıları hem dokunun istatistiksel ve yapısal özelliklerini kullandığından, doku analizinde başarılı bir şekilde kullanılan ve diğer yöntemlere göre daha iyi performans sağlayan güçlü doku araçlarıdır, öte yandan hala ciddi dezavantajları vardır: yerel dokular arasındaki mekânsal ilişkileri yakalayamazlar (Liu ve ark., 2012). Hafiane ve ark. (2015) görüntüdeki mikro dokuları yakalamak ve görüntüdeki gürültüye duyarlı olması için Median Binary Pattern (MBP) yöntemini önerdiler. Özellikle standart veri tabanlarının üzerindeki öne sürülen çeşitli LBP yaklaşımların büyük başarısına rağmen, bu tür yaklaşımlarla ilgili birçok kısıtlama vardır. Desenler, ışık, açı, poz açısından düzenli olmayan karmaşık yerel yapılar ortaya koymaktadır. Genellikle, LBP tanımlayıcılar, yerel yapıyı çıkarmak için görüntü

üzerinde sabit bir yerel boyut kullanırlar. Bu yaklaşım, tüm doku elemanlarının değişkenliğini idare etmekte başarısız olabilir. LBP'nin kullanıldığı bir kısım çalışmalar bakıldığında;

Mahdi ve ark. (2017) tarafından yapılan bir çalışmada Kuzey Atlantik buzul balina çağrılarını tespit etmede iki aşamalı sınıflandırma stratejilerinin etkinliğini araştırılmıştır. Pasif akustik izleme cihazlarından gelen verilerin zaman-frekans ölçümleri görüntü olarak değerlendirilmiştir. Seslendirme spektrografları gürültü azaltma ve ton kaldırma işlemleri için önceden işlenmiştir. Algoritmanın ilk aşaması, bir enerji saptama algoritması ile yüksüz çağrılarını ortadan kaldırır. İkinci aşamada, kontur temelli ve doku tabanlı yöntemleri kullanarak kalan sinyallerden iki veri seti çıkartılmıştır. İlki, çağrı konturlarından zaman-frekans özelliklerinin çıkartılmasına dayanıyor ve sonuncusu, çağrılarının farklı doku özelliklerini çıkarmak için LBP operatörü kullanıyor. Sonradan değerlendirme aşamasında, upcall algılama için hem kontur temelli hem de doku temelli özelliklerin etkisini değerlendirmek için birkaç sınıflandırıcı kullanılarak başarılar ölçülmüştür.

Yerel ikili örüntü (LBP) teknikleri çok sayıda alana uygulanmıştır ve parlaklık ve dönmeden bağımsızdır. Yani görüntünün belirli açılarda dönmesi başarısını çok etkilememektedir. Bununla birlikte, optik karakter tanıma için LBP 'nin performansı beklendiği kadar iyi değildir. Bu amaçla LBP tabanlı farklı operatörler önerilmiştir. Bu konuda Chu-Sing Yang ve ark. (2017) tarafından yapılan bir çalışmada gelişmiş LBP (ILBP) adı verilen, optik karakter tanıma için tasarlanmış sağlam bir kenar tanımlayıcı önerilmiştir. ILBP, orijinal LBP 'de gözlemlenen gürültü sorunlarını, tanıma hızını elde etmek için azaltılmış sayıda özellik içeren bir integral görüntü kullanarak uygulanan ölçek alanını araştırarak yenmektedir. Sonuçlar, ILBP 'nin bulanıklık ve ses için LBP 'ye göre daha sağlam olduğunu göstermektedir.

Kim ve ark. (2017) şu bir çalışma gerçekleştirdiler. Gerçek zamanlı üç boyutlu (3D) veri toplama sensörlerinin (zaman-offlight ve Kinect derinlik sensörü gibi) bulunmasından sonra, hareket tanıma performansı büyük ölçüde geliştirilmiştir. Bununla birlikte, yerel ikili desen (LBP) gibi geleneksel iki boyutlu (2D) görüntü tabanlı öznitelik çıkarma yöntemleri genellikle doku bilgisini kullandığından, doku bilgisini içermeyen derinlik veya aralıklı görüntüye uygulanamazlar. Bu çalışmada, etkin derinlik görüntüleri tabanlı uygulamalar için bir uyarlanabilir yerel ikili desen (ALBP) önerilmiştir. Geleneksel LBP'nin aksine, önerilen ALBP, alan görüntülerindeki hem rotasyon hem de derinlik mesafesi bakımından değişmez. ALBP'yi kullanarak doku

veya renk bilgisi kullanmadan nesne özelliklerini çıkarabiliriz. Önerilen ALBP'yi, etkililiğini ve kullanılabilirliğini göstermek için derinlikli görüntüler kullanarak el izlemesi için kullanılmıştır. Deneysel sonuçlar yöntemin başarısını doğrulamaktadır.

Patel ve ark. (2016) yaptığı çalışmada, yüz cinsiyet sınıflamasına yönelik çoklu nicelleştirilmiş yerel ikili kalıpları kullandılar. Bir referans piksel ile komşuları arasındaki gri farkını (GLD) kodlamak için yerel ikili modelden faydalandılar. Ayırt etme kabiliyetini arttırmak için, önerilen yöntem GLD'nin çok seviyeli vektör kuantumlamasını yaparak hem işaret hem de büyüklük bileşenlerini kullandılar. Önerilen yöntem test etmek için yaygın olarak yapılan dört veri kümesinde (FERET, PAL, CASIA ve FEI) değerlendirdiler. Performansın çeşitli mevcut yöntemlerle karşılaştırılması, önerilen yöntemin daha yüksek ayrımcılık gücü, geliştirilmiş gürültü sağlamlığı ve daha iyi genelleme yeteneği gibi avantajlara sahip olduğunu açıkça ortaya koymuştur. Bir diğer çalışmada Kaddar ve ark. (2017) dokuları karakterize etmek için bir imaj içindeki yerel yapıların mekânsal düzenlenişini tanımlamayı denediler. Bununla birlikte, genellikle bölgelerin sınırlarının yakınında bulunan karışık pikseller doku sınıflandırmada sorun olmaktadır. Bu problemi çözmek için, bu çalışmada, görüntü içindeki uzamsal bilgilerin hesaba katıldığı etkili bir Yerel İkili Desen (LBP) tanımlayıcısına dayanan sağlam ayırt edici bir doku özellikleri önerdiler. LBP kodunu hesaplamak için her bir piksel için uygun bir ölçek parametresini ve eşik değerini belirlemek için bilateral (iki kenarlı, iki yüzlü) filtre tabanlı çok ölçekli görüntü analizine dayanan etkili bir yol kullandılar. İlk olarak, karşılık gelen ölçeği belirlemek için Gauss operatörünün farkı kullanılır. İkincisi, her pikselin eşik değerini belirlemek için temel noktalara dayalı yaklaşım kullanılır. Bu, karışık pikselleri halletme yeteneğini sağlar. Ardından, her piksel için doku bilgisini karakterize etmek için LBP kodu hesaplanır. Hem sentetik hem de gerçek görüntüler kullanan deneysel sonuçlar, önerilen uygun-ölçek eşikli seçim stratejisinin doku ayırımı becerisinde belirgin bir iyileşme gösterdiğini göstermektedir.

Her geçen gün dijital görüntü, insan hayatında popülaritesini artırmıştır. İnsanlar, düzenleme araçları veya kötü niyetli yazılımlar yardımıyla imajı düzenliyor. Mahale ve ark. (2017) yaptığı çalışmada bir görüntüdeki tutarsızlığı belirlemek için ön işleme, öznetelik çıkarma ve eşleme süreçlerini içeren LBP tabanlı bir model önerdiler. Elde edilen sonuç, 2x2 blok boyutlu LBP'nin, bir görüntüdeki tutarsızlıkların otomatik tespiti için doğruluk oranı \approx %98,58'e kadar en iyi başarı oranı verdiklerini gösterdiler.

Gu ve Liu (2013)'nın yaptığı çalışmada, yerel doku ve özelliklerin bilgilerini kodlayan yeni bir Özellik Yerel İkili Örüntü (FLBP) yöntemini sundular. Özellikler genel olarak, örneğin kenarlar, Gabor dalgacık özellikleri, renk özellikleri vb. ile tanımlanır. Spesifik olarak, bir ikili görüntü, belirli bir görüntüden özellik pikselleri çıkarılarak türetilir ve daha sonra her piksel ile ikili görüntüde tanımlanan en yakın özellik pikseli arasındaki mesafe vektörünün hesaplanmasıyla bir mesafe vektör alanı elde edilir. Mesafe vektörü alanı ve FLBP parametrelerine dayanarak, verilen görüntünün FLBP gösterimi oluşturulabilir. Yalnızca bir pikseli kendi komşuluklarındaki piksellerle karşılaştıran orijinal LBP'nin aksine; FLBP bir pikseli kendi komşuluklarındaki piksellerle ve diğer komşuluklardakilerle de karşılaştırabilir. BioID ve FERET veritabanları kullanılarak göz algılama deney sonuçları, FLBP yöntemimizin fizibilitesini göstermektedir. İlk olarak, FLBP yöntemi hem göz tespit hızı hem de göz merkezi lokalizasyon doğruluğu açısından LBP yöntemini göre önemli ölçüde daha başarılı olduğu görülmüştür.

Patel ve ark. (2016) bir diğer çalışmada, yüz görüntülerinden cinsiyet tanımaya yönelik yeni bir öznelik çıkarma yöntemi, pusula yerel ikili örüntüler (CoLBP) yöntemini kullandılar. Sağlamlığı sağlamak için, önerilen yöntem ilk önce sekiz Kirsch sınır maskesi (kamuflej) kullanarak yönlü kenar yanıtları hesaplar. Ardından, her bir kenar tepkisinde komşu pikseller arasındaki mekansal ilişkiler, ayrımcılık kabiliyetini artırmak için yerel ikili desen (LBP) yardımı ile bağımsız olarak kullanılırlar. Ardından, her bir kenar tepkisinde komşu pikseller arasındaki mekansal ilişkiler, ayrıştırma kabiliyetini artırmak için yerel ikili desen (LBP) yardımı ile bağımsız olarak kullanılırlar. Son olarak, bu LBP görüntülerinden hesaplanan uzaysal histogramlar, bir yüz tanımlayıcı oluşturmak için birleştirilir. Önerilen tanımlayıcıımız, gradyan, bölgesel, global ve yön seviyesi de dahil olmak üzere dört farklı seviyeden ayırt edici bilgi çıkarmaktadır. Önerilen yöntem, yüz fotoğraflarını içeren üç veri kümesi üzerinde (renkli FERET, LFW ve Adience) değerlendirildi. Veri setlerinde mevcut olan çeşitli zorluklara (düşük çözünürlük, poz, ifade ve aydınlatma varyasyonları) rağmen, önerilen yöntem mevcut bazı kıyaslama yöntemlerine kıyasla umut verici sınıflandırma performansı sağladı.

Beyin tümörü patolojisi, sağlık hizmetleri toplumları için vazgeçilmez bir öncelik olarak kabul edilen en yaygın ölümlülük sorunlarından biridir. Bozukluğun doğru tanısı, ölümcül sonuçları en aza indirecek bir çare bulmak için bir plan yapmak için çok önemlidir. Bölünme ve saptamanın temel amacı beynin farklı bölgelerinde

ayırım yapmaktır. Doğruluğun yanı sıra, bu teknikler hızla uygulanmalıdır. Abbasi ve Tajeripour (2017) yaptığı çalışmada 3D görüntülerde beyin tümörü tespiti için otomatik bir yöntem önerilmiştir. İlk adımda, önayarım alanı düzeltme ve histogram eşleştirme, görüntülerin ön işleme tabi tutulmuştur. Bir sonraki adımda, ilgili bölge belirlenir ve Flair imgesinin arka planından ayrılır. Öğrenme özellikleri olarak, üç dikey düzlemdeki yerel ikili model (LBP-TOP) ve yönlendirme gradyentlerinin histogramı (HOG-TOP) kullanılır. Daha sonra RF (Random forest) ile sınıflandırma işlemi gerçekleştirilmiştir. Deneysel sonuçlar ve analizler, önerilen çerçevenin beyin tümörlerinin diğer tekniklerle karşılaştırıldığında daha iyi olduğunu göstermektedir. Peyret ve ark. (2017) yaptığı çalışmada, kolorektal ve prostatik tümör biyopsileri örneklerinin otomatik olarak sınıflandırılması için yeni bir çoklu spektral çok ölçekli yerel ikili model öznelik çıkarma yöntemi önerilmektedir. Çok katlı yığılmış genelleme sınıflandırma tekniği de önerilmiştir ve makalenin ana fikri hem görülebilir hem de yakın kızılötesi spektrumlarında multispektral görüntü kavramını kullanarak, basit kötü niyetli bir karşıt tümürlü doku problemi yerine, bir sınıf tanısal problemi değerlendirir. Önerilen algoritma performanslarını doğrulamak için, multispektral doku bilim görüntülerle üç farklı çoklu sınıf veri setleri üzerinde bir değerlendirme de dahil olmak üzere, çok boyutlu görüntü kullanan ilgili çalışmalara karşı karşılaştırmalı bir çalışma yürütülür: iki tanesi kolorektal biyopsi görüntülerini temsil eder- bir veri kümesi görünür spektrumda elde edilirken, ikincisi kızıl ötesine yakın spektrumları almıştır. Önerilen algoritma, farklı veri kümelerinde %99,6 doğruluk elde etmektedir. Elde edilen sonuçlar, en ayrıştırıcı bilgileri daha etkili bir şekilde yakalamak için kızılötesi dalga boylarının avantajlarını ortaya koymaktadır. Elde edilen sonuçlar, önerilen algoritmamızın benzer diğer yöntemlerden daha iyi performans gösterdiğini göstermektedir.

Wan ve ark. (2017) çalışmasında, Optik Koherens Mikroskopi (OCM) ile görüntülenen insan meme dokusunun farklı türlerini etkili bir şekilde sınıflandırabilen bir doku analiz tekniği önerilmiştir. OCM hızlı doku taramasında ortaya çıkan görüntüleme yöntemidir ve histolojiye yaklaşan yüksek çözünürlüklü mikroskobik görüntüler sunma potansiyeline sahiptir. Bununla birlikte, doku boyaması olmadan elde edilen OCM görüntüleri, görüntü analizi ve model sınıflandırması için benzersiz zorluklar ortaya koymaktadır. Birden fazla doku özelliklerini incelendi ve OCB tarafından görüntülenen dokuları sınıflandırmada daha iyi performans göstermek için Yerel İkili Patern (LBP) özellikleri kullanıldı. Sınıflandırma doğruluğunu iyileştirmek

için, LBP özelliklerinin yeni varyantlarını, yani ortalama LBP (ALBP) ve blok tabanlı LBP'yi (BLBP) önerilmiştir. Klasik LBP özelliğiyle karşılaştırıldığında, ALBP ve BLBP özellikleri komşu pikseller arasındaki ve komşuluklardaki belirli piksel blokları arasındaki yoğunluk farklarına bakarak yerel bir komşulukta doku yapısının gelişmiş bir kodlamasını sağlar. 27 iyi huylu ve 19 meme karsinomu da dahil olmak üzere 46 adet taze alınmış insan meme dokusu örneği, her örnek için 10 x 10 mm² (10 000 x 10 000 piksel) görüntüleme alanı olan geniş alan OCM ile görüntülendi. Her bir örnek için karşılık gelen H & E histolojisi elde edildi ve doğru doğruluk tanısı için kullanıldı. Her biri, ilgili H & E histolojisi ile eşleştirilmiş 4310 küçük OCM görüntü bloğu (500 × 500 piksel), geniş alan OCM görüntülerinden çıkarıldı ve bu beş sınıftan biriyle etiketlendi: adifoz doku (n = 347), fibröz stroma (n = 2,065), meme lobülleri (n = 199), karsinomalar (tüm alt tiplerden bir araya getirilmiş, n = 1,127) ve arka plan (numunelerin dışındaki bölgeler, n = 572). Deneyimlerimiz, seçilen LBP setini ve iki yeni varyantın (ALBP ve BLBP) özelliklerini birden fazla ölçekte birleştirerek, sınıflandırma doğruluğu, (yalnızca LBP özelliklerini kullanarak) %81,7'den bir sinir ağı sınıflandırıcısı kullanarak %93,8'e yükseldiğini gösteriyor. Entegre özellik, aynı zamanda, büyük saha OCM görüntülerinin tümör algılaması için sınıflandırılması için kullanıldı. 0.959'luk bir eğri değerinin altındaki bir alanla bir alıcı çalışma karakteristiği (ROC) eğrisi elde edildi. Kötü niyetli örneklerden iyi huyluları ayırt etmek için %100 duyarlılık düzeyi ve %85,2 özgünlük (kesinlik) düzeyi elde edildi. Birkaç başka deneyde, LBP'nin ve iki değişkenin (ALBP ve BLBP özellikleri) tamamlayıcı nitelikleri ve bu doku özelliklerinin sınıflandırma için entegrasyonunun önemi de gösterilmektedir. Birden fazla ölçekten özelliklerin kullanılması ve özellik seçimi gerçekleştirilmesi, hesaplama verimliliğini korurken doğruluğu artırmak için etkili mekanizmalardır.

Tıbbi görüntü tanıma hem bilgisayar görme hem de hesaplama biyolojisinde önemli bir görevdir. Tıbbi görüntü sınıflandırması alanında, yerel ikili örüntülere (LBP) dayalı bir görüntüyü temsil etmek popüler hale gelmiştir. Bununla birlikte, var olan LBP tabanlı yöntemlerin çoğunun, ikili örüntüleri sabit bir komşuluk yarıçapında kodladığı ve yerel örüntüler arasındaki mekansal ilişkileri görmezden geldiği bilinmektedir. LBP'deki mekansal ilişkileri görmezden gelmek, mikroskop ile elde edilen tıbbi görüntüler gibi karmaşık örnekler için ayırt edici özellikleri yakalama sürecinde zayıf bir performansa neden olacaktır. Bu problemi çözmek için, Liu ve ark. (2016), her piksel için uyarlanabilir bir komşuluk yarıçapı atayarak yerel ikili kalıpları

iyileřtirmek iin yeni bir yntem nerdiler. Bu uyarlanabilir lokal ikili kalıplara dayanarak, grnt sunumu iin mikro yapıları kodlamak iin uzamsal bitiřik histogram stratejisi neriyoruz. nerilen yntemin standart LBP'yi nemli derecede geliřtirdiđini ve bazı diđer yaygın yaklařımlarla karřılařtırıldıđında uygun olduđunu gsteren drt tıbbi veri kmesi zerinde kapsamlı bir deđerlendirme yapılmıřtır.






3. MATERYAL VE METOT

3.1. Materyal

Çalışma ile ilgili inceleme materyalleri Siirt ilinin farklı lokasyonlarından toplanmıştır. Araziden toplanan üzüm örnekleri laboratuvar ortamına getirilmiştir. Üzüm çekirdekleri pens yardımı ile çıkarılmış etil alkol (%70) ile temizlenerek kurutulmuştur. Üzüm çekirdek görüntüleri Olympus marka SZ 61 model mikroskop ve DP 20 model kamera ile gerçekleştirilmiştir. Bu çalışmada Aşkar, Binetati, C Nator, Cevzane, Gadüv, Gozane Siyah, Hazirani, Heci Mendi, Heseni, Sinciri, Tayfi Siyah ve Tayfi üzüm türlerine ait görüntüler kullanılmıştır. Çalışmada kullanılan üzüm türlerine ait görüntüler Şekil 3.1’de verilmiştir. Ayrıca kullanılan üzüm çekirdek türleri Tablo 3.1’de verilmiştir.



Şekil 3. 1. Çalışmada kullanılan üzüm türlerine ait görüntüler

Tablo 3. 1. Üzüm türleri ve kodları

Kod	Türü
T1	Aşkar
T2	Binetati
T3	C Nator
T4	Cevzane
T5	Gadüv
T6	Gozane Siyah
T7	Hazirani
T8	Heci Mendi
T9	Heseni
T10	Sinciri
T11	Tayfi
T12	Tayfi Siyah


3.2. Metot

Bu çalışmada üzüm türlerinin sınıflandırılması için bilgisayar görü tabanlı yeni bir yaklaşım önerilmiştir. Karakteristik özelliğe sahip üzüm çekirdeklerinin görüntüleri kullanılmıştır. Önerilen yöntem LBP_{RGB} klasik LBP yönteminin renkli görüntüler için düzenlenmiş halidir. Önerilen yöntem RGB renk katmanlı LBP (LBP_{RGB}) yöntem olarak isimlendirilmiştir. Bu yöntem ile renkli üzüm çekirdeklerine ait görüntülerden etkili özellikler çıkarılmıştır. Yöntem aşağıda anlatılmıştır.

3.2.1. Yerel İkili Örüntüler

Yerel İkili Örüntüler (Local Binary Pattern=LBP, YİÖ) tanımlayıcısı görüntülerden etkili özellikler elde etmemizi sağlayan bir istatistiksel yaklaşımdır. LBP tanımlayıcısı özellik çıkarımı yerel komşuluk değerlerine dayanır. Bilgisayar görü uygulamalarında yaygın bir şekilde kullanılmaktadır. Etkinliği çeşitli uygulamalarla kanıtlanmıştır. İki aşamadan oluşmaktadır. Birinci aşamada görüntülerden yerel ikili örüntüler, mikro yapılar çıkarır. İkinci aşamada ise bu örüntülerin histogramını oluşturur (Ojala ve ark., 2002; Lio ve ark., 2009).


LBP tanımlayıcısı, 3x3 komşuluğunda merkez pikseli (f_C) etrafındaki pikseller $f_P = (P = 0,1, \dots, 7)$ ile karşılaştırarak her piksel için ikili bir değer $S(f_P - f_C)$ oluşturmaktadır. LBP tanımlayıcısı ile bir pikselin etiketlenmesine ilişkin bir örnek Şekil 3.2'de verilmiştir. LBP değerleri görüntüdeki her pikselin komşuları arasındaki farkın basamak fonksiyonu ile ikilileştirilmesi ile elde edilir (Eşitlik 1).



Şekil 3. 2. LBP dairesel komşu şeması

$$YiÖ_{P,R}(x_c) = \sum_{p=0}^{P-1} \mu(x_p - x_c) 2^p, \mu(y) = \begin{cases} 1, y \geq 0 \text{ ise} \\ 0, y < 0 \text{ ise} \end{cases} \quad (1)$$

LBP_{P,R} biçimindeki operatörde, R yarıçapı belirtip komşu piksellerin merkez piksele olan uzaklığını belirtirken, P ise işleme dahil edilen komşu piksel sayısını ifade eder (Zhao ve ark., 2007). Aşağıdaki örnekte (Şekil 3.3) R yarıçap bir (1) alınırken, komşu sayısı P ise sekiz (8) alınmıştır.

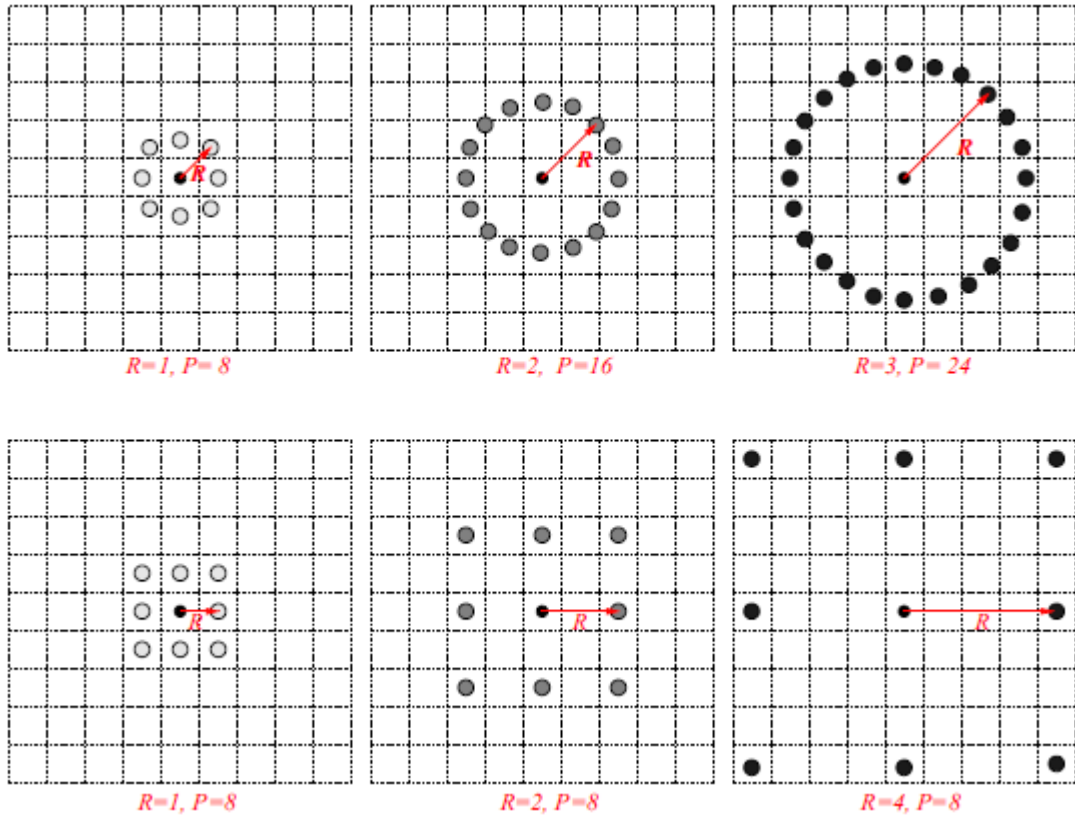


Şekil 3. 3. Bir piksel için LBP değerinin elde edilmesi

Yapılan çalışmalarda görüntülerdeki yüzeylerinin büyük bir kısmının uniform örüntülerden oluştuğu görülmektedir. Uniform örüntüler, ikili LBP kodunda 0-1 ya da 1-0 geçiş sayısı 2 ya da daha az olanlardır. Örneğin 00000000 ve 11111111 örüntüleri 0 geçişe, 01100000 ve 11000011 örüntüleri 2 geçişe sahip olduklarından uniform örüntülerdir. Uniform örüntüler, spot, kenar, köşe gibi basit dokuları da açıklayabilmekteler. Toplamda (P-1) P+2 uniform örüntü bulunmaktadır (Nanni ve ark., 2010; Ahonen ve ark., 2006; Kaya ve ark., 2015).

LBP'nün ilk parametresi komşu sayısını belirten P'dir. LBP görüntünün oluşturulmasında P'nin büyük değerleri hem öznelik histogramını büyütmede hem de işlem maliyetini artırmaktadır. P'nin küçük değerleri ise önemli bilgi kaybına neden olabilmektedir. LBP'nin ikinci parametresi ise ölçek (R) parametresidir. R komşu

piksellerin merkez piksele olan uzaklığını belirtir. Farklı R değerlerin kullanılması ile farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmaktadır. Bu notasyon çeşitli dairesel komşulukların kullanılabilceğini de göstermektedir. Farklı P ve R değerlerin kullanılması ile farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmaktadır. Şekilde 3.4'te farklı LBP operatörlerine örnek verilmiştir.

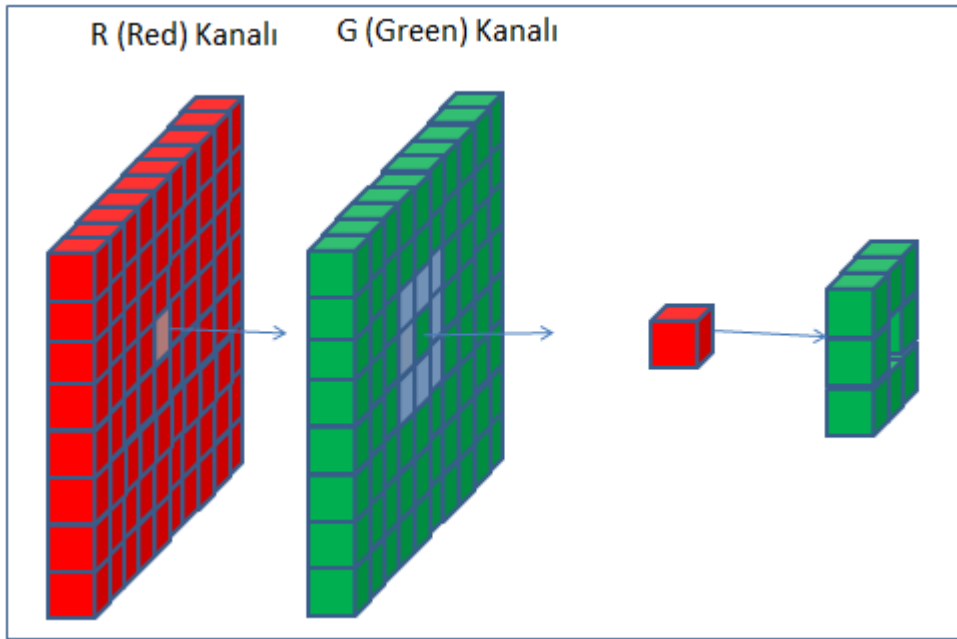


Şekil 3. 4. Farklı P ve R parametrelerine göre LBP tanımlayıcıları

3.3. RGB Renk Katmanlı LBP'ler


Klasik LBP yönteminde görüntüler önce gri seviye görüntüye dönüştürülür. Daha sonra LBP yöntemi uygulanır. Yukarıda klasik LBP yönteminin çalışma mantığını anlatmıştık. LBP yönteminde renkli görüntülerdeki renk kanallarındaki bilgileri kullanamamaktadır. Bu kanallarda ayır edici özelliklerin olduğu düşünülmektedir. Bu yüzden bu çalışmada renkli görüntüye uygulanabilecek bir yöntem önerilmiştir. Önerilen yöntem renkli görüntülerin tüm kanallarında ayır edici özellikler taramaktadır. Oluşturulan bu yeni yaklaşım ile klasik yerel ikili örüntülerin kullanıldığı gri renklere ek olarak kırmızı, yeşil ve mavi renk kümelerinden yararlanılmıştır. Uygulanması klasik yerel ikili örüntülerden farklılık göstermektedir. Bu yöntemde resmin renk

kanallarından (R (red), G (green), B (blue)) öznitelikler çıkarmaktadır. Her resim için R, G, B kanalları ayrı düşünüldüğünde bir resmin üç (3) farklı görüntüsü elimizde bulunmuş olacaktır. Bu yaklaşımda her piksel kendi resmi içindeki komşular veya farklı resimdeki aynı yerdeki komşular ile karşılaştırılarak LBP özellikleri elde etmektedir. Bu işlem sonucunda seçtiğimiz merkez pikseli, resmin farklı filtrelenmiş hallerindeki aynı konumdaki pikseller ile kıyaslıyoruz ve kıyaslama sonucunda ikili örüntüler elde ediyoruz. Örneğin R resmi G resmi kullanılarak özellikler çıkarmak için R resimdeki her piksel G resmindeki aynı konumdaki pikselin etrafındaki komşular ile kıyaslanmaktadır. Burada amaç görüntüleri birbirinden ayırt eden farklı öznitelikler elde etmektedir. Önerilen yöntemle ait bazı örnekler aşağıdaki şekillerde gösterilmiştir.



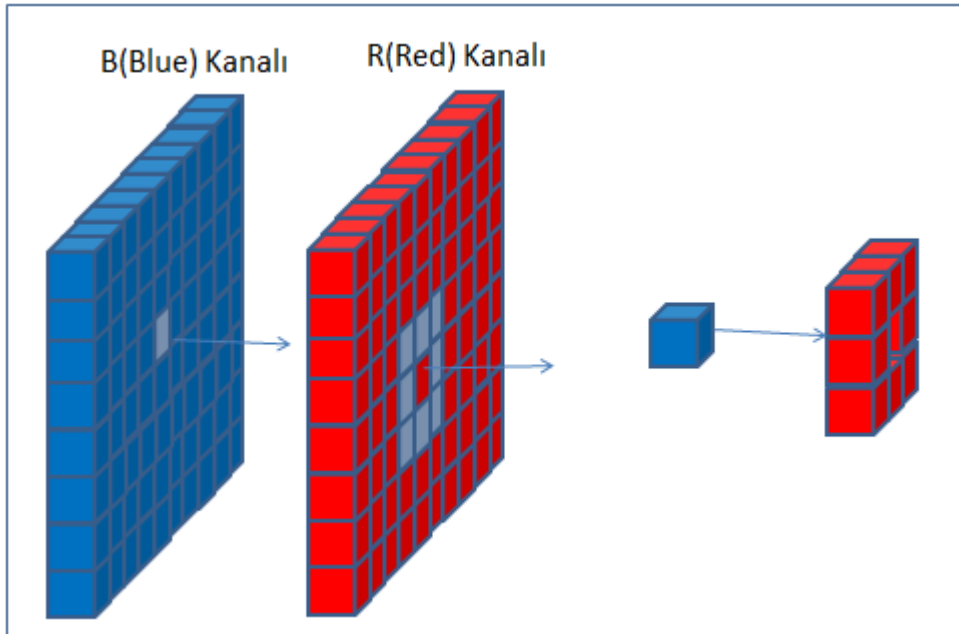
Şekil 3. 5. R-G kanalları için LBP_{RGB}

Yukarıdaki örnekte R kanalındaki her piksel G kanalındaki yansımasının etrafındaki sekiz (8) piksel ile karşılaştırılarak LBP operatörü hesaplanmaktadır. LBP R-G kanallarındaki piksel bilgilerinden elde edilmektedir.



Şekil 3. 6. G-B kanalları için LBP_{RGB}

Yukarıdaki örnekte G kanalındaki her piksel B kanalındaki yansımasının etrafındaki sekiz (8) piksel ile karşılaştırılarak LBP operatörü hesaplanmaktadır. LBP G-B kanallarındaki piksel bilgilerinden elde edilmektedir.



Şekil 3. 7. B-R kanalları için LBP_{RGB}

Yukarıdaki örnekte B kanalındaki her piksel R kanalındaki yansımasının etrafındaki sekiz (8) piksel ile karşılaştırılarak LBP operatörü hesaplanmaktadır. LBP B-R kanallarındaki piksel bilgilerinden elde edilmektedir. Önerilen LBP_{RGB} yaklaşımı ile R-R, R-G, R-B, G-G, G-B, G-R, B-B, B-R ve B-G şeklinde 9 farklı kombinasyonda LBP elde edilir.

3.4. Sınıflandırma

Sınıflandırma terimi, bir veri kümesinin önceden belli olan kategorilerine dağıtılma işlemidir. Bu çalışmada sınıflandırma üzüm çekirdek görüntülerinin üzüm türleri şeklinde dağıtılmasıdır. Sınıflandırma yöntemleri, verilen bir eğitim kümesinden bu dağılım şeklini diğer bir deyişle hangi parametreler ile gözlemlerin hangi kategorilere ayrışacağını öğrenirler ve daha sonra test verileri geldiğinde doğru şekilde sınıflandırmaya çalışırlar. Veri kümesi üzerinde verilen bu sınıfları belirten değerlere etiket ismi verilir ve gerek eğitim gerekse test sırasında verinin sınıfının belirlenmesi için kullanılırlar. Bu tezde amacımız üzüm çekirdeklerinden etkili özellikler elde ederek bu özellikler üzerinden görüntülerin sınıflandırılmasıdır. Bu çalışmada sınıflandırma algoritmaları konu dışındadır. Ancak LBP_{RGB} ile elde edilen görüntüler Yapay sinir ağları (YSA), Karar destek vektörleri (KDV), Karar Ağaçları, K-en yakın komşu yöntemleri gibi farklı sınıflandırma algoritmaları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

3.5. Performans Ölçütleri

Model başarımını değerlendirirken kullanılan temel kavramlar hata oranı, kesinlik, duyarlılık ve F-ölçütüdür. Modelin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atılan örnek sayısı nicelikleriyle alakalıdır. Model başarımını ölçmek için kullanılan ölçütler aşağıdaki karışıklık matrisinden elde edilir.

Tablo 3. 2. Performans ölçütleri

Gerçek Sistemde / Tahmini Sistemde	Sınıf 1	Sınıf 0
Sınıf 1	DP (Doğru Pozitif)	YP (Yanlış Pozitif)
Sınıf 0	YN (Yanlış Negatif)	DN (Doğru Negatif)

Dođru Pozitif: Tamamıyla dođru sınıflandırılan örneklerin sayısını belirtir.

Dođru Negatif: Diđer sınıflara ait tamamıyla dođru sınıflandırılan örnek sayısı.

Yanlıř Pozitif: Yanlıř sınıflandırılan örneklerin sayısı

Yanlıř Negatif: Diđer sınıflara ait yanlıř sınıflandırılan örnek sayısı.

3.5.1. Dođruluk (Accuracy)

Model başarımının ölçülmesinde kullanılan en popüler ve basit yöntem, modele ait dođruluk oranıdır. Dođru sınıflandırılmış örnek sayısının (TP +TN), toplam örnek sayısına (TP+TN+FP+FN) oranıdır.

$$\text{Dođruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (2)$$

3.5.2. Hata Oranı (Error rate)

Hata oranı ise bu deđerin 1'e tamlayanıdır. Diđer bir ifadeyle yanlıř sınıflandırılmış örnek sayısının (FP+FN), toplam örnek sayısına (TP+TN+FP+FN) oranıdır.

$$\text{Hata Oranı} = \frac{FP+FN}{TP+FP+FN+TN} \quad (3)$$

ya da

$$\text{Hata Oranı} = 1 - \text{Dođruluk} \quad (4)$$

3.5.3. Kesinlik(Precision)

Kesinlik, sınıfı 1 olarak tahminlenmiş True Pozitif örnek sayısının, sınıfı 1 olarak tahminlenmiş tüm örnek sayısına oranıdır.

$$\text{Kesinlik} = \frac{TP}{TP+FP}$$

(5)

3.5.4. Hatırlama (Recall)

Gerçek deđer pozitif olup pozitif deđere sınıflandırılan sayısının, gerçek deđer pozitif olanların tümüne oranıdır.

$$\text{Recall (r)} = \frac{TP}{TP + FN} \quad (6)$$

3.5.5. Duyarlılık (Sensitivity)

Dođru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranıdır.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (7)$$


3.5.6. F-measure (F)

Kesinlik ve duyarlılık ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. Bunun için f-ölçütü tanımlanmıştır. F-ölçütü, kesinlik ve duyarlılığın harmonik ortalamasıdır.

$$2 * TP / (2 * TP + FP + FN) \quad (8)$$

3.6. Çalışma Diyagramı

Bu tezde üzüm çekirdek görüntüleri kullanılarak bilgisayar görü tabanlı üzüm teşhisi gerçekleştirilmiştir. Çalışmanın diyagramı Şekil 3.8’de verilmiştir. Her blokta yapılan işlemler kısaca özetlenmiştir.



Şekil 3. 8. Çalışma Diyagramı

Blok 1: Bu kısımda üzüm çekirdek görüntüleri elde edilmiştir. 12 üzüm türüne ait toplamda 224 görüntü toplanmıştır. Görüntüler mikroskop altında kamera ile çekilmiştir.

Blok 2: Ön işlem bloğudur. Elde edilen görüntüler üzerinde temizleme işlemlerinin yapıldığı bloktur.

Blok 3: Bu aşamadan görüntülerden özellikler elde edilmiştir. Görüntülerden hem LBP, hem de LBP_{RGB} yöntemi ile özellikler çıkarılmıştır.

Blok 4: Elde edilen LBP görüntülere ait histogramlar çıkarılmıştır. Histogramlar özellikler matrisi olarak kabul edilmiştir.

Blok 5: Bu blokta elde edilen LBP ve LBP_{RGB} özellikler kullanılarak farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi 10-kat çapraz geçerlilik testine göre gerçekleştirilmiştir. Yapılan çapraz doğrulama işlemine göre veri kümesi 10 kümeye bölünmüştür. Bir çapraz doğrulamada 10 kümenin 1 kümesi test, 9 kümesi ise eğitim için kullanılır. Her küme 1 kez test için

geriye kalan 9 küme ise eğitim için kullanılmış anlamına gelir. Sınıflandırma algoritmaları olarak yapay sinir ağları (YSA), karar destek vektörleri (KDV), Logistic Model Tree (LMT), K-en yakın komşu algoritması gibi yöntemler kullanılmıştır. Yazılım olarak sınıflandırma işlemi için Weka yazılımı kullanılmıştır.


Blok 6: Sonuçların paylaşıldığı bloktur. Üzüm türünün tespit edildiği aşamadır. Bu aşamada görüntüler önerilen metot ile ilgili sınıflara ayrıştırılmaktadır.




4. SONUÇLAR

4.1. LBP ve LBP_{RGB} Sonuçları

Bu tezde yeni bir LBP yaklaşımı önerilmiştir. Bu yaklaşım ile üzüm çekirdek görüntülerinden üzüm teşhisi gerçekleştirilmiştir. Bu yaklaşım renkli görüntülere uygulanmaktadır. Bir görüntünün her renk (RGB) kanalındaki her piksel kendi renk kanalı veya diğer bir kanaldaki yansıması olan piksel etrafındaki komşular ile karşılaştırılarak LBP operatörü oluşturulmaktadır. Önerilen yöntem renkli görüntülerin tüm kanallarında ayırt edici özellikler taramaktadır. Oluşturulan bu yeni yaklaşım ile klasik yerel ikili örüntülerin kullanıldığı gri renklere ek olarak kırmızı, yeşil ve mavi renk kümelerinden yararlanılmıştır. Uygulanması klasik yerel ikili örüntülerden farklılık göstermektedir. RGB renk katman sayısından dolayı bu yöntem ile 9 farklı veri seti elde edilmektedir. RR, GG, BB, RG, RB, GB, GR, BR ve BG gibi 9 farklı kanal karşılaştırmalarından dolayı farklı LBP operatörler elde edilmektedir. Şekil 4.1'deki görüntü için kanal karşılaştırmaları için elde edilen LBP görüntüler Şekil 4.2'de verilmiştir.

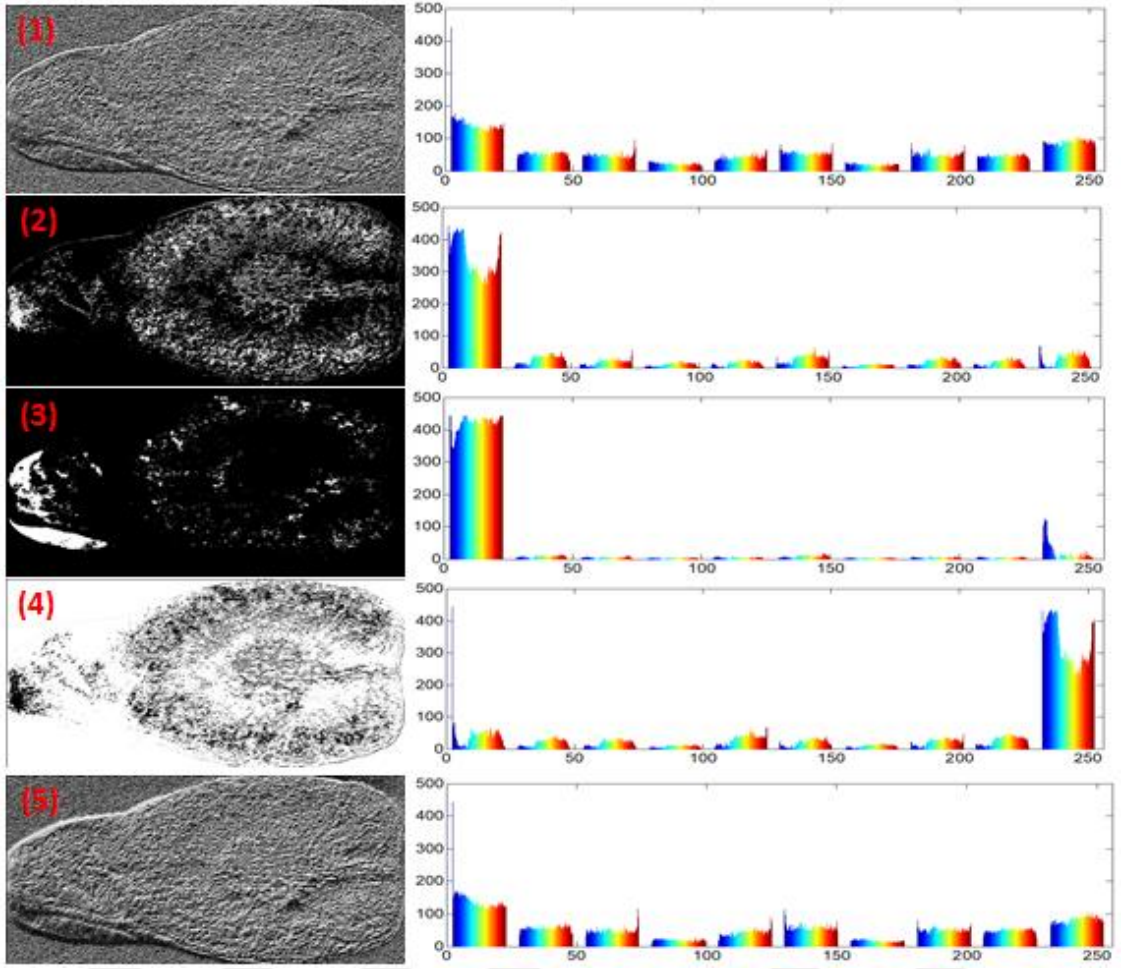


Şekil 4. 1. Üzüm Çekirdeği




Şekil 4. 2. RGB kanallar ve kombinasyonlar için elde edilen LBP görüntüler

Şekil 4.2'den görüldüğü elde edilen LBP görüntüler birbirinden farklılık göstermektedir. Dolayısıyla elde edilecek LBP histogramları da farklılık gösterecektir. Bu yöntem ile amaç üzüm türlerini birbirinden ayırt edecek örüntüler aramaktır. Dolayısıyla farklı LBP örüntüler bu üzüm türünün teşhisinde yardımcı olacaktır. Bir görüntü için farklı renk kanallarından elde edilen histogramlar Şekil 4.3 ve Şekil 4.4'te verilmiştir.



Şekil 4. 3. LBP görüntü ve Histogramları. (1) LBP_{RR} , (2) LBP_{RG} , (3) LBP_{RB} , (4) LBP_{GR} , (5) LBP_{GG} görüntü ve histogramlar



Şekil 4. 4. LBP görüntü ve histogramlar. (6). LBP_{GB}, (7) LBP_{BR}, (8) LBP_{BG}, (9) LBP_{BB}, (10) LBP_{Klasik} görüntü ve histogramlar

Şekil 4.3 ve Şekil 4.4'ten görüldüğü gibi farklı renk kanallarından elde edilen görüntüler birbirinden farklılık göstermektedir. Hem LBP görüntülerinden hem de histogramlardan bu farklılıklar görülmektedir. Bu farklı görüntülerin üzüm teşhisinde başarılı olup olmadığı sınıflandırma metotları ile anlaşılabilir. Elde edilen bu görüntüleri özellik vektörleri olarak düşünerek sınıflandırma metotlarına verildi. Farklı sınıflandırma metotları denenmiştir. Sınıflandırma için açık kaynak bir program olan Weka yazılımı kullanılmıştır. Farklı sınıflandırma metotları denenmiştir. En yüksek başarı oranı gözlenen metotlara ait sonuçlar verilmiştir. Her bir veri seti için elde edilen başarı oranları aşağıdaki tablolarda verilmiştir. Üzüm çekirdek görüntülerinden elde edilen LBPRR görüntüleri için başarı oranları Tablo 4.1'de verilmiştir. Tablo 4.1'de karışıklık matrisi verilmiştir. Her üzüm türü için başarı oranları ayrı ayrı gösterilmektedir. Karışıklık matrisinde soldan sağa köşegen sütun her üzüm türü için

doğru sınıflandırılan görüntü sayısını vermektedir. Diğer hücrelerdeki değerler ise yanlış sınıflandırılan görüntü sayılarıdır.

Tablo 4. 1. LBP_{RR} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
16	0	0	1	1	0	0	0	0	0	0	2
0	14	0	0	1	1	0	0	0	0	0	0
0	0	13	0	0	1	0	0	0	0	0	0
0	0	0	17	1	0	1	2	0	0	0	0
0	0	0	2	15	1	0	0	1	0	0	1
0	1	0	0	0	15	0	1	1	3	0	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	1	1	0	1	17	1	0	0	0
0	1	1	0	2	0	0	1	16	0	0	0
0	1	0	1	0	1	0	0	0	13	1	0
1	0	0	2	3	1	0	0	0	1	12	1
0	0	0	2	0	1	0	0	0	1	1	16

Karışıklık matrisini kullanarak her üzüm türü için başarı oranları LBP_{RR} performans tablosunda verilmiştir.

Tablo 4. 2. LBP_{RR} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,8	0,005	0,941	0,8
0,875	0,014	0,824	0,875
0,929	0,005	0,929	0,929
0,81	0,044	0,654	0,81
0,75	0,044	0,625	0,75
0,714	0,034	0,682	0,714
0,909	0,009	0,833	0,909
0,81	0,02	0,81	0,81
0,762	0,015	0,842	0,762
0,765	0,024	0,722	0,765
0,571	0,01	0,857	0,571
0,762	0,02	0,8	0,762
0,777	0,021	0,788	0,777

Tablo 4.2'ye bakıldığında en yüksek başarı oranı T3 üzüm türü için %92,9 olarak elde edilmiştir. Daha sonra en yüksek başarı T7 üzüm türü için %90,9 olarak gözlenmiştir. En kötü başarı oranı T11 üzüm türü için %57,10 olarak elde edilmiştir.

Tüm görüntüler için ortalama sınıflandırma başarısı %77,7'dir. Sonuç olarak LBP_{RR} öznelikleri için YSA sınıflandırma metodu ile %77,7 başarı oranı elde edilmiştir.

LBP_{RG} özneliklerini kullanarak YSA ile edilen karışıklık matrisi ve performans değerleri Tablo 4.3 ve Tablo 4.4'te verilmiştir.

Tablo 4. 3. LBP_{RG} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
12	0	0	1	0	1	0	0	0	0	2	4
1	14	0	0	1	0	0	0	0	0	0	0
0	0	11	0	1	0	0	0	2	0	0	0
1	0	0	19	1	0	0	0	0	0	0	0
0	0	0	2	15	2	0	0	0	1	0	0
0	0	0	0	1	18	0	0	1	1	0	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	0	0	0	1	18	0	0	2	0
0	1	2	0	1	0	0	1	15	0	0	1
0	1	0	0	0	2	0	0	0	11	3	0
4	0	0	1	0	0	0	1	0	1	12	2
3	0	0	3	2	1	0	0	0	0	1	11

Tablo 4. 4. LBP_{RG} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,6	0,044	0,571	0,6
0,875	0,01	0,875	0,875
0,786	0,01	0,846	0,786
0,905	0,034	0,731	0,905
0,75	0,034	0,682	0,75
0,857	0,034	0,72	0,857
0,909	0,005	0,909	0,909
0,857	0,01	0,9	0,857
0,714	0,015	0,833	0,714
0,647	0,014	0,786	0,647
0,571	0,039	0,6	0,571
0,524	0,034	0,611	0,524
0,741	0,025	0,744	0,741

Performans tablosuna bakıldığında LBP_{RG} öznelikleri ile LBP_{RR} özneliklere göre daha düşük başarı oranı elde edilmiştir. LBP_{RG} ile ortalama %74,10 başarı oranı elde edilmiştir. Sınıflandırma işlemi YSA ile gerçekleştirilmiştir. En yüksek başarı oranı

T7 üzüm türü için %90,90 olarak gözlenmiştir. En düşük başarı oranı ise T12 için %52,4 olarak gözlenmiştir.

LBP_{RB} öznitelikleri kullanarak elde edilen karışıklık matrisi ve performans ölçütleri Tablo 4.5 ve Tablo 4.6’da verilmiştir. Sınıflandırma işlemi LMT (Logistic Model Tree) ile gerçekleştirilmiştir.

Tablo 4. 5. LBP_{RB} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
7	5	0	1	0	1	0	0	0	3	1	2
3	7	0	2	1	2	0	0	0	0	1	0
0	0	13	0	0	0	0	0	1	0	0	0
0	0	0	16	0	4	0	1	0	0	0	0
1	0	0	2	6	2	0	5	1	1	0	2
1	1	1	3	4	5	0	0	3	0	1	2
1	0	0	0	0	1	9	0	0	0	0	0
0	0	0	0	5	5	2	7	1	1	0	0
0	0	1	2	2	3	0	0	12	0	1	0
2	1	0	0	0	0	0	2	0	9	0	3
3	0	0	0	0	1	0	2	1	2	10	2
5	0	0	0	0	1	0	0	4	1	1	9

Tablo 4. 6. LBP_{RB} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,35	0,078	0,304	0,35
0,438	0,034	0,5	0,438
0,929	0,01	0,867	0,929
0,762	0,049	0,615	0,762
0,3	0,059	0,333	0,3
0,238	0,099	0,2	0,238
0,818	0,009	0,818	0,818
0,333	0,049	0,412	0,333
0,571	0,054	0,522	0,571
0,529	0,039	0,529	0,529
0,476	0,025	0,667	0,476
0,429	0,054	0,45	0,429
0,491	0,05	0,496	0,491

Tablolara bakıldığında LBP_{RB} özniteliklerin başarısız sonuçlara neden olduğu görülmektedir. Bu öznitelikler ile ortalama %49,10 başarı oranı gözlenmiştir. Sınıflandırma işlemi LMT ile gerçekleştirilmiştir. En yüksek başarı oranı T3 üzüm türü için %92,9 olarak gözlenmiştir. En düşük başarı oranı ise T6 için %23,8 olarak

gözlenmiştir. LBP_{RB} özneliklerin başarısız olmasının nedeni özneliklerin düzensiz, dengesiz dağılımından kaynaklanmaktadır. Örnek görüntü için histogramına bakılabilir.

LBP_{GR} özneliklerini ile YSA sınıflandırma metodu kullanarak elde edilen karışıklık matrisi ve başarı oranları Tablo 4.7 ve Tablo 4.8’de verilmiştir.

Tablo 4. 7. LBP_{GR} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
9	0	1	2	0	0	0	0	0	0	3	5
1	15	0	0	0	0	0	0	0	0	0	0
0	0	12	0	0	0	0	0	2	0	0	0
1	1	0	19	0	0	0	0	0	0	0	0
0	1	0	1	14	2	0	1	0	0	0	1
0	1	0	0	1	18	0	0	0	1	0	0
1	0	0	0	0	1	9	0	0	0	0	0
0	0	0	1	0	0	1	17	1	0	1	0
0	0	1	0	2	0	0	0	16	0	1	1
0	0	0	0	1	1	0	0	0	13	2	0
3	0	0	1	0	1	0	0	1	1	13	1
1	0	0	1	3	1	0	1	0	0	1	13

Tablo 4. 8. LBP_{GR} özelliklerin YSA ile performans sonuçlar

TP Oran	FP Oran	Kesinlik	Hatırlama
0,45	0,034	0,563	0,45
0,938	0,014	0,833	0,938
0,857	0,01	0,857	0,857
0,905	0,03	0,76	0,905
0,7	0,034	0,667	0,7
0,857	0,03	0,75	0,857
0,818	0,005	0,9	0,818
0,81	0,01	0,895	0,81
0,762	0,02	0,8	0,762
0,765	0,01	0,867	0,765
0,619	0,039	0,619	0,619
0,619	0,039	0,619	0,619
0,75	0,024	0,749	0,75

LBP_{GR} öznelikleri ile YSA sınıflandırma metodu kullanarak elde edilen ortalama başarı oranı %75’tir. En düşük başarı oranı T1 üzüm türü için %45,00 olarak gözlenmiştir. En yüksek başarı oranı %93,80 ile T2 için gözlenmiştir.

Şimdi LBP_{GG} özneliklerini kullanarak YSA ile sınıflandırma işlemi sonuçlara bakalım. Elde edilen sonuçlar Tablo 4.9 ve Tablo 4.10’da verilmiştir.

Tablo 4. 9. LBP_{GG} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
16	0	0	1	1	0	0	0	0	0	0	2
0	14	0	0	0	2	0	0	0	0	0	0
0	0	11	0	0	1	0	0	0	1	0	1
1	0	0	18	0	0	0	1	0	1	0	0
0	0	0	1	15	1	0	0	1	0	1	1
0	2	2	0	0	12	0	0	0	5	0	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	2	1	0	1	16	1	0	0	0
0	1	1	0	0	0	0	1	18	0	0	0
0	0	0	1	0	2	0	0	0	12	2	0
1	0	0	2	1	0	0	0	0	1	15	1
1	0	1	0	1	0	0	0	0	0	0	18

Tablo 4. 10. LBP_{GG} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,8	0,015	0,842	0,8
0,875	0,014	0,824	0,875
0,786	0,019	0,733	0,786
0,857	0,034	0,72	0,857
0,75	0,02	0,789	0,75
0,571	0,034	0,632	0,571
0,909	0,005	0,909	0,909
0,762	0,01	0,889	0,762
0,857	0,01	0,9	0,857
0,706	0,039	0,6	0,706
0,714	0,015	0,833	0,714
0,857	0,025	0,783	0,857
0,781	0,02	0,786	0,781

LBP_{GG} öznelikleri ile %78,10 başarı oranı elde edilmiştir. En yüksek başarı oranı %90,90 ile T7 için elde edilmiştir. En kötü sınıflandırma başarı oranı T6 üzüm türü için %57,10 olarak gözlenmiştir.

LBP_{GB} öznelikleri ile LMT kullanarak elde edilen karışıklık matrisi ve performans değerleri Tablo 4.11 ve Tablo 4.12’de verilmiştir.

Tablo 4. 11. LBP_{GB} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
13	1	0	0	0	0	0	1	0	2	1	2
0	10	0	2	2	1	0	0	0	1	0	0
0	0	10	0	0	0	0	0	3	0	0	1
2	1	0	12	4	1	0	1	0	0	0	0
1	1	1	0	8	1	1	6	0	0	1	0
0	1	0	1	0	14	1	1	2	0	1	0
1	0	0	0	0	1	7	1	0	0	1	0
0	0	0	0	5	1	1	7	1	2	4	0
1	0	2	0	2	2	3	0	11	0	0	0
0	1	0	0	2	1	1	1	1	9	0	1
2	0	1	2	1	0	0	2	0	0	9	4
4	0	1	0	0	0	0	1	0	0	2	13

Tablo 4. 12. LBP_{GB} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,65	0,054	0,542	0,65
0,625	0,024	0,667	0,625
0,714	0,024	0,667	0,714
0,571	0,025	0,706	0,571
0,4	0,078	0,333	0,4
0,667	0,039	0,636	0,667
0,636	0,033	0,5	0,636
0,333	0,069	0,333	0,333
0,524	0,034	0,611	0,524
0,529	0,024	0,643	0,529
0,429	0,049	0,474	0,429
0,619	0,039	0,619	0,619
0,549	0,042	0,558	0,549

LBP_{GB} özneliklerini kullanarak LMT ile sınıflandırma işlemi gerçekleştirildi. Bu özellikler ile elde edilen ortalama başarı oranı %54,90 olarak gözlenmiştir. En yüksek başarı oranı %71,4 ile T3 için elde edilmiştir. En kötü sınıflandırma başarı oranı T5 üzüm türü için %40 olarak gözlenmiştir. Çok yüksek başarı oranı elde edilmemiştir. Bu da bu özelliklerin üzüm türünü teşhisinde yetersiz olduklarını göstermektedir.

LBP_{BR} öznelikleri ile LMT sınıflandırma yöntemi ile elde edilen karışıklık matrisi ve performans değerleri Tablo 4.13 ve Tablo 4.14'te verilmiştir.

Tablo 4. 13. LBP_{BR} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
8	3	0	1	0	1	0	0	0	0	3	4
0	10	0	0	2	1	0	2	0	1	0	0
0	0	11	0	0	0	1	0	1	0	0	1
0	0	0	19	0	0	0	1	0	0	1	0
1	1	0	3	6	3	0	1	2	1	0	2
3	1	1	3	1	4	1	1	6	0	0	0
2	0	0	0	0	1	8	0	0	0	0	0
0	1	1	2	3	5	1	4	0	2	2	0
0	0	0	1	0	4	0	0	15	1	0	0
2	1	0	0	3	1	0	4	0	4	0	2
2	0	0	0	1	2	1	3	1	1	9	1
5	0	0	0	2	3	1	1	2	2	0	5

Tablo 4. 14. LBP_{BR} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,4	0,074	0,348	0,4
0,625	0,034	0,588	0,625
0,786	0,01	0,846	0,786
0,905	0,049	0,655	0,905
0,3	0,059	0,333	0,3
0,19	0,103	0,16	0,19
0,727	0,023	0,615	0,727
0,19	0,064	0,235	0,19
0,714	0,059	0,556	0,714
0,235	0,039	0,333	0,235
0,429	0,03	0,6	0,429
0,238	0,049	0,333	0,238
0,46	0,052	0,449	0,46

Tablolara bakıldığında LBP_{BR} öznelikleri ile başarısız sonuçlar elde edildiği görülmektedir. Ortalama başarı oranı %46 olarak gözlenmiştir. En yüksek başarı oranı %90,05 ile T4 için elde edilmiştir. En kötü sınıflandırma başarı oranı T6 ve T8 üzüm türü için %19 olarak gözlenmiştir. Bu özelliklerin üzüm türünü teşhisinde yetersiz oldukları görülmüştür.

LBP_{BG} öznelikleri kullanarak LMT ile elde edilen başarı oranları ve performans ölçütlerine ait sonuçlar Tablo 4.15 ve Tablo 4.16'da verilmiştir.

Tablo 4. 15. LBP_{BG} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
12	2	0	1	0	0	0	0	0	1	1	3
0	10	0	1	1	3	0	0	0	1	0	0
0	0	8	0	0	0	0	1	4	0	1	0
1	0	0	17	0	0	0	3	0	0	0	0
1	1	1	1	6	3	0	3	3	1	0	0
0	1	1	0	1	12	1	0	5	0	0	0
1	0	0	0	0	1	9	0	0	0	0	0
0	1	0	4	6	0	1	5	0	2	2	0
1	0	0	0	2	3	1	0	14	0	0	0
1	1	0	0	2	1	0	1	0	8	1	2
1	3	0	3	0	0	0	4	1	1	6	2
6	0	0	0	1	0	0	1	0	1	0	12

Tablo 4. 16. LBP_{BG} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,6	0,059	0,5	0,6
0,625	0,043	0,526	0,625
0,571	0,01	0,8	0,571
0,81	0,049	0,63	0,81
0,3	0,064	0,316	0,3
0,571	0,054	0,522	0,571
0,818	0,014	0,75	0,818
0,238	0,064	0,278	0,238
0,667	0,064	0,519	0,667
0,471	0,034	0,533	0,471
0,286	0,025	0,545	0,286
0,571	0,034	0,632	0,571
0,531	0,045	0,531	0,531

LBP_{BG} öznelikleri ile yine düşük başarı oranları gözlenmiştir. Ortalama başarı oranı %53,10 olarak gözlenmiştir. En yüksek başarı oranı %81,8 ile T7 için elde edilmiştir. En kötü sınıflandırma başarı oranı T8 üzüm türü için %23,8 olarak gözlenmiştir. LBP_{BG} özneliklerin dengesiz dağılımından dolayı sonuçlar başarısız olarak gözlenmiştir.

LBP_{BB} öznelikleri kullanılarak YSA sınıflandırma metodu elde edilen başarı oranları Tablo 4.17 ve Tablo 4.18’de verilmiştir.

Tablo 4. 17. LBP_{BB} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
19	0	0	0	0	0	0	0	0	0	0	1
0	14	0	0	1	0	0	0	0	1	0	0
0	0	13	0	0	1	0	0	0	0	0	0
1	1	0	19	0	0	0	0	0	0	0	0
0	0	0	1	12	1	0	0	4	1	1	0
0	1	2	0	1	15	0	0	1	1	0	0
0	0	0	1	0	1	9	0	0	0	0	0
0	0	0	1	1	0	1	18	0	0	0	0
0	0	1	0	3	0	0	1	15	1	0	0
0	0	0	1	0	2	0	0	0	14	0	0
0	0	0	1	1	0	0	0	0	0	18	1
2	0	0	0	1	0	0	0	0	0	0	18

Tablo 4. 18. LBP_{BB} özelliklerin YSA ile performans sonuçlar

TP Oran	FP Oran	Kesinlik	Hatırlama
0,95	0,015	0,864	0,95
0,875	0,01	0,875	0,875
0,929	0,014	0,813	0,929
0,905	0,025	0,792	0,905
0,6	0,039	0,6	0,6
0,714	0,025	0,75	0,714
0,818	0,005	0,9	0,818
0,857	0,005	0,947	0,857
0,714	0,025	0,75	0,714
0,824	0,019	0,778	0,824
0,857	0,005	0,947	0,857
0,857	0,01	0,9	0,857
0,821	0,017	0,824	0,821

LBP_{BB} öznelikleri ile yüksek başarı oranı elde edilmiştir. Ortalama başarı oranı %82,10 olarak gözlenmiştir. En yüksek başarı oranı T1 üzüm türü için %95 olarak gözlenmiştir. En düşük başarı oranı ise T5 üzüm türü için gözlenmiştir. Sınıflandırma sonuçları YSA ile elde edilmiştir. Sonuç olarak en başarılı sonuçlar LBP_{BB} öznelikleri ile gözlenmiştir.

Şimdi klasik LBP ile elde edilen sonuçlara bakalım. Klasik LBP özneliklerini kullanarak YSA ile elde edilen başarı oranları Tablo 4.19 ve 4.20’de verilmiştir.

Tablo 4. 19. LBP özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
18	0	0	0	0	0	0	0	0	0	1	1
0	13	0	0	1	2	0	0	0	0	0	0
0	0	13	0	0	1	0	0	0	0	0	0
1	0	0	19	1	0	0	0	0	0	0	0
0	0	0	1	14	1	0	1	2	1	0	0
0	1	2	0	0	16	0	0	0	2	0	0
0	0	0	1	0	1	9	0	0	0	0	0
0	0	0	2	0	0	1	18	0	0	0	0
0	0	1	0	2	0	0	1	16	1	0	0
0	0	0	1	0	2	0	0	0	14	0	0
1	0	0	0	2	0	0	1	0	1	16	0
0	0	0	1	1	0	0	1	0	1	0	17

Tablo 4. 20. LBP özelliklerin YSA ile performans sonuçlar

TP Oran	FP Oran	Kesinlik	Hatırlama
0,9	0,01	0,9	0,9
0,813	0,005	0,929	0,813
0,929	0,014	0,813	0,929
0,905	0,03	0,76	0,905
0,7	0,034	0,667	0,7
0,762	0,034	0,696	0,762
0,818	0,005	0,9	0,818
0,857	0,02	0,818	0,857
0,762	0,01	0,889	0,762
0,824	0,029	0,7	0,824
0,762	0,005	0,941	0,762
0,81	0,005	0,944	0,81
0,817	0,017	0,828	0,817

Klasik LBP öznelikleri kullanılarak YSA ile ortalama %81,7 başarı oranı gözlenmiştir. En yüksek başarı oranı %92,90 ile T3 için elde edilmiştir. En kötü sınıflandırma başarı oranı T5 üzüm türü için %70 olarak gözlenmiştir. Başarılı bir sonuç olmak ile birlikte önerilen yöntemimizden daha başarılı değildir.

4.2. Uniform LBP ve Uniform LBP_{RGB} Sonuçları

Yapılan çalışmalarda görüntülerdeki yüzeylerinin büyük bir kısmının uniform örüntülerden oluştuğu görülmektedir. Uniform örüntüler, ikili LBP kodunda 0-1 ya da 1-0 geçiş sayısı 2 ya da daha az olanlardır. Örneğin 00000000 ve 11111111 örüntüleri 0 geçişe, 01100000 ve 11000011 örüntüleri 2 geçişe sahip olduklarından uniform

örüntülerdir. Uniform örüntüler, spot, kenar, köşe gibi basit dokuları da açıklayabilmekteler. Toplamda (P-1) P+2 uniform örüntü bulunmaktadır.

Şimdi tüm LBP operatörleri için elde edilen özniteliklerden sadece uniform örüntüleri kullanarak elde edilen başarı sonuçlarına bakalım.

LBP_{RR}^{U2} kullanarak elde edilen karışıklık matrisi ve başarı oranları Tablo 4.21 ve Tablo 4.22’de verilmiştir. Sınıflandırma işlemi YSA ile gerçekleştirilmiştir.

Tablo 4. 21. LBP_{RR}^{U2} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
14	0	0	1	1	0	0	0	0	1	1	2
0	13	0	0	1	1	0	0	0	1	0	0
0	0	13	0	0	1	0	0	0	0	0	0
1	0	0	18	1	0	0	1	0	0	0	0
1	0	0	0	14	1	0	0	1	0	2	1
0	0	3	0	1	14	0	1	0	1	1	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	1	1	0	1	18	0	0	0	0
0	1	1	0	1	0	0	1	16	0	1	0
0	1	0	1	0	1	0	0	0	14	0	0
2	0	0	0	2	0	0	0	0	1	16	0
2	0	0	0	1	0	0	1	0	1	1	15

Tablo 4. 22. LBP_{RR}^{U2} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,7	0,029	0,7	0,7
0,813	0,01	0,867	0,813
0,929	0,019	0,765	0,929
0,857	0,015	0,857	0,857
0,7	0,044	0,609	0,7
0,667	0,025	0,737	0,667
0,909	0,005	0,909	0,909
0,857	0,02	0,818	0,857
0,762	0,005	0,941	0,762
0,824	0,024	0,737	0,824
0,762	0,03	0,727	0,762
0,714	0,015	0,833	0,714
0,781	0,021	0,788	0,781

Tablo 4.21 ve Tablo 4.22’den görüldüğü gibi uniform öznitelikler kullanılarak ortalama %78,10 başarı oranı gözlenmiştir. En yüksek başarı oranı T3 üzüm türü için

%92,9 olarak elde edilmiştir. En düşük başarı oranı T6 üzüm türü için %66,7 olarak elde edilmiştir.

LBP_{RG}^{U2} öznelikleri ile elde edilen başarı oranları ve karışıklık matrisi Tablo 4.23 ve Tablo 4.24'te verilmiştir. Sınıflandırma işlemi YSA ile gerçekleştirilmiştir.

Tablo 4. 23. LBP_{RG}^{U2} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
12	0	0	1	1	2	1	0	0	0	1	2
0	14	0	0	0	2	0	0	0	0	0	0
0	0	11	0	1	0	0	0	2	0	0	0
0	0	0	20	1	0	0	0	0	0	0	0
1	1	0	2	15	1	0	0	0	0	0	0
0	1	0	0	1	17	0	0	1	1	0	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	1	0	0	1	16	2	0	1	0
0	0	1	0	2	0	0	1	17	0	0	0
0	1	0	0	1	1	0	1	0	12	1	0
1	0	0	1	0	1	0	1	0	1	15	1
1	0	0	2	3	1	0	0	1	0	0	13

Tablo 4. 24. LBP_{RG}^{U2} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,6	0,015	0,8	0,6
0,875	0,014	0,824	0,875
0,786	0,005	0,917	0,786
0,952	0,034	0,741	0,952
0,75	0,049	0,6	0,75
0,81	0,044	0,654	0,81
0,909	0,009	0,833	0,909
0,762	0,015	0,842	0,762
0,81	0,03	0,739	0,81
0,706	0,01	0,857	0,706
0,714	0,015	0,833	0,714
0,619	0,015	0,813	0,619
0,768	0,023	0,78	0,768

Tablolara bakıldığında LBP_{RG}^{U2} özellikleri ile %76,80 başarı oranı elde edilmiştir. En yüksek başarı oranı T4 üzüm türü için %95,2 olarak elde edilmiştir. En düşük başarı oranı T1 üzüm türü için %60 olarak elde edilmiştir. Üzüm türünün teşhisi için kabul edilebilir bir başarı oranıdır.

Şimdi LBP_{RR}^{U2} özniteliklerini kullanarak elde edilen sonuçlara bakalım. Karışıklık matrisi ve performans değerleri Tablo 4.25 ve Tablo 4.26’da verilmiştir.

Tablo 4. 25. LBP_{RR}^{U2} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
9	2	0	4	0	1	0	0	0	0	2	2
0	10	0	0	1	2	0	0	0	1	2	0
1	0	9	0	0	0	1	0	3	0	0	0
1	0	0	18	1	1	0	0	0	0	0	0
0	0	0	3	6	4	0	3	0	1	0	3
1	1	1	1	2	10	0	0	2	1	1	1
1	0	0	1	0	1	7	1	0	0	0	0
0	0	0	1	5	0	1	10	1	1	2	0
0	0	1	0	1	1	0	0	18	0	0	0
1	1	0	0	2	2	0	1	0	8	0	2
2	1	0	0	0	1	0	4	1	0	12	0
3	0	0	1	2	2	1	1	1	2	0	8

Tablo 4. 26. LBP_{RR}^{U2} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,45	0,049	0,474	0,45
0,625	0,024	0,667	0,625
0,643	0,01	0,818	0,643
0,857	0,054	0,621	0,857
0,3	0,069	0,3	0,3
0,476	0,074	0,4	0,476
0,636	0,014	0,7	0,636
0,476	0,049	0,5	0,476
0,857	0,039	0,692	0,857
0,471	0,029	0,571	0,471
0,571	0,034	0,632	0,571
0,381	0,039	0,5	0,381
0,558	0,043	0,559	0,558

LBP_{RR}^{U2} öznitelikler ile düşük başarılı sonuçlar elde edilmiştir. Ortalama %55,80 olarak gözlenmiştir. En yüksek başarı oranı T4 ve T9 üzüm türleri için %85,7 olarak elde edilmiştir. En düşük başarı oranı T5 üzüm türü için %30 olarak elde edilmiştir. Kabul edilebilir sonuçlar değil. LBP_{RR}^{U2} öznitelikler başarısız sonuçlar üretmiştir.

Şimdi LBP_{GR}^{U2} öznitelikleri kullanılarak elde edilen sonuçlara bakalım. Elde edilen sonuçlar Tablo 4.27 ve Tablo 4.28’de verilmiştir.

Tablo 4. 27. LBP_{GR}^{U2} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
14	0	0	1	0	1	0	0	0	0	0	4
1	15	0	0	0	0	0	0	0	0	0	0
0	0	12	0	0	0	0	1	1	0	0	0
1	0	0	16	0	0	0	0	1	0	0	3
1	1	0	1	14	1	0	0	0	0	0	2
0	1	0	0	1	17	0	0	1	1	0	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	1	0	0	1	19	0	0	0	0
0	0	1	0	2	0	0	1	15	0	1	1
0	0	0	0	0	2	0	1	0	14	0	0
1	0	0	1	0	0	0	1	0	1	16	1
3	0	0	1	4	0	0	0	0	0	0	13

Tablo 4. 28. LBP_{GR}^{U2} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,7	0,034	0,667	0,7
0,938	0,01	0,882	0,938
0,857	0,005	0,923	0,857
0,762	0,025	0,762	0,762
0,7	0,034	0,667	0,7
0,81	0,025	0,773	0,81
0,909	0,005	0,909	0,909
0,905	0,02	0,826	0,905
0,714	0,015	0,833	0,714
0,824	0,01	0,875	0,824
0,762	0,005	0,941	0,762
0,619	0,054	0,542	0,619
0,781	0,021	0,789	0,781

LBP_{GR}^{U2} öznelikler kullanılarak ortalama %78,10 başarı oranı gözlenmiştir. En yüksek başarı oranı T2 üzüm türü için %93,8 olarak elde edilmiştir. En düşük başarı oranı T12 üzüm türü için %61,9 olarak elde edilmiştir. Kabul edilebilir bir başarı oranıdır.

Tablo 4.29 ve Tablo 4.30'da LBP_{GG}^{U2} öznelikleri kullanılarak YSA ile elde edilen sonuçlar verilmiştir.

Tablo 4. 29. LBP_{GG}^{U2} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
15	0	0	1	0	0	0	0	0	1	1	2
0	12	0	0	2	2	0	0	0	0	0	0
0	0	13	0	0	1	0	0	0	0	0	0
0	0	0	18	1	0	0	2	0	0	0	0
0	1	0	0	15	1	0	0	1	0	1	1
0	1	0	0	1	16	0	0	2	1	0	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	1	0	0	1	19	0	0	0	0
0	0	1	0	2	1	0	1	15	1	0	0
0	1	0	0	0	1	0	1	0	14	0	0
2	0	0	0	2	0	0	1	0	1	14	1
0	1	1	0	1	0	0	0	0	1	0	17

Tablo 4. 30. LBP_{GG}^{U2} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,75	0,01	0,882	0,75
0,75	0,019	0,75	0,75
0,929	0,01	0,867	0,929
0,857	0,01	0,9	0,857
0,75	0,044	0,625	0,75
0,762	0,034	0,696	0,762
0,909	0,005	0,909	0,909
0,905	0,025	0,792	0,905
0,714	0,015	0,833	0,714
0,824	0,024	0,737	0,824
0,667	0,01	0,875	0,667
0,81	0,02	0,81	0,81
0,795	0,019	0,803	0,795

LBP_{GG}^{U2} öznelikler kullanılarak ortalama %79,50 başarı oranı gözlenmiştir. En yüksek başarı oranı T3 üzüm türü için %92,9 olarak elde edilmiştir. En düşük başarı oranı T6 üzüm türü için %66,7 olarak elde edilmiştir. Kabul edilebilir bir başarı oranıdır.

Tablo 4.31 ve Tablo 4.32’de LBP_{GB}^{U2} öznelikleri kullanılarak LMT ile elde edilen sonuçlar verilmiştir.

Tablo 4. 31. LBP_{GB}^{U2} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
11	1	0	2	0	0	0	0	0	1	2	3
0	7	0	2	0	4	0	0	0	1	2	0
0	0	11	0	0	0	0	1	1	0	0	1
1	1	0	17	2	0	0	0	0	0	0	0
1	0	0	1	6	5	0	7	0	0	0	0
0	2	0	2	2	10	0	1	4	0	0	0
2	0	0	0	0	1	7	1	0	0	0	0
0	0	0	0	4	2	1	9	1	4	0	0
0	0	0	0	2	3	1	1	13	1	0	0
0	0	0	0	0	2	1	2	0	8	3	1
3	1	0	1	0	0	0	5	0	3	7	1
1	0	1	0	2	0	1	0	0	3	0	13

Tablo 4. 32. LBP_{GB}^{U2} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,55	0,039	0,579	0,55
0,438	0,024	0,583	0,438
0,786	0,005	0,917	0,786
0,81	0,039	0,68	0,81
0,3	0,059	0,333	0,3
0,476	0,084	0,37	0,476
0,636	0,019	0,636	0,636
0,429	0,089	0,333	0,429
0,619	0,03	0,684	0,619
0,471	0,063	0,381	0,471
0,333	0,034	0,5	0,333
0,619	0,03	0,684	0,619
0,531	0,045	0,545	0,531

LBP_{GB}^{U2} ile başarısız sonuçların elde edildiği görülmektedir. Ortalama %53,10 sınıflandırma başarısı elde edilmiştir. En yüksek başarı oranı T4 üzüm türü için %81 olarak elde edilmiştir. En düşük başarı oranı T5 üzüm türü için %30 olarak elde edilmiştir. Kabul edilebilir sonuçlar değildir.

Tablo 4.33 ve Tablo 4.34’de LBP_{RR}^{U2} öznitelikleri kullanılarak LMT ile elde edilen sonuçlar verilmiştir.

Tablo 4. 33. LBP_{BR}^{U2} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
11	1	0	1	0	1	1	0	0	0	3	2
0	12	0	1	1	1	0	0	0	0	1	0
0	0	11	0	0	0	0	0	2	1	0	0
0	0	0	17	1	1	0	0	0	0	2	0
1	1	0	2	6	5	0	1	2	1	1	0
1	1	1	1	2	6	1	0	4	1	2	1
1	0	0	0	0	1	9	0	0	0	0	0
0	2	0	2	2	1	1	10	0	0	2	1
0	0	1	0	1	1	0	1	17	0	0	0
1	1	0	0	2	2	0	2	0	4	0	5
2	0	0	0	0	0	0	4	1	1	13	0
5	0	0	1	0	1	0	0	2	3	0	9

Tablo 4. 34. LBP_{BR}^{U2} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,55	0,054	0,5	0,55
0,75	0,029	0,667	0,75
0,786	0,01	0,846	0,786
0,81	0,039	0,68	0,81
0,3	0,044	0,4	0,3
0,286	0,069	0,3	0,286
0,818	0,014	0,75	0,818
0,476	0,039	0,556	0,476
0,81	0,054	0,607	0,81
0,235	0,034	0,364	0,235
0,619	0,054	0,542	0,619
0,429	0,044	0,5	0,429
0,558	0,043	0,544	0,558

LBP_{RR}^{U2} öznelikleri en başarısız sonuçlar gözlenmiştir. %55,80 sınıflandırma başarısı gözlenmiştir. En yüksek başarı oranı T7 üzüm türü için %81,8 olarak elde edilmiştir. En düşük başarı oranı T10 üzüm türü için %23,5 olarak elde edilmiştir. Kabul edilebilir sonuçlar değil. LBP_{RR}^{U2} öznelikleri dengesiz bir dağılım göstermektedir.

Tablo 4.35 ve Tablo 4.36'da LBP_{BG}^{U2} öznelikleri kullanılarak LMT ile elde edilen sonuçlar verilmiştir.

Tablo 4. 35. LBP_{BG}^{U2} özelliklerin LMT ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
7	2	0	3	0	0	0	0	0	1	2	5
0	12	0	0	2	0	0	0	0	0	2	0
0	0	10	0	0	0	0	0	3	0	0	1
0	0	0	17	2	0	0	1	0	0	1	0
1	1	0	2	4	4	0	5	3	0	0	0
0	2	1	0	3	12	0	0	2	1	0	0
1	0	0	0	0	1	9	0	0	0	0	0
0	0	0	4	2	1	1	10	1	0	2	0
0	0	2	0	0	1	0	0	18	0	0	0
2	2	0	0	1	0	0	0	0	10	2	0
1	2	0	2	1	0	0	2	0	2	7	4
5	0	0	0	1	0	0	1	0	1	1	12

Tablo 4. 36. LBP_{BG}^{U2} özelliklerin LMT ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,35	0,049	0,412	0,35
0,75	0,043	0,571	0,75
0,714	0,014	0,769	0,714
0,81	0,054	0,607	0,81
0,2	0,059	0,25	0,2
0,571	0,034	0,632	0,571
0,818	0,005	0,9	0,818
0,476	0,044	0,526	0,476
0,857	0,044	0,667	0,857
0,588	0,024	0,667	0,588
0,333	0,049	0,412	0,333
0,571	0,049	0,545	0,571
0,571	0,042	0,56	0,571

LBP_{BG}^{U2} öznitelikleri en başarısız sonuçlar gözlenmiştir. %57,71 sınıflandırma başarısı gözlenmiştir. Kabul edilebilir sonuçlar değil. LBP_{BG}^{U2} öznitelikleri dengesiz bir dağılım göstermektedir.

Tablo 4.37 ve Tablo 4.38’de LBP_{RR}^{U2} öznitelikleri kullanılarak YSA ile elde edilen sonuçlar verilmiştir.

Tablo 4. 37. LBP_{BB}^{U2} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
17	1	0	0	1	0	0	0	0	0	0	1
0	14	0	0	1	0	0	0	0	1	0	0
0	0	13	0	0	1	0	0	0	0	0	0
0	1	0	16	1	0	0	2	0	1	0	0
0	1	0	1	13	2	0	1	2	0	0	0
1	2	0	0	0	13	0	0	1	4	0	0
0	0	0	1	0	1	9	0	0	0	0	0
0	0	0	1	1	0	1	18	0	0	0	0
0	0	1	0	3	0	0	1	15	1	0	0
0	0	0	1	0	5	0	0	0	11	0	0
0	0	0	1	1	0	0	0	1	0	16	2
2	0	0	1	0	0	0	0	0	0	2	16

Tablo 4. 38. LBP_{BB}^{U2} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,85	0,015	0,85	0,85
0,875	0,024	0,737	0,875
0,929	0,005	0,929	0,929
0,762	0,03	0,727	0,762
0,65	0,039	0,619	0,65
0,619	0,044	0,591	0,619
0,818	0,005	0,9	0,818
0,857	0,02	0,818	0,857
0,714	0,02	0,789	0,714
0,647	0,034	0,611	0,647
0,762	0,01	0,889	0,762
0,762	0,015	0,842	0,762
0,763	0,023	0,769	0,763

LBP_{RR}^{U2} öznelikleri kabul edilebilir sonuçlar göstermiştir. %76,30 sınıflandırma başarısı gözlenmiştir. LBP_{RR}^{U2} öznelikleri dengesiz bir dağılım göstermektedir.

Şimdi klasik LBP^{U2} ile elde edilen sonuçlara bakalım. Tablo 4.39 ve Tablo 4.40'ta LBP^{U2} öznelikleri kullanılarak YSA ile elde edilen sonuçlar verilmiştir.

Tablo 4. 39. LBP^{U2} özelliklerin YSA ile başarı oranları

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
15	0	0	2	0	0	0	0	0	1	0	2
0	13	0	0	1	2	0	0	0	0	0	0
0	0	13	0	0	1	0	0	0	0	0	0
1	0	0	17	1	0	0	2	0	0	0	0
0	1	0	0	13	1	0	1	2	0	1	1
0	1	0	0	0	16	0	0	2	1	1	0
0	0	0	0	0	1	10	0	0	0	0	0
0	0	0	1	0	0	1	19	0	0	0	0
0	1	1	0	3	0	0	1	15	0	0	0
0	1	0	0	0	1	0	1	0	14	0	0
1	0	0	0	2	0	0	1	0	1	15	1
0	0	0	1	1	0	0	0	0	1	0	18

Tablo 4. 40. LBP^{U2} özelliklerin YSA ile performans sonuçları

TP Oran	FP Oran	Kesinlik	Hatırlama
0,75	0,01	0,882	0,75
0,813	0,019	0,765	0,813
0,929	0,005	0,929	0,929
0,81	0,02	0,81	0,81
0,65	0,039	0,619	0,65
0,762	0,03	0,727	0,762
0,909	0,005	0,909	0,909
0,905	0,03	0,76	0,905
0,714	0,02	0,789	0,714
0,824	0,019	0,778	0,824
0,714	0,01	0,882	0,714
0,857	0,02	0,818	0,857
0,795	0,02	0,799	0,795

LBP^{U2} ile %79,50 başarı oranı elde edilmiştir. Kabul edilebilir bir sonuçtur. En yüksek başarı T3 üzüm türü için %92,9 olarak gözlenmiştir. En düşük başarı T5 üzüm türü için %65 olarak elde edilmiştir.

4.3. Yöntemlerin Karşılaştırılması

LBP_{RGB} yöntemi 9 farklı kombinasyonda LBP operatörü oluşturulabilir. Bu dokuz yöntem ile farklı öznelik matrisleri oluşturulur. Bu dokuz veri seti ve klasik LBP veri seti için elde edilen başarı oranları Tablo 4.41'de verilmiştir. Tabloda uniform özelliklere ait sonuçlar da verilmiştir.

Tablo 4. 41. Yöntemlerin Karşılaştırılması

Veri Seti	Başarı %	TP Oran	FP Oran	Kesinlik	Hatırlama
LBP_{RR}	77,70	0,8	0,005	0,941	0,8
LBP_{RG}	74,10	0,6	0,044	0,571	0,6
LBP_{RB}	49,10	0,35	0,078	0,304	0,35
LBP_{GR}	75,00	0,45	0,035	0,563	0,45
LBP_{GG}	78,10	0,8	0,015	0,842	0,08
LBP_{GB}	54,90	0,65	0,054	0,542	0,65
LBP_{BR}	46,00	0,4	0,074	0,348	0,4
LBP_{BG}	53,10	0,6	0,059	0,5	0,6
LBP_{BB}	82,10	0,95	0,015	0,864	0,95
LBP	81,70	0,9	0,01	0,9	0,9
LBP_{RR}^{U2}	78,10	0,7	0,029	0,7	0,7
LBP_{RG}^{U2}	76,80	0,6	0,015	0,8	0,6
LBP_{RB}^{U2}	55,80	0,45	0,049	0,474	0,45
LBP_{GR}^{U2}	78,10	0,7	0,034	0,667	0,7
LBP_{GG}^{U2}	79,50	0,75	0,01	0,882	0,75
LBP_{GB}^{U2}	53,10	0,55	0,039	0,579	0,55
LBP_{BR}^{U2}	55,80	0,55	0,54	0,5	0,55
LBP_{BG}^{U2}	57,10	0,35	0,049	0,412	0,35
LBP_{RR}^{U2}	76,30	0,85	0,015	0,85	0,85
LBP^{U2}	79,50	0,75	0,01	0,882	0,75

Tabloya bakıldığında en yüksek başarı oranı LBP_{BB} öznelikleri ile elde edilmiştir. Önerilen yöntem ile elde edilmiştir. En yüksek başarı oranı %82,10 olarak gözlenmiştir.



5. TARTIŞMA

Bu tez çalışmasında üzümlerin sınıflandırılması için klasik yöntemlere alternatif bilgisayar görü tabanlı bir yöntem önerilmiştir. Bu amaçla üzüm türlerinin çekirdek görüntüleri kullanılmıştır. Çok fazla sayıda çeşide sahip üzüm bütün dünyada yetiştirilen en önemli tarımsal ürünler arasında yer almaktadır. Gözlem yapılarak bitki türlerinin sınıflandırılması çok güçlü bir botanik bilgisi gerektirmektedir. Bu durum çoğu zaman botanik bilimcileri için bile çok zor bir alan olmuştur. Ayrıca alanında uzman botanikçilerin sayısındaki azalma bitki türlerinin tanımlanması için görüntü işleme ve ilişkilerin tanımlanmasına dayalı teknikler gibi farklı yöntemlerin kullanımını zorunlu hale getirmiştir. Ayrıca kamera sistemlerinin ve diğer portatif cihazların geliştirilmesi gibi konuyla ilgili farklı alanlardaki gelişmeler bu düşüncenin uygulanabilirliğini artırmıştır.

Tohum, döllenen sonra tohum taslağının gelişmesiyle meydana gelir. Bir tohumda içten dışa doğru embriyo, besin dokusu ve tohum kabuğu olmak üzere üç kısım bulunur. Embriyo kesesindeki yumurta hücresinin döllenişle oluşan yapıya zigot denir. Zigotun gelişerek oluşturduğu yapıya ise embriyo denir. Tohumun canlı olan kısmıdır. Tez çalışmasında kullanılan görüntüler Siirt ilinin farklı lokasyonlarından toplanmış üzüm türlerinden elde edilmiştir. Araziden toplanan üzüm örnekleri laboratuvar ortamına getirilmiştir. Üzüm çekirdekleri pens yardımı ile çıkarılmış etil alkol (%70) ile temizlenerek kurutulmuştur.

Önerilen bilgisayar görü sistem ile üzüm çekirdek görüntülerinden o üzümün türünü tespit edip ve sınıflandırılmıştır. Çalışmada ilk olarak üzüm çekirdek görüntülerinden doku ve renk özellikler elde edilmiştir. Elde edilen bu özellikler makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Bilgisayar görü sistemlerinde ve görüntü işlemede doku analizi önemli bir yer tutar.

Son yıllarda doku analizi için çeşitli yaklaşımlar önerilmiştir. Bu yaklaşımların çoğu yapısal, model temelli, istatistiksel (histogram, mutlak gradyan, çalışma uzunluğu matrisi, ortak oluşum matrisi, oto-regresif model, dalgacıklar) ve dönüşüm bazlı yöntemlere (Castellano ve ark., 2004; Maani ve ark., 2013; Zhu ve ark., 2015) dayanmaktadır.

Uygulamada en yaygın kullanılan yöntemler Local Binary pattern (LBP), Grey Level Co-occurrence Matrix (GLCM) yöntemleridir. LBP, Ojala ve ark. (1996) tarafından önerilmiş doku sınıflandırma için kullanılan etkili en basit istatistiksel yaklaşımlardan biridir. Bir görüntünün veya görüntüdeki bir yerel yapının istatistiksel

olarak yoğunluğunu belirtir. LBP görüntüdeki her pikseli, pikselin etrafında dairesel olarak oluşan komşu pikseller ile karşılaştırır (Pan ve ark., 2017).

LBP yaklaşımı, merkez pikselin ve komşularının yerel farklılıklarının merkezi pikselin kendisinden bağımsız olduğu varsayımına dayanmaktadır. Pikseller arasındaki ilişkiler ikili örüntüler ile ifade edilir. LBP'nin başlıca avantajları: (1) güçlü bir ayırdıcı, (2) diğer yöntemlere göre daha hesaplama maliyeti, (3) basit uygulanabilir olması önemli avantajlardır.

LBP'nin bilgisayar gözü uygulamalarındaki başarısına rağmen geleneksel LBP'nin bazı dezavantajları da bulunmaktadır. (1) uzun dengesiz dağılmış histogramlar üretilmektedir. (2) görüntü dönmeye bağımlıdır, (3) Gürültüye duyarlı ve büyük ölçekli dokuların algılanması zor olmaktadır. Bu durum etkili özelliklerin elde edilmesini zorlaştırmaktadır (Lian, 2015). Bu yüzden farklı geliştirilmiş çeşitli LBP yöntemler önerilmiştir. Bu çalışmada renkli görüntüler için LBP tabanlı yeni bir yaklaşım önerilmiştir. Görüntülerin RGB kanallarının birbirleri ile karşılaştırmalarına dayanan bir renk katmanlı bir yaklaşım ile üzüm çekirdek görüntülerinden üzüm türü teşhisi gerçekleştirilmiştir. Bu yaklaşım renkli görüntülere uygulanmaktadır. Bir görüntünün her renk (RGB) kanalındaki her piksel kendi renk kanalı veya diğer bir kanaldaki yansıması olan piksel etrafındaki komşular ile karşılaştırılarak LBP operatörü oluşturulmaktadır. Önerilen yöntem renkli görüntülerin tüm kanallarında ayırt edici özellikler taramaktadır. Oluşturulan bu yeni yaklaşım ile klasik yerel ikili örüntülerin kullanıldığı gri renklere ek olarak kırmızı, yeşil ve mavi renk kümelerinden yararlanılmıştır. Uygulanması klasik yerel ikili örüntülerden farklılık göstermektedir. RGB renk katman sayısından dolayı bu yöntem ile 9 farklı veri seti elde edilmektedir. RR, GG, BB, RG, RB, GB, GR, BR ve BG gibi 9 farklı kanal karşılaştırmalarından dolayı farklı LBP operatörler elde edile bilinmektedir.

Farklı renk kanallarından elde edilen örüntüler birbirinden farklılık göstermektedir. Hem LBP görüntülerinden hem de histogramlardan bu farklılıklar görülmektedir. Bu farklı örüntülerin üzüm teşhisinde başarılı olup olmadığı sınıflandırma metotları ile anlaşılabilir. Elde edilen bu örüntüleri özellik vektörleri olarak düşünerek sınıflandırma metotlarına verildi. Farklı sınıflandırma metotları denenmiştir. Sınıflandırma için açık kaynak bir program olan Weka yazılımı kullanılmıştır. Farklı sınıflandırma metotları denenmiştir. YSA, LMT, Bayes, Naive Bayes, Random Forest gibi sınıflandırma metotları denenmiştir. Çalışmada LBP_{RGB} operatörleri ile elde edilen tüm özneliklerin kullanılması gözlenen sonuçların yanında

sadece uniform özniteliklerin kullanılması ile elde edilen sonuçlar da paylaşılmıştır. En yüksek başarı oranı LBP_{BB} öznitelikleri ile YSA sınıflandırmasında elde edilmiştir. Önerilen yöntem ile elde edilmiştir. En yüksek başarı oranı %82,10 olarak gözlenmiştir. En düşük başarı ise LBP_{RB} özniteliklerin kullanılması ile %49,10 olarak gözlenmiştir. Üzüm türlerin genel sınıflandırma başarılarına bakıldığında en yüksek başarı oranları T1 (Aşkar), T2 (Bınatati), T3 (C Nator), T4 (Cevzane) ve T7 (Hazirani) türleri için gözlenmiştir.





6. KAYNAKLAR

- Abbasi, S., Tajeripour, F., 2017. Detection of brain tumor in 3D MRI images using local binary patterns and histogram orientation gradient, *Neurocomputing*, 219, 526-535.
- Ahonen, T., Hadid, A., Pietikainen, M., 2006. Face description with local binary patterns: Application to face recognition, *IEEE transactions on pattern analysis and machine intelligence*, 28 (12), 2037-2041.
- Ahonen, T., Pietikäinen, M., 2007. Soft histograms for local binary patterns, *In Proceedings of the Finnish signal processing symposium, FINSIG* (Vol. 5, 1).
- Castellano, G., Bonilha, L., Li, L.M., Cendes, F., 2004. Texture analysis of medical images, *Clin, Radiol*, 59, 1061–1069.
- Cernadas, E., M. Fernández-Delgado, E., González-Rufino, P., Carrión, 2017. Influence of normalization and color space to color texture classification, *Pattern Recognition* 61 : 120-138.
- Gu, J., Liu, C., 2013. Feature local binary patterns with application to eye detection, *Neurocomputing*, 113, 138-152.
- Guo, Z., Zhang, D., 2010. A completed modeling of local binary pattern operator for texture classification, *Image Processing, IEEE Transactions on*, Vol. 19 (6), 1657-1663.
- Hadizadeh, H., 2015. Multi-resolution local Gabor wavelets binary patterns for gray-scale texture description, *Pattern Recognition Letters*, 65, 163-169.
- Kaddar, B., Fizazi, H., Boudraa, A. O., 2017. Texture features based on an efficient local binary pattern descriptor, *Computers & Electrical Engineering*.
- Kaya, Y., Ertuğrul, Ö. F., Tekin, R., 2015. Two novel local binary pattern descriptors for texture analysis, *Applied Soft Computing*, 34, 728-735.
- Kaya, Y., Ertuğrul, Ö. F., Tekin, R., 2015. Two novel local binary pattern descriptors for texture analysis, *Applied Soft Computing*, 34, 728-735.
- Kim, J., Yu, S., Kim, D., Toh, K. A., Lee, S., 2017. An adaptive local binary pattern for 3d hand tracking, *Pattern Recognition*, 61, 139-152.
- Lian, G., 2015. Rotation invariant color texture classification using multiple sub-DLBPs, *Journal of Visual Communication and Image Representation*, 31, 1-13.
- Liao, S., Law, M. W., Chung, A. C., 2009. Dominant local binary patterns for texture classification, *IEEE transactions on image processing*, 18 (5), 1107-1118.
- Liu, D., Wang, S., Huang, D., Deng, G., Zeng, F., Chen, H., 2016. Medical image classification using spatial adjacent histogram based on adaptive local binary patterns, *Computers in biology and medicine*, 72, 185-200.

- Liu, L., Zhao, L., Long, Y., Kuang, G., Fieguth, P., 2012. Extended local binary patterns for texture classification, *Image and Vision Computing*, Vol. 30 (2), 86-99.
- Maani, R., Sanjay K., Yee-Hong Y., 2013. Noise robust rotation invariant features for texture classification, *Pattern Recognition* 46.8: 2103-2116.
- Mahale, V. H., Ali, M. M., Yannawar, P. L., Gaikwad, A. T., 2017. Image Inconsistency Detection Using Local Binary Pattern (LBP), *Procedia Computer Science*, 115, 501-508.
- Nanni, L., Lumini, A., Brahnam, S., 2010. Local binary patterns variants as texture descriptors for medical image analysis, *Artificial intelligence in medicine*, 49 (2), 117-125.
- Ojala, T., Pietikainen, M., Maenpaa, T., 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24 (7), 971-987.
- Pan, Z., Li, Z., Fan, H., Wu, X., 2017. Feature based local binary pattern for rotation invariant texture classification, *Expert Systems with Applications*, 88, 238-248.
- Patel, B., Maheshwari, R. P., Balasubramanian, R., 2016. Multi-quantized local binary patterns for facial gender classification. *Computers & Electrical Engineering*, 54, 271-284.
- Patel, B., Maheshwari, R. P., Raman, B., 2016. Compass local binary patterns for gender recognition of facial photographs and sketches, *Neurocomputing*, 218, 203-215.
- Peyret, R., Bouridane, A., Khelifi, F., Tahir, M. A., Al-Maadeed, S., 2017. Automatic classification of colorectal and prostatic histologic tumor images using multiscale multispectral local binary pattern texture features and stacked generalization, *Neurocomputing*.
- Pourreza, A., Pourreza, H., Abbaspour-Fard, M. H., Sadrnia, H., 2012. Identification of nine Iranian wheat seed varieties by textural analysis with image processing, *Computers and electronics in agriculture*, 83, 102-108.
- Shan S. G., Zhang W. C., Su Y., Chen X. L., Gao W., 2006. Ensemble of piecewise FDA based on spatial histograms of local (Gabor) binary patterns for face recognition, *In: Proceedings of the 18th International Conference on Pattern Recognition. Hong Kong, China: IEEE*, 606-609.
- Tan, X., Triggs, B., 2010. Enhanced local texture feature sets for face recognition under difficult lighting conditions, *Image Processing, IEEE Transactions on*, Vol. 19 (6), 1635-1650.

- Wan, S., Lee, H. C., Huang, X., Xu, T., Xu, T., Zeng, X., 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, Z., Liu, S., Mei, X., Xiao, B., Zheng, L. 2017. Learning completed discriminative local features for texture classification, *Pattern Recognition*, 67, 263-275.
- Zhao, G., Pietikainen, M., 2007. Dynamic texture recognition using local binary patterns with an application to facial expressions. *IEEE transactions on pattern analysis and machine intelligence*, 29 (6), 915-928.
- Zhou, S. R., Yin, J. P., Zhang, J. M., 2013. Local binary pattern (LBP) and local phase quantization (LBQ) based on Gabor filter for face representation, *Neurocomputing*, Vol. 116, 260-264.
- Ziqi Zhu, Xinge You, C.L. Philip Chen, Dacheng Tao, Weihua Ou, Xiubao Jiang, Jixin Zou, 2015. An adaptive hybrid pattern for noise-robust texture analysis, *Pattern Recognition* 48.8: 2592-2608.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Burhan ÖZDEMİR
Doğum Yeri ve Tarihi : Silopi - 20.05.1986
Telefon : 90 (484) 212 11 11 /3653
E-posta : burhanozdemir.01@gmail.com

EĞİTİM

Derece		Bitirme Yılı
Lise	: Cizre Lisesi, CİZRE	2004
Üniversite	: Bakü Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, BAKÜ/AZERBAYCAN	2010

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2013-Devam Ediyor	Siirt Üniversitesi, Bilgi İşlem Daire Başkanlığı	Müh.

UZMANLIK ALANI: Web Yazılım

AKADEMİK ÇALIŞMALAR

Bildiri B. Özdemir & Y. Kaya (2017). Multilayer Local Binary Patterns for Grape Types Detection, *8th International Advanced Technology Symposium*, 958- 961.