



**MAKİNE GÖRMESİ TABANLI KALİTE
KONTROLÜ İÇİN ÖZELLİK
ÇIKARIM YÖNTEMLERİNİN GELİŞTİRİLMESİ**

Büşra AKARSU

**Yüksek Lisans Tezi
Mekatronik Anabilim Dalı
Danışman: Doç. Dr. Koray Şener PARLAK**

TEMMUZ-2018

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE GÖRMESİ TABANLI KALİTE KONTROLÜ İÇİN
ÖZELLİK ÇIKARIM YÖNTEMLERİNİN GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

Büşra AKARSU

142134104

**Tezin Enstitüye Verildiği Tarih: 07/07.2018
Tezin Savunulduğu Tarih: 26/07.2018**

Tez Danışmanı: Doç. Dr. Koray Şener PARLAK (F.Ü)

Diğer Jüri Üyeleri: Doç. Dr. M. Fatih TALU (İ.Ü)

Doç. Dr. Mehmet KARAKÖSE (F.Ü)

TEMMUZ-2018

ÖNSÖZ

Yapılan bu tez çalışmasında bilgi birikimi ve tecrübeleriyle daima bana yol gösteren ve desteğini esirgemeyen değerli danışman hocam, Sayın Doç. Dr. Koray Şener PARLAK ve Doç. Dr. Mehmet KARAKÖSE' ye teşekkürlerimi sunarım.

Eğitim hayatım boyunca sürekli benim yanımda olan ve hayatımın her aşamasında arkamda varlığını hissettiğim canım annem Hafize AKARSU ve canım babam Selahattin AKARSU' ya teşekkür ederim.

Çalışmalarında gerek bilgi birikiminden yararlandığım gerekse manevi olarak her zaman yanımda hissettiğim arkadaşım Arş. Gör. Gökçe YILDIRIM' a ve beni her zaman sabırla destekleyen aileme sonsuz teşekkürlerimi sunarım.

TEŞEKKÜR

Bu tez kapsamında yapılan çalışmalar 0743.STZ.2014 (112D021) nolu SAN-TEZ projesi ile desteklenmiştir. Bu destekleri sağlayan TÜBİTAK, T.C. Bilim, Sanayi ve Teknoloji Bakanlığı ile MEDEL Elektronik Elektrik Mak. Dem. Araç. Ürt. Ve Paz. San. ve Tic. Ltd. Şti. firmasına teşekkür ederim.

Büşra AKARSU

ELAZIĞ- 2018

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER.....	III
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	VIII
SEMBOLLER LİSTESİ	XI
KISALTMALAR LİSTESİ	XII
1. GİRİŞ	13
1.1. Özellik Çıkarımı	15
1.2. Kalite Kontrol İşlemlerinde Kullanılan Özellik Çıkarım Yöntemleri	18
1.2.1. Morfolojik Özellikler.....	22
1.2.2. Doku Özellikleri	23
1.2.3. Renk Özellikleri.....	24
1.3. Tezin Amacı ve Kapsamı	25
1.4. Tezin Yapısı.....	26
2. GÖRME TABANLI KALİTE KONTROL İÇİN ÖZELLİK ÇIKARIM	
YÖNTEMLERİNİN MATEMATİKSEL MODELLERİ	27
2.1. Görme Tabanlı Kalite Kontrol.....	27
2.1.1. Donanım	28
2.1.2. Yazılım	30
2.2. Özellik Çıkarım Yöntemleri	32
2.2.1. Yerel İkili Görüntü (LBP)	32
2.2.2. Gri seviye Eş-oluşum Matrisi (GLCM).....	34
2.2.3. Gabor Dalgacık Filtresi	38
3. LBP-GLCM-GABOR DALGACIK DOKU ANALİZİ TEKNİKLERİNİN	
KARŞILAŞTIRILMASI	41
3.1. Uygulamada Kullanılan Veri Tabanları	41
3.2. Karşılaştırılan Yöntemler	43
3.2.1. Gri Seviye Eş- Oluşum Matrisi (GLCM)	43
3.2.2. Yerel İkili Örüntü (LBP)	44

3.2.3. Gabor Dalgacık Filtresi	45
3.3. Sınıflandırma Sonuçları	46
3.3.1. GLCM.....	46
3.3.2. LBP	49
3.3.3. Gabor Dalgacık Filtresi	50
3.4. Sonuçların Değerlendirilmesi	52
4. YEREL İKİLİ SINIFLANIRICI KULLANILARAK GELİŞTİRİLMİŞ BİR YAKLAŞIM.....	56
4.1. Önerilen Yöntem	56
4.2. Deneysel Sonuçlar	58
4.3. Bölüm Değerlendirmesi.....	58
5. GRİ SEVİYE EŞ OLUŞUM MATRİSİ KULLANARAK ELDE EDİLEN YENİ BİR ÖZELLİK ÇIKARIM YÖNTEMİ.....	60
5.1. Önerilen Yöntem	60
5.2. Deneysel Sonuçlar	62
5.3. Bölüm Değerlendirmesi.....	66
6. GERÇEK ZAMANLI ÇALIŞABİLİR SİSTEM TASARIMI	68
6.1. Önerilen Yöntem	68
6.2. Deney Sonuçları	69
6.2. Bölüm Değerlendirmesi.....	70
7. SONUÇLAR.....	71
KAYNAKLAR	73
ÖZGEÇMİŞ	81
KAYNAKLAR	74
ÖZGEÇMİŞ.....	82

ÖZET

Bu tez çalışmasında makine görmesi tabanlı endüstriyel ürünlerin kalite kontrolü için kullanılan özellik çıkarım yöntemleri üzerine bir çalışma gerçekleştirilmiştir. Çalışma kapsamında literatürde en çok kullanılan yöntemler araştırılmıştır. Yüzey hatalarında doku analizi yöntemlerinin daha çok kullanıldığı görülmüştür. Bu yüzden çalışma doku analizi teknikleri kullanılarak gerçekleştirilmiştir. Kalite kontrol uygulamalarında en çok kullanılan yöntemlerden ikisi yerel ikili örüntü (LBP) ve Gri Seviye Eş-oluşum matrisleridir (GLCM) ve son dönem çalışmalarında Gabor Dalgacık Filtresi de sıklıkla kullanılmıştır. Yapılan çalışma kapsamında bu üç yöntemin iki farklı veri tabanı kullanılarak uygulama karşılaştırmaları gerçekleştirilmiştir. Bu veri tabanlarından birisi haddelenmiş çelik şeritlerin yüzey hatalarından diğer veri tabanı da kusurlu ve kusursuz kumaş görüntülerinden oluşmaktadır. Çalışmada temel yerel ikili örüntü metodunun geliştirilmesi için bir çalışma gerçekleştirilmiştir. Bu çalışmada GLCM için yeni bir özellik çıkarım yöntemi önerilmiştir. Çalışmada hem önerilen yöntemin tek başına kullanıldığında elde edilen sonuçlar hem de bölüm 3’de kullanılan özellikler ile birlikte elde edilen sonuçlar verilmiştir. Önerilen yöntemin iki veri tabanı için de iyi ayırıcı güce sahip olduğu görülmüştür. Son bölümde özellik seçim yöntemi kullanılarak doğruluk oranları yükseltilmiştir. Özellik seçimi işleminden sonra doğruluk oranlarının tüm yönler ve iki ayrı uzaklık için NEU veri tabanında %93’den, kumaş veri tabanında ise %90’dan daha iyi sonuçlar edilmiştir. Bu yüksek lisans tezi kapsamında geliştirilen çalışmalar TÜBİTAK ve T.C. Bilim, Sanayi ve Teknoloji Bakanlığı tarafından 0743.STZ.2014 (112D021) numaralı SAN-TEZ projesi ile desteklenmiştir.

Anahtar Kelimeler: Özellik Çıkarımı, Makine Görmesi, Kalite Kontrol, Gri Seviye Eş-oluşum Matrisi, Yerel İkili Örüntü, Gabor Dalgacık Filtresi

SUMMARY

DEVELOPMENT OF NEW FEATURE EXTRACTION METHOD FOR MACHINE VISION BASED MEASUREMENT AND QUALITY INSPECTION IN CONVEYED OBJECTS

In this thesis, proposed a new feature extraction method for machine vision based measurement and quality inspection in conveyed object. In the scope of the study, the most commonly used methods in the literature were investigated and find out texture analysis methods have been used frequently. So the study is based on texture analysis. Two of the most common methods used in quality control applications are local binary pattern and gray level co-occurrence matrices, and Gabor Wavelet Filter is often used in recent studies. Within the scope of the study, application of these three methods were compared using two different databases. One of these databases consists of surface defects of rolled steel strips and the other database consists of flawed and perfect fabric images. Then a study was conducted to develop the local binary pattern method. In the next section, a new feature extraction method is proposed for the GLCM method. In the study, both the results obtained when using the proposed method alone and the results obtained with the features used in Chapter 3 are given. In the last section, accuracy rates were increased by using property selection method. It was seen that the new method proposed for GLCM in feature selection process increased the accuracy rates. After the feature selection process, the accuracy rates were obtained higher than the 93% in the NEU database and 90% in the fabric database for all directions and two separate distances. The studies developed within the scope of this master thesis were supported by the SAN-TEZ project number 0743.STZ.2014 (112D021) by TUBITAK and the Ministry of Science, Industry and Technology.

Keywords: Feature Extraction, Machine Vision, Quality Control, Gray Level Co-occurrence Matrix, Local Binary Pattern, Gabor Wavelet Filter

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 1.1. Endüstriyel ürünlerin yüzey görüntüsüne göre literatürdeki sınıflandırılması ...	14
Şekil 1.2. Endüstriyel ürünlerin sınıflandırılması için kullanılan özellikler ve günümüze kadar kullanılmış temel özellik çıkarım yöntemleri	18
Şekil 2.1. Bilgisayar görmesi sistemlerinin bileşenleri	29
Şekil 2.2. Görme tabanlı kalite kontrol yöntemlerinin yazılım aşamasının akış şeması.....	30
Şekil 2.3. Temel yerel ikili örüntünün hesaplanmasının örneği.....	33
Şekil 2.4 P=8, R=1 olan genişletilmiş LBP operatörünün örneği	33
Şekil 2.5. d=2 iken GLCM için olası yön açılarının gösterimi	35
Şekil 2.6. Eş oluşum matrisinin oluşturulması sürecinin örneği	36
Şekil 3.1. Kullanılan iki veri tabanına ait görüntü örnekleri	42
Şekil 3.2. Oluşturulan veri seti örneği.....	42
Şekil 3.3. GLCM yöntemini uygulamasına ait örnek gösterim.....	44
Şekil 3.4. LBP yönteminin uygulanmasına ait örnek.....	45
Şekil 3.5. Gabor dalgacık yöntemi uygulamasına ait bir örnek	46
Şekil 4.1. Temel LBP operatörü ile komşu piksellerin bulunması.....	57
Şekil 4.2. Çalışmanın yapılmasına ait örnek	57
Şekil 5.1. GLCM yön örnekleri.....	61
Şekil 5.2. Eş- oluşum matrisi örneği	62
Şekil 6.1. Sınıflandırma için kullanılan yöntemin akış diyagramı	68

TABLÖLAR LİSTESİ

	<u>Sayfa No</u>
Tablo 1.1. Endüstriyel ürünlerin süreçlerine göre literatürdeki sınıflandırılması	13
Tablo 1.2. Kalite kontrol için literatürde kullanılmış özellik çıkarım yöntemleri ve uygulama alanları için örnek alanlar	21
Tablo 3.1. Uygulamada kullanılan GLCM yönteminin ayarları	43
Tablo 3.2. Uygulamada kullanılan LBP ayarları ve elde edilen çıktı boyutu	44
Tablo 3.3. Uygulamada kullanılan Gabor dalgacık filtesine ait ayarlar	45
Tablo 3.4. NEU veri tabanı kullanılarak GLCM' nin farklı ayarlarda elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	47
Tablo 3.5. NEU veri tabanı kullanılarak GLCM' nin farklı ayarlarda elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	47
Tablo 3.6. Kumaş veri tabanı kullanılarak GLCM' nin farklı ayarlarda elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	48
Tablo 3.7. Kumaş veri tabanı kullanılarak GLCM' nin farklı ayarlarda elde edilen özelliklerin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları	48
Tablo 3.8. NEU veri tabanı kullanılarak LBP' nin farklı ayarlarda elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	49
Tablo 3.9. NEU veri tabanı kullanılarak LBP' nin farklı ayarlarda elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	49
Tablo 3.10. Kumaş veri tabanı kullanılarak LBP' nin farklı ayarlarda elde edilen özelliklerin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları	50
Tablo 3.11. Kumaş veri tabanı kullanılarak LBP' nin farklı ayarlarda elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	50
Tablo 3.12. NEU veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	50
Tablo 3.13. NEU veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	51
Tablo 3.14. Kumaş veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	51

Tablo 3.15.	Kumaş veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	52
Tablo 3.16.	Karmaşıklık matrisi örneği.....	52
Tablo 3.17.	NEU veri tabanı kullanılarak iki farklı yönelimde uzaklık birken GLCM özellik çıkarım algoritmasının DVM sınıflandırıcısı kullanılarak elde edilen sonuçları	53
Tablo 3.18.	NEU veri tabanı kullanılarak farklı yönelimlerde uzaklık birken GLCM özellik çıkarım algoritmasının DVM sınıflandırıcısı kullanılarak elde edilen sonuçları	54
Tablo 4.1.	NEU veri tabanı kullanılarak önerilen yöntem ile elde edilen KNN ve DVM sınıflandırma sonuçları.....	58
Tablo 4.2.	Kumaş veri tabanı kullanılarak önerilen yöntem ile elde edilen KNN ve DVM sınıflandırma sonuçları.....	58
Tablo 5.1.	NEU veri tabanı veri tabanı kullanılarak GLCM' nin farklı ayarlarda önerilen yöntem ile elde edilen özelliğin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	63
Tablo 5.2.	NEU veri tabanı veri tabanı kullanılarak GLCM' nin farklı ayarlarda önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	63
Tablo 5.3.	Kumaş veri tabanı kullanılarak GLCM' nin farklı ayarlarda önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları	64
Tablo 5.4.	Kumaş veri tabanı kullanılarak GLCM' nin farklı ayarlarda önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları	64
Tablo 5.5.	NEU veri tabanı kullanılarak GLCM' nin farklı ayarlarda on yedi özellik ve önerilen yöntem ile elde edilen özelliğin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	65
Tablo 5.6.	NEU veri tabanı kullanılarak GLCM' nin farklı ayarlarda on yedi özellik ve önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	65
Tablo 5.7.	Kumaş veri tabanı kullanılarak GLCM' nin farklı ayarlarda önerilen yöntem ve on yedi özellik çıkarım yöntemi ile elde edilen özelliğin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları.....	66

Tablo 5.8.	Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda önerilen yöntem ve on yedi özellik çıkarım yöntemi ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları.....	66
Tablo 6.1.	Önerilen sistemden elde edilen kumaş veri seti DVM sınıflandırıcısı ile elde edilen sonuçları.....	69
Tablo 6.2.	Önerilen sistemden elde edilen kumaş veri seti KNN sınıflandırıcısı ile elde edilen sonuçları.....	69
Tablo 6.3.	Önerilen sistemden elde edilen NEU veri seti KNN sınıflandırıcısı ile elde edilen sonuçları.....	70
Tablo 6.4.	Önerilen sistemden elde edilen NEU veri seti KNN sınıflandırıcısı ile elde edilen sonuçları.....	70

SEMBOLLER LİSTESİ

$\mathbf{x}_c$	: LBP operatörü üzerindeki merkez piksel
$\mathbf{x}_p$	: LBP operatörü üzerindeki merkez pikselin komşuları
$\mathbf{R}$	: LBP operatöründeki merkez piksele uzak
$\mathbf{P}$	: LBP operatöründe işleme sokulan komşu sayısı
$\mathbf{u}(\mathbf{y})$	: LBP operatöründe merkez piksel ve komşuları arasında olan ilişki
$\mathbf{LBP}_{P,R}(\mathbf{x}_c)$	: LBP operatöründeki merkez piksel
$\mathbf{d}$	: GLCM operatöründeki iki piksel arasındaki uzaklık
θ	: GLCM operatöründeki iki piksel arasındaki açı
$\mathbf{i}, \mathbf{j}$	: İki pikselin yoğunluk değerleri
$\mathbf{P}(\mathbf{i}, \mathbf{j} \mid \Delta \mathbf{x}, \Delta \mathbf{y})$	: Matris elemanlarının meydana gelme sıklığı
$\mathbf{Q}$	: GLCM metodundaki özellik çıkarım yöntemleri
$\mathbf{g}(\mathbf{x}, \mathbf{y})$	: 2-D Gabor çekirdek
σ_x, σ_y	: Gaussian'ın büyük ve küçük genişliği
$\mathbf{W}$	: Gabor fonksiyonunun radial frekansı
$\psi_{mn}(\mathbf{x}, \mathbf{y})$	: Gabor dalgacık filtresi
$\mathbf{m}$	: Ölçek
$\mathbf{n}$	: Yönelim
$\mathbf{U}_h, \mathbf{U}_l$	: Üst ve alt frekans
μ_{ab}	: Ortalama
σ_{ab}	: Standart sapma

KISALTMALAR LİSTESİ

DVM	: Destek Vektör Makinaları
FFT	: Hızlı Fourier Dönüşümü
Fisher-LDA	: Fisher Doğrusal Diskriminant Analizi
GLCM	: Gri Seviye Eş-Oluşum Matrisi
KNN	: K En Yakın Komşu Algoritması
LBP	: Yerel İkili Örüntü
LDA	: Doğrusal Diskriminan Analizi
PCA	: Temel Bileşen Analizi



1. GİRİŞ

Endüstriyel ürünlerin kalite kontrol işleminin hızlı ve güvenilir bir şekilde gerçekleştirilmesi üretici açısından hem para hem de itibar kaybını önlenmesi için çok önemlidir. Görsel incelemeye dayalı insan algılaması uzun zamandır kalite için bir rehber olarak kabul edilmiştir ve ürün müşterilerin önyargılarına uymazsa satın alınma ihtimali büyük ölçüde azalır [1]. Bilim insanları görüntü üzerinden elde edilen bilgiler ile sınıflandırma yaparak hem hızlı hem de iyi sonuçlar elde edebileceğini çalışmalarında göstermişlerdir. Hızlı ve güvenilir sonuçlar elde edebilmesinin yanında elektronik bileşenlerin daha verimli hale gelmesi ve ucuzlaması yaygınlaşmasında olumlu koşullar yaratmıştır. Ayrıca ürünlerin sadece görüntüleri üzerinden bilgi elde ettiği için nesnel ve tahribatsız değerlendirme yapabilmektedir [2]. Bilgisayarla görme sistemleri ağırlıklı olarak kalite kontrol uygulamalarında kullanılmaktadır [3]. Bunun dışında endüstriyel faaliyetlerde makine görmesinden de faydalanılmaktadır [4]. Görsel kalite kontrol uygulamalarının en yaygın kullanım alanlarından biri yiyecek endüstrisi olmasına rağmen medikal, otomotiv, tekstil vb. birçok endüstri ürününün kalite kontrolü yapılmıştır ve bu konuda çalışmalar devam etmektedir. Endüstriyel ürünlerin denetlenme süreçlerine göre kusurları dört gruba ayrılır [4]. Tablo 1.1 'de kalite kontrol işlemindeki kusur çeşitleri verilmiştir.


Tablo 1.1. Endüstriyel ürünlerin süreçlerine göre literatürdeki sınıflandırılması [4]

Kalite Kontrol	Kontrol edilen özellikler	Referanslar
Boyut	Boyut, şekil, pozisyon, hizalama vb.	[5]
Yapısal	Delikler, yarıklar, yabancı cisimler vb.	[6]
Yüzey	Çukurlar, çizikler, çatlaklar, pürüzlülük vb.	[7]
İşleyiş	İşlemin standartlara uyumsuzluğu	[8]

Boyut kalite kontrolü yöntemlerinde nesnelerin geometrik özelliklerinin iki ya da üç boyutta incelenmesini içerir. Yüzey kalite kontrolü çizilme, aşınma, pürüz ve doku denetimini içerir. Yapısal bozukluklar eksik ya da ekstra parçaların varlığının kontrol

edilmesidir. İlk üç kalite kontrol yöntemi ürünün üretilirken oluşan hataları kontrol ederek ürünün fabrikadan çıkmadan önce ürünün istenilen kalitede olup olmadığının tespiti için yapılır hatanın önlenmesi amacıyla yapılmaz. İşleyiş denetleme önleyici bir denetlemedir ve karmaşıklığından dolayı kumaş denetlemesinde kullanılmamaktadır [9]. Tablodaki kontrol edilen özellikler farklı olmasına rağmen çoğu uygulamada araştırılan sonuç sadece kusurlu ya da kusursuz olmasıdır.

Literatürde denetlemelerin sınıflandırılması gibi materyallerin yüzey özellikleri göz önünde bulundurularak da bir sınıflandırma yapılmıştır. [9]'da ağ denetlemesi için materyaller iki ana kategoriye ayrılmıştır. Birincisi tek biçimli materyaller diğeri dokulu materyallerdir. Metal, kâğıt, film gibi materyaller tek biçimli materyallere örnek verilmiş, seramik, plastik, tekstil ürünleri dokulu materyallere örnek verilmiştir. Dokulu ürünler ise üç alt sınıfa ayrılmaktadır. Bunlar tek biçimli dokulu materyaller, düzensiz dokulu materyaller, desenli dokulu materyallerdir. Şekil 1.1' de materyallerin yüzey özelliklerine göre sınıflandırılması verilmektedir.



Şekil 1.1. Endüstriyel ürünlerin yüzey görüntüsüne göre literatürdeki sınıflandırılması

Doku, uzaktan (uydu ve uçaklardan) elde edilen görüntüden biyomedikal (hücre kültürleri, doku örnekleri) görüntülere kadar birçok görüntü analizinde kullanılmış önemli bir özelliktir [10]. Endüstriyel ürünlerin doku dışında da bağımsız olan özellikleri bulunmaktadır. Bunlar büyüklük, şekil, renk, ışıklandırma, duruş vb. özelliklerdir [4].

Nesnelerin bu özellikleri kendileri ile ilgilidir ve bunlar özellik çıkarımı işlemi literatürde kullanılan özelliklerdir. Literatürde bazı uygulama sadece bir bağımsız özelliğe bağlı olarak sınıflandırma yapmıştır.

1.1. Özellik Çıkarımı

Görüntü üzerindeki nesnelere bağlı olarak bilgi çıkarmak için görüntü tanıma yöntemleri kullanılmaktadır. İşlenmiş görüntü üzerinden çok yararlı bilgiler elde edilebilmektedir. Fakat görüntü üzerindeki ham bilgi sayısı çok fazladır. Boyut arttıkça hesaplama maliyeti de üstel olarak artmaktadır [11]. Her özellik yapılacak iş için gerekli değildir. Bu yüzden yapılacak iş için en uygun özelliklerin çıkarılıp hesaplama maliyetinin düşürülmesi gerekmektedir. Yüksek boyutlu veri kümelerinde mümkün olduğu kadar çok bilgi koruyan az sayıda özellik gösterimi aranmaktadır [11]. Özellik çıkarımı giriş verilerini azaltarak yapılacak iş için en uygun olan verilerin çıkarılması işlemidir. Bu veriler bir bölgenin tanımlanması, skaler olmayan bir sonuç ile yeni bir görüntü dönüşümü ve bir ölçüm ile ifade edilebilir [12]. Giriş verilerinin azaltılması ile hem işlem yükü azaltılmaktadır hem de gereksiz verileri yapılan işlemin sonucunu etkilemesine engel olunmaktadır. Fakat orijinal özelliklerin doğrusal kombinasyonları genellikle yorumlanamaz ve orijinal bir özelliğin ne kadar katkıda bulunduğu konusunda bilgiler çoğu zaman kaybolur [13]. Bu yüzden veri elde etme için en çok kullanılan yöntemlerden birisi özellik çıkarımı olmuştur. Özellik çıkarımı bir uygulamada kullanılırken soyutlama seviyesi ne kadar düşük tutulursa görüntüdeki yerini bulmak o kadar kolay olur fakat anlam çıkarmayı zorlaştırır, soyutlama seviyesi yüksek olursa da görüntüdeki yerini bulmak zor olur [14].

Özellik çıkarımı kalite kontrol sistemleri, yüz tanıma sistemleri, uzaktan algılama sistemleri, medikal görüntü analizi, içerik tabanlı görüntü alımı gibi birçok alanda kullanılmaktadır. Yani görüntü üzerinden her türlü bilgi edinilmesinin temel adımı özellik çıkarımıdır [14]. Özellik çıkarımı sınıflar arasındaki iyi ayırıcı güce sahip özelliklerin doğrusal kombinasyonlar oluşturması anlamına gelir [13]. Yani bir dizi veri içerisinde ayırt edici özelliklerin çıkarılması işlemidir. Üç tane ana amacı vardır:

- Veri boyutunu azaltmak,
- İlgili verilere odaklanmak,
- Veri kalitesini arttırmak [16].

Özellik ise yapılacak iş için en uygun sonucu verecek ölçüm değeridir. Bir model oluşturmak için bilgilendirici özelliklere ihtiyacımız vardır [15]. Çıkarılan özellikler uygulamada kullanılmasına bağlı olarak gerekli, gereksiz ve ihtiyaç fazlası olarak sınıflandırılabilir [13]. Özellik çıkarımının sonucu görüntü temsili oluşturarak özellik vektörüdür.

Sınıflandırma işlemi için hem çok fazla görüntü hem de görüntü üzerinde çok fazla özellik ile işlem yapılmaktadır. Geçerli bir sınıflandırma için, özellikler arasında rasyonel bir ilişki olmalıdır [17] ve sınıflandırma doğruluğu için sınıflar arası büyük farklar, sınıf içi küçük farklılıklar içermelidir [18]. Özellik çıkarımı sadece sınıflandırma için kullanılacak veri ile ilgilenildiği için sınıflandırmada kullanılması zorunlu olmayan verilerin sınıflandırmayı olumsuz yönde etkilemesinin önüne geçilmiştir. Sınırlı eğitim kümesiyle istatistiksel sınıflandırıcı kullanılacağı zaman özellikler makul derecede küçük tutulmalıdır. Buna boyutluluk laneti denilmektedir [19]. Yani eğitim seti, özellik vektöründen küçük olursa sınıflandırıcının performansı düşebilir [20].

Özellik çıkarımı ön işleme aşamasında da kullanılabilir. Ön işleme aşamasında kullanılan yöntemler gürültüyü azaltmak amacıyla kullanılmaktadır [13]. Araştırmacılar tarafında faydalı bulunan bu filtreleme tekniklerinin bazı pratik zorlukları da bulunmaktadır. Örneğin uzman yardımı olmadan gürültüyü istisnadan ayırmak zordur. Özellik çıkarım yöntemleri gürültüye daha toleranslıdır [13]. Bunun dışında bilgisayar görmesi uygulamalarında bölütleme işleminde ve/veya sınıflandırmanın ön işlemi olarak kullanılmaktadır.


Literatürde özellikler nasıl elde edildiğine bağlı olarak düşük seviye ve yüksek seviye diye iki bölüme ayrılmıştır. [14, 21]'de düşük seviye özellikler herhangi bir şekil bilgisi olmadan görüntüden çıkarılabilen özellikler olarak tanımlanmaktadır. Düşük seviyeli özellik çıkarım teknikleri gerçek zamanlı uygulamalar için uygundur [22]. Yüksek seviyeli özellik çıkarımı ise düşük seviyeli özellikleri temel alarak çıkarılır. En iyi sonuca ulaşmak için yapılan işe en uygun olan özellik seçilmelidir. Bunun için çıkarılan özellikler oluşabilecek bozulmalar ve değişimlere karşı devam ettirilebilir olmalıdır [19]. İdeal özelliklerin çıkarılması bilgisayarla görmede hâlâ zor bir alandır [23].

Özellik çıkarım yöntemlerinin düşük ve yüksek seviye olarak ikiye ayrılması dışında da çeşitli şekillerde sınıflandırmalar yapılmıştır. [14]'de özellikler iki ana başlıkta toplanmıştır. Bunlar genel özellikler ve alana özgü özelliklerdir. Genel özelliklerde piksel seviyesi özellikler, yerel özellikler, evrensel özellikler alt sınıflarına ayırmıştır. Genel

özellikler renk, doku, şekil gibi bağımsız özelliklerdir. Alana özgü özellikler yüz, parmak izi gibi belirli bir alan için düşük seviyeli özelliklerin sentezidir. [21]'de ise düşük seviyeli özellik çıkarımı, şekil eşleme ile özellik çıkarımı, esnek şekil çıkarma, nesne tanımla alt bölümlerine ayırmıştır. [24]'de düşük seviyeli özellikleri genel özellikler, evrensel özellikler ve alana özgü özellikler olarak üç alt başlık altında toplamıştır. [14,21]'deki yapılan sınıflandırmalarda kesin sınırlarla bir birinden ayrılmamıştır, sınıflar arasında örtüşmeler bulunmaktadır.

[25]'de özellik çıkarımı, özellik yapımı ve özellik seçimi olarak iki başlık altında toplanmıştır. Özellik yapma özellikler arasındaki bağlantıyı kullanarak yeni bir özellik oluşturma sürecidir [16]. Fakat özellik oluşturmak hem işlem yükünü arttırdığı için programın hızını yavaşlatacaktır hem de gereksiz verilerin sayısını arttırabileceği için doğruluk oranını da düşürecektir. Özellik seçimi ise var olan tüm veriler içerisinde en iyi olan özelliklerin seçilmesidir [13]. Bu yüzden [25]'de gerekli olan özellikler seçilerek depolama alanındaki veriler azaltılıp algoritmanın hızın artması, doğruluk oranının artması özellik seçiminin kullanımında teşvik edici olduğu söylenmektedir. Yani özellik çıkarım yöntemleri ve özellik seçim yöntemleri tahmin doğruluğu, görselleştirme, öğrenilen bilginin anlaşılabilirliği gibi performansı artırıcı özellikler için birlikte kullanılabilir [13].

Endüstriyel ürünler üzerinde yapılan çalışmalar incelendiğinde kullanılan özellikler üç ana başlık altına toplanabilmektedir. Bu özellikler morfolojik, renk ve doku özellikleridir. Morfolojik özellikler genellikle yiyecek endüstrisinde kullanılırken doku özellikleri hata tespitinde sıklıkla kullanılmaktadır. Endüstriyel ürünler için renk özellikleri kullanılırken bir özellik çıkarım yöntemi yerine renk alanları kullanılarak işlemler gerçekleştirilmiştir. Fakat granit gibi bazı yüzeyler düzensizdir. Renk bilgisine sahip olmadan iki farklı granit türü aynı tür olarak sınıflandırılabilir. Renk özellikleri bu tür durumlar dışında yiyecek endüstrisinde de sıklıkla kullanılmaktadır. Çünkü yiyeceklerin renkleri tazelikleri hakkında bilgi sahibi olmamızı sağlamaktadır. Morfolojik özellikler daha çok tohum, buğday, meyve, sebze gibi ürünlerin sınıflandırılmasında kullanılmıştır. Şekil 1.2' de endüstriyel ürünler için kullanılan özellik çıkarım algoritmaları sınıflandırılmıştır. Tez kapsamında yapılan çalışmada yüzeye bağlı sınıflandırma işlemi gerçekleştirilmiştir. Yapılan çalışmada doku özelliklerinin sıklıkla kullanıldığı görülmektedir ve bu yüzden bu alanda çalışma yapılmıştır.



Şekil 1.2. Endüstriyel ürünlerin sınıflandırılması için kullanılan özellikler ve günümüze kadar kullanılmış temel özellik çıkarım yöntemleri

1.2. Kalite Kontrol İşlemlerinde Kullanılan Özellik Çıkarım Yöntemleri

Bilgisayar görmesi uygulamalarında öge ile ilgili verileri analiz etmek için önemli karakteristiklerin çıkarılması gerekmektedir. Belirli başlıklar göz önünde bulundurularak kalite kontrol uygulamaları incelendiğinde her uygulamanın da kendi içinde bölümlere ayrıldığı görülmektedir. Örneğin kumaşlar kalite kontrol uygulamalarında motifli ve motifli kumaşlar olarak ikiye ayrılır [26]. Motifli olan kumaşlarda özgün olan yöntemler uygulanmaktadır. Kumaşlar için kullanılan özellik çıkarım algoritmaları uzaysal domain ve frekans domain olarak ikiye ayrılır [27]. Uzaysal domain görüntü pikselleri direk işleme alırken, frekans domain de ise görüntüye Fourier dönüşümü uygulanır. Uzaysal domain kullanılan uygulamaların çoğu Gri seviye eş oluşum matrisi (GLCM)'den elde edilen matrislerdir [28]. Hızlı Fourier Dönüşümü (FFT), Gabor filtresi ve dalgacık dönüşümü de frekans domain' e örnek verilebilir. Motifsiz yüzeylerde istatistiksel, spektral, model tabanlı, yapısal yaklaşımlar kullanılmıştır [26]. Fourier dönüşüm, Gabor Filtresi ve dönüşüm, dalgacık dönüşümü, Radon dönüşüm, temel bileşenler analizi spektral yaklaşımlara örnek verilebilir. Dalgacık dönüşümü ve fraktal yöntem yeni

geliştirilmektedir. Fraktal yöntemi pürüzlülük özellikleri için yetkin olabilmektedir. MRF model yerel rastgelelik ve genel düzenliliği hesaba katabilir.

Yiyecek ürünlerde kalite ve derecelendirme kontrolü yapılmaktadır [29]. Mantarlarda renk ve şekil tazelik konusunda bilgi veren özelliklerdir, patateslerin sınıflandırılmasında şekil, boyut, renkler, lekeler patateslerin sınıflandırılmasında kullanılmıştır. Meyvelerin sınıflandırılmasında şekil, boyut, doku, parlaklık, renk, lekelerin var olması gibi özellikler meyvelerin alınma oranını etkilemektedir [2], tahıl ürünlerinde şekil, morfolojik değişkenler, renk, doku gibi özellikler, et ürünlerinde renk, doku, geometrik parametreler gibi özellikler, endüstriyel ürünler için renk, şekil, kullanılmıştır. Örneğin [33]'de kalite kontrol işlemi renk, şekil, boyut gibi özellikler için ayrı ayrı yapılmış ve karşılaştırmaları gösterilmiştir.

[18]'de Xie görsel denetim sürecinde genellikle doku ve/veya renk analizi ve sınıflandırma işlemini içerdiğini söylemektedir. Bu çalışma dışında [34]'de bilgisayar görmesinde en sık kullanılan özelliklerin nesne sayısı, boyutlar, geometri, parlaklık ve doku olduğunu belirtmiştir. Bu özellikler morfolojik, kromatik, dokusal ve yapısal olarak dört gruba ayrılabilir.

Morfolojik özellikler piksel yoğunluğunu dikkate almadan nesnenin şeklini çizmeye yarar. Nesneler üzerinde en çok yapılan ölçümler şekli tanımlayanlardır [30]. Matematiksel morfoloji, görüntüdeki nesnelerin şekli için etkili operasyonları nicel olarak tanımlamayı hedefler [31]. Genelde filtreleme ve bölütleme için bir araç olarak kullanılır [17]. Matematiksel morfolojinin şekil ve boyuta duyarlı olmasından dolayı kalite kontrol işlemlerinde sıklıkla kullanılmaktadır [32]. Üzerinde çalışılan nesne yapılandırma elemanı olarak bilinen başka bir nesne ile karşılaştırılarak yapılır [35]. Uygulamalarda genel olarak kullanılan matematiksel morfolojik özellikler açma, kapama, genişleme, aşındırmadır. Tohumlar için yaygın olarak kullanılan morfolojik özellikler alan, çevre, en yüksek yarıçap, en düşük yarıçap, ortalama yarıçap, ana eksen uzunluğu, ikincil eksen uzunluğu, şekil momentleri, radyal Fourier tanımlayıcıları ve sınır Fourier tanımlayıcılarından elde edilir [36]. Yapılan literatür çalışmasında Fourier tanımlayıcıları, kenar çıkarım algoritmaları ve moment değişmezleri yöntemlerinin sıklıkla kullanıldığı görülmüştür.

Kromatik özellikler farklı spektral banttaki piksellerin yoğunluğunu ya da renkleri nitelendirir. Renk en ayırt edilebilir, en basit ve en yaygın özelliktir [37]. Literatürde renk özellikleri endüstriyel ürünler ve tarım ürünlerinde sıklıkla kullanılmıştır. Renk modelleri renk özellikleri çıkarılmasında önemli rol oynamaktadır [38]. Literatürde HSV renk sistemi

ve RGB renk sistemini ayrı ayrı ve ikisini birlikte kullanan uygulamalar bulunmaktadır. RGB renk alanı ile karşılaştırıldığında HSV renk alanı renk bilgisini daha iyi ifade edebilen sezgisel bir renk modelidir [33]. Literatürde tohum sınıflandırmasında renk için sıklıkla kullanılan özellikler ortalama, varyans, aralık, RGB renkleri ve ortalamalarının momentleri ve histogramları, Renk (H), Doyma (S) ve Yoğunluk (I) değerlerinin yoğunluk ve aralıklarından elde edilir [36]. Yapılan çalışmada renk için kullanılan özellik çıkarım yöntemleri olarak moment değişmezleri, renk histogramı, renk korelogram yöntemleri gösterilmiştir. Fakat literatürde renkli doku yöntemleri de sıklıkla kullanılmaktadır.

Yapısal veya bağlamsal özellikler görüntüyü oluşturan bir ya da daha fazla cisim arasındaki ilişkiyi tanımlamaktadır. Örneğin kusurun cisimle olan ilişkisi gibi ilişkileri tanımlamaktadır.

Doku, belirli bir ölçeğe, düzene sahip olan görüntünün homojenliğinin bir açıklamasıdır [39]. Dokulu malzemelerde bulunan kusurların nitelendirilmesi açıkça tanımlanmamıştır [9]. Doku tanımlarında periyodiklik, yönsellik ve rassallık önemlidir [40]. Doku analizi genellikle resim sınıflandırmasına dâhil edilir fakat genel bir tanımı yoktur [41]. Doku analizi renk parlaklığı veya yoğunluğun yerel mekânsal değişimine dayanmaktadır [39]. Görüntüdeki yoğunlukların mekânsal organizasyonu hakkında bilgi sağlar [42]. Çıkarılan doku özellikleri nesne desenlerini pürüzlülük pürüzsüzlük ve tekrarlama ile tanımlamaktadır [36].

Çok çeşitli doku analizi tekniği bulunmaktadır [43]. Bunlar istatistiksel yöntemler, filtreleme teknikleri ve dalgacık ayırıştırmasına dayanan yeni teknikler ve benzeri yöntemlerdir. [14]'de doku analiz tekniklerini iki sınıfa ayırmıştır: istatistiksel yaklaşımlar ve yapısal yaklaşımlar. [44]'de ise doku yapısal, istatistiksel sinyal işleme, model tabanlı stokastik, morfoloji tabanlı metotlar olarak beş sınıfa ayrılmıştır. İçlerinden en çok kullanılan yöntemler istatistiksel ve sinyal işlemedir. Çünkü bu yöntemler herhangi bir doku türüne direk uygulanabilirler. Yapısal metotlar nadir bulunan dokularda uygulandığı için, model tabanlı stokastik metotlar zorluğu yüzünden, morfoloji tabanlı metotlar çok iyi sonuçlar vermediği için yaygın olarak kullanılmamaktadır.

İstatistiksel yöntemler basit, uygulaması kolay, güçlü uyum ve sağlamlığa sahiptirler. Gri seviye eş oluşum matris (GLCM), yerel ikili örüntü (LBP), Gabor Dalgacık filtre gibi istatistiksel yöntemler günümüzde sıklıkla kullanılmaktadır [45].

Dokuların düzenli bir desen oluşturduğuna inanılmasına rağmen mermer ve granit gibi bazı ürünlerin dokuları düzensizdir [46] ve granit üzerinde yaptıkları çalışmada renk

bilgisi olmadan kişilerin iki farklı türde granit görüntüsünün aynı türe ait görüldüğünü belirtmektedir. Bu durum renk bilgileri ile daha iyi karar vereceğimizi göstermektedir.

Yapılan literatür çalışmasına göre kalite kontrol için en sık kullanılan özellikler üç başlık altında toplanabilmektedir. Bu özellikler doku, morfolojik (şekil) ve renk. İncelen çalışmalara bağlı olarak en çok doku özelliklerinin kullanıldığı söylenebilir. Son dönemlerde yapılan kalite kontrol uygulamaların birden fazla özellik çıkarım yönteminin sınıflandırmada beraber kullanıldığı görülmektedir.

Tablo 1.2. Kalite kontrol için literatürde kullanılmış özellik çıkarım yöntemleri ve uygulama alanları için örnek alanlar

Özellik Çıkarım Metodu	Uygulama Alanı	Referans
GLCM	Yiyecek	[47, 90]
	İlaç	[48]
	Tekstil	[49]
	Ahşap	[50]
	Diğer	[51]
LBP	Yiyecek	[52,53]
	Ahşap	[54]
	Tekstil	
	Çelik	
	Diğer	[92]
Gabor Wavelet	Yiyecek	[55]
	Tekstil	[56, 57, 58]
Şekil Özellikleri	Yiyecek	[59]
	Tohum	
	Otomotiv	
	Paketleme	
Fourier Şekil Tanımlayıcıları	Yiyecek	[59]
	İlaç	
	Tekstil	[60]
	Filmaşın	[61]
	Kâğıt	
Moments	Yiyecek	[91]
	Tohum	
Renk özellikleri	Yiyecek	[43, 62, 63]
	Fayans	
	Tekstil	
	Ahşap	
	Tohum	

1.2.1. Morfolojik Özellikler

Morfolojik özellikler ürünün boyut, şekil, gibi özelliklerdir. Bu özellikler kalite kontrolde sıklıkla kullanılır. Örneğin meyvelerin boyutlarına göre sınıflandırılması nakliye ve pazarlamada önemlidir. Görsel kalite kontrol uygulamalarının hızlı bir şekilde sonuca ulaşılması gerekmektedir. Bu yüzden dolayı en basit özelliklerin kullanılması en iyi yoldur.

Şekil özellikleri bir nesnenin boyutlarını karakterize eden özellikleridir [36]. Bu özellik çıkarım metotları şeklin çevre uzunluğu, alan, en yüksek yarıçap, en düşük yarıçap, ortalama yarıçap, ana eksen uzunluğu, küçük eksen uzunluğu, yönelme açısı gibi özelliklerini tanımlamaktadır. Bu özellikler dışında Fourier tanımlayıcılar, moment değişmezleri, sınır kodlama (boundry encoding) gibi çeşitli yöntemlerde bulunmaktadır. Moments değişmezleri ve Fourier tanımlayıcıları ölçek ve oryantasyona bağlı olmadıkları için en çok kullanılan yöntemlerdir [59].

Literatürde çeşitli Fourier tanımlayıcıları olmasına rağmen bunların çoğu geleneksel örüntü tanıma ve elektrik mühendisliği alanlarıyla sınırlıdır [64]. Fourier tanımlayıcı iki boyutlu bir sınır çizgisinden tek boyutlu bir fonksiyon elde etmeye yarar [65]. Fourier tanımlayıcının eksiklerinden birisi gerçek verilerle kullanılmasında bütünleşmiş bir yaklaşımın olmamasıdır [64]. Düşük karmaşıklığa sahip olması, her tanımlayıcının fiziksel bir anlamının olması, kolayca normalleştirilebilmesi, tüm ölçeklerde şeklin özelliklerin tarif edebilmesi avantajlarına sahiptir [65]. Diğer sınır tabanlı metotlara göre doğruluk ve performans açısından daha iyi sonuçlar verdiği görülmüştür [61]. [58]'de farklı boyut ve şekilde olan patateslerin sınıflandırma işlemi için uzunluk, alan, en gibi özellikler ve Fourier tanımlayıcı kullanarak şekilsiz patateslerin belirlenmesi ve homojen şekilli patateslerin elde edilmesi gerçekleştirilmiştir. Çalışmada patatesler %98 oranında doğru sınıflandırılmış ve küçük, orta, büyük boyuta göre yapılan sınıflandırmada %100 doğruluk oranına ulaşılmıştır. Genellikle Fourier tanımlayıcılar meyve sebze ve yemiş gibi ürünlerin sınıflandırması için kullanılmıştır [36]. [60]'de ise filmaşın üretiminde yüzey kusurların denetlemek için değiştirilmiş Fourier tanımlayıcıları kullanılmış. Sınıflandırmada k-medoid algoritması kullanılmıştır. Veri seti üretim tesislerinde elde edilen gerçek kusurlardan oluşmuştur. Uygulama çevrim dışı olarak kullanılmak için geliştirilmiştir ve başarılı sonuçlar elde edilmiştir.

Fourier tanımlayıcıları dışında moments değişmezleri de morfolojik özelliklerin elde edilmesi için kullanılmaktadır. Moment değişmezlerine Hu değişmez momentleri, ortogonal moment gibi yöntemler örnek verilebilir [66].

1.2.2. Doku Özellikleri

Yerel ikili örüntü basit ve güvenilir bir yöntem olduğu için doku analizi uygulamalarında sıklıkla kullanılmaktadır. Son dönemlerde yapılan çalışmalarda genellikle birden fazla özellik çıkarım yöntemi kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. [52]'de GLCM ve LBP kullanılarak dört farklı buğday çeşidini tanımayı otomatik olarak gerçekleştirmektedirler. Sınıflandırma işlemi için k-kümeleme algoritması kullanılmıştır. [53]'de tohum hatalarının tespiti için bir çalışma yapılmıştır. Çalışmada tohumların hatalarını tespit ederken GLCM, LBP ve renk özelliklerini kullanmışlardır. Destek Vektör Makinaları (DVM) ile sınıflandırma gerçekleştirilmiştir. Yapılan deneyler 14 000 örnek üzerinde gerçekleştirilmiş. Bu özellik çıkarım yöntemlerinin birleştirilmiş şekilde kullanılması ile %81,8 doğruluk oranına ulaşılmıştır. Sınıflandırmalarında kusurlu olan tohumların normal tohumlarla yanlış sınıflandırmaya olasılığı düşük olduğu söylenmektedir. [54]'de ağaç türleri arasında sınıflandırma işlemi gerçekleştirilmiştir ve elde edilen sonuçlar gerçek zamanlı kullanılabilecek bir uygulama olduğu anlaşılmış ve iyi bir doğruluk oranına ulaşmıştır.

GLCM görüntülerde gri düzey değerlerinin mekânsal dağılımını analiz etmek için yapılan istatistiksel bir yöntemdir. Metot verilen alanda iki gri seviye arasındaki oluşum frekansını değerlendirir. Çeşitli kalite kontrol uygulamalarının iyi sonuçlar elde edilmiştir. Fakat uygulama karmaşıklığı çok yüksektir, pikseller arasındaki ilişkiyi incelemek zordur ve resim hakkında genel bilgi verememektedir. Eş-oluşum matrisi hatalı ve hatasız yüzeylerin ayırımında yararlıdır [51].

[48]'de tek renkli, iki renkli ve çok renkli ilaç kapsülleri kırık kapsül, kayıp kapsül, hem kırık hem kayıp kapsül, uygun olmayan şekilde hizalanmış kapsül ve yüzey kusurları olan kapsüller ile denenmiştir. Her kategoriden on üç farklı tipte görüntü üzerinden deney yapılmıştır. Deneylerde kendi önerdikleri dört farklı yöntem ve GLCM yöntemi karşılaştırılmıştır. GLCM tek renkli kapsüllerde iyi, iki renkli kapsüllerde ortalama, çok renkli kapsüllerde çok iyi sonuçlar vermiştir. [51]'de hard disklerin okuma yazma

kafasının en önemli parçası olan hava yatağının yüzey kontrolü için makine görmesi uygulaması kullanılmıştır. Değişmeyen parlaklıkta görüntülerde çok iyi sonuçlar elde edildiği belirtilmiştir.

[50]'de ağaçların budak yerinin sınıflandırılmasında GLCM, LBP ve istatistiksel moment yöntemleri kullanarak gerçekleştirilmiştir. Bu yöntemlerin teker teker kullanılması çok iyi sonuçlar vermemiştir. Bu yüzden GLCM+LBP, GLCM+ istatistiksel moment, LBP+ istatistiksel moment kullanılarak görüntüden elde edilen veriler temel bileşenler analizi (PCA) ve doğrusal diskriminant analizi (LDA) kullanılarak elde edilen veriler azaltılmıştır. Sınıflandırma için KNN ve DVM kullanılmıştır. GLCM+LBP ile her iki sınıflandırmada da %100 doğruluk oranına ulaşılmıştır. [49]'de GLCM ve yapay sinir ağlarına dayanan bir yöntem ile kumaşın kusurlu olup olmadığını belirlemesi üzerine bir çalışma yapılmıştır.

Gabor dalgacık görüntü işleme uygulamalarında sıklıkla kullanılmaktadır. [55]'da meyveler üzerindeki hataları tespit etmede Gabor Dalgacık filtresi kullanılmıştır. [56] ve [57]'de kumaş üzerindeki bozuklukları çıkarmak için kullanılmıştır. [58]'de ise üç çeşit dokuma kumaşın sınıflandırılması yapılmıştır. Çalışmada Gabor dalgacık filtresi, LBP ve GLCM yöntemleri karşılaştırılmıştır.

1.2.3. Renk Özellikleri

Renk endüstriyel ürünlerin sınıflandırılmasında sıklıkla kullanılan bir özelliktir. Özellikle yiyecek ürünlerde müşterinin ürünü alıp almamasını en çok etkileyen özelliklerden birisidir. [62]'de portakal kabuklarını iyi ya da kötü olarak sınıflandırması yapılmıştır. Bu işlem yapılırken RGB renk alanı kullanılmıştır. Pikseler çok geniş bir alanda değiştiği için görüntüdeki rastgele görüntü yamalarını örneklemeyi ve bu yamaların renk histogramlarının hesaplaması önerilmiştir. Yapılan çalışmada her kanal için on altı örnek çıkarılmış bu da toplamda dört bin doksan altı özellik boyutu oluşturmuştur. Boyutun büyüklüğü hem zaman kaybı hem de gürültü duyarlılığı oluşturmaktadır. Bu yüzden Fisher Doğrusal Discriminant Analiz (Fisher-LDA) metodu kullanılarak boyut atmış dörde düşürülmüştür. Sınıflandırma için Destek Vektör Makinaları kullanılmıştır. Yanlış algılama oranı %1,7'dir. [63]'de ise aynı uygulamayı elma üzerinde denemişlerdir ve yanlış algılama oranı %1,6'dır.

[42]'de narların derecelendirilmesi ve sınıflandırılması için renk doku özellikleri ve ayrıık dalgacık dönüşümü kullanılmıştır. Renk doku özellik analizi için görüntü HSI renk alanına dönüştürülmüştür. Bu işlem SGDM matrisini oluşturmak için yapılmaktadır. Bu dönüşümle on iki tane özellik elde edilmektedir. Daha sonra istatistiksel özellik elde edilebilmek için dalgacık dönüşümü kullanılmaktadır. Buradan üç tane özellik elde edilmektedir. [67]'da baskı devre kartı üzerindeki lehim macunu denetlenmiştir. Makalede lehim macunu için yeni bir yöntem önerilmektedir.

Blasco ve arkadaşları nar taneleri için R/G oranının R, G, B'nin grup halinde kullanılmasından ya da ayrı ayrı kullanılmasından daha iyi sonuç verdiğini söylemektedir [68]. RGB sistemi sıklıkla kullanılmasına rağmen RGB sisteminden diğer sistemlere dönüşümleri ile ilgili uygulamalar daha fazladır. Çünkü diğer sistemler insan algısına daha yakın sistemlerdir.

1.3. Tezin Amacı ve Kapsamı

Ürünlerin kalite kontrol işleminden geçmesi müşteri memnuniyeti açısından önemlidir. Bu işlemin hızlı ve doğruluk oranının yüksek olması ise işverenlerin hem maliyet hem de itibar kaybının önüne geçilmesini sağlamaktadır. Kalite kontrol işlemi için bilgisayar görmesi uygulamaları bu yüzden sıklıkla kullanılmaktadır. Sınıflandırmanın gerçekleştirilebilmesi için özellik çıkarımı işleminin gerçekleştirilmesi gerekmektedir. Bu tez çalışmasında, endüstriyel ürünlerin kalite kontrolü için kullanılacak yeni bir özellik çıkarım yöntemi önerilmektedir. Bu amaç doğrultusunda literatürde kalite kontrol için yapılan çalışmalar incelenmiş ve kullanılan yöntemler belirlenmiştir. Daha sonra yüzey hataları için kullanılan özellik çıkartım yöntemleri Northeastern University (NEU) yüzey hataları veri tabanı ve oluşturulan kumaş veri tabanı kullanılarak elde edilen sonuçları karşılaştırılmıştır. Bu yöntemler incelenerek üzerinde çalışmalar gerçekleştirilmiş ve LBP yönteminden yeni bir yöntem geliştirilmiştir. GLCM literatürde sıklıkla kullanılan ve başarılı sonuçlar elde edilen bir yöntemdir. Bu yöntem eş- oluşum matrisi elde edildikten sonra çeşitli istatistiksel yöntemler ile özellik çıkarım işlemi gerçekleştirilmektedir. Yapılan çalışmada GLCM için literatürde bulunmayan yeni bir özellik çıkarım yöntemi önerilmiştir. Daha sonraki bölümde özellik seçimi işlemi gerçekleştirilerek doğruluk oranları arttırılmıştır.

1.4. Tezin Yapısı

Bu tez çalışması *giriş bölümü* ile birlikte yedi bölümden oluşmaktadır. Giriş bölümünde kalite kontrol hakkında bilgi verilmiştir. Daha sonra özellik çıkarımı hakkında genel bilgi verildikten sonra endüstriyel ürünlerin kalite kontrolü için kullanılan özellik çıkarım yöntemleri sınıflandırılmış ve bu yöntemler hakkında bilgi verilmiştir.

İkinci bölümde görme tabanlı kalite kontrol yöntemleri hakkında bilgi verilmiş ve literatürde yüzey hatalarının tespiti için kullanılan üç tane yöntemin matematiksel modelleri verilmiştir.

Üçüncü bölümde LBP, GLCM ve Gabor Dalgacık filtresi yöntemleri NEU ve kumaş veri tabanları kullanılarak karşılaştırılmıştır.

Dördüncü bölümde LBP yöntemi kullanılarak yeni bir yöntem geliştirilmiştir. NEU ve kumaş veri tabanı kullanılarak elde edilen sonuçlar verilmiştir.

Beşinci bölümde GLCM yöntemi için literatürde olmayan yeni bir istatistiksel özellik çıkarım yöntemi geliştirilmiştir. NEU ve kumaş veri tabanı kullanılarak elde edilen sonuçlar verilmiştir.

Altıncı bölümde beşinci bölümde önerilen yöntem üzerinden gerçek hayatta kullanılabilecek bir sistem tasarımı yapılmıştır.

Yedinci bölümde yapılan çalışmalar hakkında genel bir değerlendirme yapılmıştır.

2. GÖRME TABANLI KALİTE KONTROL İÇİN ÖZELLİK ÇIKARIM YÖNTEMLERİNİN MATEMATİKSEL MODELLERİ

Endüstriyel gelişmeler ile ürünlerin daha hızlı bir şekilde üretilip müşteriye ulaşması amaçlanmaktadır. Müşteri memnuniyeti açısından, ürünlerin müşteriye ulaşmadan önce aynı standartta olduklarının tespit edilmesi gerekmektedir. Kalite kontrol işleminin hızlı ve iyi bir şekilde gerçekleştirilmesi birçok bilim insanının ilgisini çekmiştir. Görüntü üzerinden hata tespiti hem hızlı hem de güvenilir sonuçlar elde edilebilmesi bu alanda çalışmalar yapılmasını sağlamıştır.

Çeşitli kalite faktörlerinin incelenmesi hem çok öznel nitelikte olan hem de çok tekrarlayan bir iştir. Bu durum insanların kalite kontrol işlemi yaparken birçok sebep yüzünden yanlış sınıflandırma yapmasına sebep olabilmektedir. Fakat makine görmesi bu tür işler için çok uygundur [69]. Literatürde makine görmesi ve bilgisayar görmesinden yaygın olarak faydalanılmaktadır ve bu uygulamalar yapay sinir ağlarıyla da desteklenerek insan düşünme sistemine daha benzer sistemler elde edilmeye çalışılmaktadır.

Bilgisayar görmesi nesne tanıma ve nicel bilgi çıkarma işlemleri için görüntü işleme ve analiz kullanan teknolojidir [69]. Bilgisayar görmesi üzerinde çalışan araştırmacılar görüntüyü üç boyutlu şeklini ve görünümünü korumak için matematiksel modeller üzerinde çalışmaktadır [71]. Bilgisayar görmesi şekil sınıflandırması, kalite kontrol, kalite derecelendirme, çeşit sınıflandırması gibi görevlerde kullanılmıştır [2].

2.1. Görme Tabanlı Kalite Kontrol

1960'lı yıllardan bu yana bilgisayar görüntüsü tıbbi teşhis, fabrika otomasyonu, uzaktan algılama, otonom araç ve robot yönlendirmesi gibi birçok alanda uygulanmıştır [2]. Endüstriyel alanda da kullanılarak hem daha ucuz ve tekrar eden işler için daha verimli sonuçlar elde edilmesi amaçlanmıştır. Otomatik görme sistemleri ölçme, bütünlük kontrolü ve kalite kontrolü amacıyla kullanılabilir [72].

Makine görmesiyle elde edilen sonuçlar robot kollarının yönlendirilmesinde, arızalı parçaların kusurlarını tespit edip hatalı kısmı ayırma veya düzeltmede, sınıflandırmada

kullanılabilmektedir [4]. Hiçbir endüstriyel görme sistemi her uygulama alanında bütün görevleri yerine getiremez.

Görsel denetim sistemleri temel olarak bir ışık kaynağı, görüntü yakalamak için bir cihaz ve özellik çıkarması ve işlemesi için bir hesaplama sistemini içermektedir [34]. Görüntü kameralar aracılığıyla alınarak alınan görüntünün analizi için özelleştirilmiş donanımı ve yazılımı kullanılmaktadır [2]. Endüstriyel ürünlerin kalite kontrol işlemleri yapılırken görüntü alan kameraların konumu ve her üründe kullanılan ışıklandırma aynıdır [4]. Bu durum her ürün için aynı koşullarda karar vermeyi ve daha iyi sonuçlar elde edilmesi açısından önemlidir. Fakat ışıklandırma, arka plan rengi, görüntüyü alan cihaz görüntünün kalitesini etkilemektedir [34].

Bir makine görmesi sistemi tasarımında sistemin ihtiyaç ve kısıtlarının belirlenerek uygun yazılım ve donanımın seçilmesi gerekmektedir. Örneğin bu ihtiyaçlardan birisi sistemin kullanıldığı çevrenin koşulları için uygun hıza sahip olması gereklidir.


Endüstriyel ürünlerin kontrol işlemleri genellikle aşağıda tanımlanan gibi olmasına rağmen yetiştirilen ürünlerin toplanması gibi bilgisayar görmesi uygulamaları da bulunmaktadır.

[4]'de yazılım araçlarının çoklu işlem seviyesi desteği, kolay işletme, çerçeve hızı ve dinamik erim desteği, genişletilebilirlik, özelleştirilmiş donanım desteği özelliklerine sahip olması gerektiği söylenmiştir. Filtreleme, eşik değeri elde etme gibi işlemler düşük seviye, görüntü bölütleme, özellik çıkarma gibi orta seviye, sınıflandırma, nesne tanıma yüksek seviye işlem olarak tanımlanmaktadır ve yazılım bütün seviyelerdeki fonksiyonları desteklemektedir. Çerçeve hızı ve dinamik erim desteği yeni türde algılayıcıların görüntü alma hızını, yazılımın bu görüntülerini aynı hızda işlemlerini desteklemektedir. Genişletilebilir olması yeni algoritmalarla uyum sağlayabilmesi anlamına gelmektedir. Donanım desteği özelliği yazılım paketlerinin yeterli hızla ulaşamaması durumunda destekleyici rol üstlenmektedir.

Son yıllardaki test tekniklerindeki ilerlemeler elektronik ve bilişim alanlarındaki gelişmelerde önemli bir faktör olmuştur. Otomasyon, üretim hatlarındaki test ekipmanlarının gelişimini tetiklemiş ve sensör teknolojisinin gelişimi yeni ölçüm yöntemlerinin oluşmasına yol açmıştır [34].

2.1.1. Donanım

Bilgisayar görmesi sistemlerinin donanımı standarttır ve bir kamera, bilgisayar yazılım ve donanımı, ışık, görüntü yakalama kartından oluşmaktadır [69]. Işıklandırma birden fazla kullanılabilir. Işıklandırmanın doğru yapılması yansıma, gölge ve bazı gürültüleri azaltmaktadır. Bu durum işlem süresini kısaltmakta etkilidir [2]. Şekil 2.1.'de standart bir endüstriyel görme sisteminin örneği verilmiştir.



Şekil 2.1. Bilgisayar görmesi sistemlerinin bileşenleri

Aydınlatmada ışıklandırmanın yeri, lamba tipi, renk kalitesi gibi özelliklere dikkat edilmesi gerekmektedir [2]. Akkor lamba, floresan, lazer, X ışını tüpleri, kızılötesi lambalar ışıklandırma olarak kullanılmıştır. İncelen çalışmalarda genel olarak floresan lamba kullanılmıştır. Gomes ve Leta [34] çalışmalarında günün saati, hava koşulları gibi olumsuz etkiler olmasına rağmen doğal ışığın en iyi seçenek olduğunu söylemektedir.

Görüntü elde edilirken arka plan da alınmaktadır. Bu yüzden elde edilen görüntüdeki arka plan özellikle renk analizi uygulamalarında çok etkilidir. Uygulamalarda farklı renkler kullanılmasına rağmen siyah ve beyaz renk bölütleme işlemini kolaylaştırdığı için daha sık kullanılmaktadır fakat bu durum kontrol edilen ürüne göre değişebilmektedir [34].

Görüntü üretmek için tek renkli ve renkli kamera, ultrason, X-ray, yakın kızılötesi spektroskop, lazer üçgen kamera [6], tarayıcı gibi birçok sensör kullanılmaktadır. Fakat makine görmesi uygulamalarında genel olarak CCD kameralar kullanılmıştır. CCD kameralar görülebilir aralıkta işlem yapmaktadır. Bu kameralar ile kaliteli görüntüler elde edilebilmektedir. CCD kameralar gürültüyü azaltan ve sensörün hassaslığını arttıran daha az çip üzerinde bulunmaktadır. CMOS sensörlerde devrenin çoğu yerleşik olduğu için daha

hızlıdır fakat aynı aydınlatma koşulları altında farklı pikseller için tepki tutarlılığına daha hassastır. Pratikte endüstriyel görme sistemlerinin çoğunluğu 300 K piksel çözünürlük düzeyinde görüntü alınmaktadır, görüntü sensörleri teknolojileri 16 M piksel çözünürlüğe ulaşmak için çalışılmaktadır [4]. Hız ve çözünürlük arasında bir denge vardır. Yani yüksek çözünürlüklü görüntü işleme sistemine daha büyük veri akışı sağlar ve bu yüzden algoritma yavaşlar.

Renkli kameralar çoğunlukla CCD sensör teknolojisi üzerinden ilerlemektedir [4]. Dijital kameralarda 3 CCD yongası kullanılarak kırmızı, yeşil ve mavi kanallara ayırarak 24 bit gerçek renk edinimi elde edilebilir hale gelir. Dijital renkli kameralar JPEG formatında çeker ve iletimi FireWire (IEEE 1394 ara yüzü) iletişimi ile sağlar [4].

Görüntü elde edilen sistemlerin mükemmel olmamaları yüzünden elde edilen görüntülerde hatalar bulunabilmektedir. Bu durum donanımsal olarak halledilebilmekte fakat para ve zaman kaybına yol açmaktadır [69].

2.1.2. Yazılım

Görüntü işleme ve resim analizi bilgisayar görmesinin temel olarak kabul edilir [2,70]. Görüntü işleme süreci farklı şekillerde tarif edilmiştir. Şekil 2.2’de Brosnan’ın yaptığı tanımlamaya göre bir akış şeması çizilmiştir.



Şekil 2.2. Görme tabanlı kalite kontrol yöntemlerinin yazılım aşamasının akış şeması

[2]’de görüntü işleme/ analiz düşük düzey işleme, ara düzey işleme, yüksek düzey işleme olarak üç ana seviyeye bölünmüştür. Düşük seviye işlem görüntünün elde edilmesi ve ön işlemleri içermektedir. Ön-işlemler görüntüyü iyileştirerek yapılacak işlem için görüntünün hazırlanmasıdır [93]. Görüntü elde edildikten sonra tekrarlı gürültü, yanlış odaklanma, düzgün olmayan odaklanma, düzensiz aydınlatma kaynaklı gürültüleri gibi hataları gidermek için bir dizi görüntü iyileştirme yöntemleri kullanılmaktadır. Yani

gürültü giderilmesi, gri düzeyi düzeltme, bulanıklaştırmayı düzeltme gibi işlemleri içermektedir.

Ara düzey işleme [2]'de görüntü bölütleme, temsil etmek ve açıklaması olarak tanımlanmaktadır. Görüntü bölütleme görüntüdeki nesneleri ve alanları güçlü bir korelasyon gösteren bölgelere ayırmaktır. Bu işlem ürünün arka plandan ayrılması için yapılmaktadır. Bölütleme benzer piksellerin gruplanmasıyla yapılır. Benzerlik piksellerde gri seviye, renk ve doku temel alınabilir. Bölütlenmiş görüntü bölge veya sınır olarak temsil edilebilir. Sınır boyut ve şekil analizinde kullanılır, bölge doku ve kusur değerlendirmesinde kullanılmaktadır [2]. Açıklama görüntü bölgelerinin nicel bilgilerinin çıkarılması ile ilgilidir. Günümüzde popüler olan bölütleme işlemleri eşikleme, kenar tabanlı bölütleme, bölge tabanlı bölütleme, gradient tabanlı bölütleme, sınıflandırma tabanlı bölütleme yöntemleridir [69].

Yüksek seviyeli işlem tanıma ve yorumlama olarak ikiye ayrılır. İstatistiksel sınıflandırıcılar ve çok katlı sinir ağları kullanılmaktadır. Yani bu adımlar kalite sıralama sınıflandırma için gerekli bilgileri sağlar.

Bütün seviyelerin bilgi tabanı ile bağlantısı vardır. Bu durum daha hassas karar vermede gereklidir. Sinir ağları, bulanık mantık, genetik algoritmalar gibi algoritmalar bilgi tabanı oluşturmak için kullanılmaktadır. Bu tür algoritmalar görüntü tanıma ve karar verme yeteneğini içerir.

[69]'de görüntü iyileştirme aşamasından hemen sonra bölütleme işleminin yapılması gerektiği söylenmektedir. Özellik çıkarma, bölütleme işleminde bölümlerin sınıflandırılmasını kolaylaştıran tanımlayıcı kümeleri hesaplar [73].

Sınıflandırma tabanlı imge bölütleme piksel yönelimli bir bölütleme yöntemidir. Bu yöntem ile alınan görüntüleri ürün, arka plan ya da hatalı ve sağlam olarak sınıflandırma yapılır. Görüntüden elde edilen renk, şekil, doku gibi özellikler sayesinde sınıflandırma yapılabilir.

Bölütleme işleminden sonra nesne ölçüm yöntemleri kullanılmaktadır. Bu ölçümler görüntüyü anlamak ve yorumlamak için gerekli ölçümleri içermektedir [69]. Yani bölütleme işlemini yapmak için de özellik çıkarım yapılarak farklı alt bölgelere ayrılmaktadır.

Alınan görüntüdeki yoğunluk değerleri matris şeklinde piksellerde tutulmaktadır. Bu matristeki değerler görüntüdeki piksellerin yeri geometrik bilgileri ve piksellerle ilişkili

yoğunluk değerleri de yüzey bilgilerini içermektedir [69]. Geometrik bilgi ile boyut ve şekil bilgisi elde edilmektedir. Yüzey bilgisi ile renk ve doku bilgisi elde edilmektedir.

[73]'de ise bu işlemler görüntünün elde edilmesi, dijitalleştirme, ön işlem, bölütleme, özellik çıkarımı, sınıflandırma olarak tanımlamaktadır. Görüntü elde etmek dijital görüntüye dönüştürülebilen bir optik görüntü elde etmektir [73]. Bölütleme işlemi ile gerekli olan bölgeler alındıktan sonra özellik çıkarma işlemi ile objeye ait özellikler elde edilir.


Özelleştirilmiş ve mali tasarruf sağlayan çözümlerin tercih edildiği durumlarda Linux bir standart haline gelmektedir [4]. Bu durumu Linux'un açık kaynaklı ücretsiz ürünlerinin olması ve yazılım bağımsızlığının sağlanması gereken özel uygulamaların olması sağlamaktadır. Fakat Linux'ün uygulama geliştirme araçlarının sınırlı olması bu işletim sisteminin olumsuz özelliklerindendir.

2.2. Özellik Çıkarım Yöntemleri

Yüzey hatalarının sınıflandırılmasında genellikle doku özellikleri kullanılarak gerçekleştirilmektedir. Doku analizinde istatistiksel yöntemler, filtreleme teknikleri ve dalgacık ayrıştırmasına dayanan yeni teknikler ve benzeri yöntemler kullanılarak gerçekleştirilebilir. Bu bölümde Gri seviye eş oluşum matris (GLCM), yerel ikili örüntü (LBP), Gabor Dalgacık filtre istatistiksel yöntemlerinin matematiksel modelleri verilmiştir. İstatistiksel özellikler parametrelere ve yapılandırma kararlarına çok bağlıdır [12].


2.2.1. Yerel İkili Görüntü (LBP)

LBP gri seviyeden bağımsız olarak ölçüm yapan bir operatördür. Bu yöntem yerel doku özelliklerini tasvir etmek için önerilmiştir. Basit fakat etkili bir yöntemdir. Temel LBP operatör, 3x3'lük bir pencere kullanılır. Ortadaki piksel ile komşu piksellerin değerleri karşılaştırılır. Eğer karşılaştırılan piksel büyükse 1 küçükse 0 yazılır. Tüm pikseler karşılaştırıldıktan sonra tüm pikseler sol üstten başlayarak saat yönünde alınır. Elde edilen sonuç ondalık değere dönüştürülerek sonuç elde edilir. Şekil 2.2' de temel LBP operatörüne ait bir örnek verilmiştir.



Şekil 2.3. Temel yerel ikili örüntünün hesaplanmasının örneği

Daha sonra geliştirilen yöntemde dairesel şekilde komşuluk ilişkisine bakılarak hesaplanmıştır. Burada iki parametre (P ve R) kullanılır. P örnekleme sayısını R yarıçapı belirtir. Merkezdeki bulunan piksel değeri komşu değerlerden çıkarılır. LBP özelliklerinin ortalama aydınlatma değişikliklerinden etkilenmediği gösterilmiştir. Ojala ve arkadaşları (2002)'de doku görüntüleri ile yaptıkları deneyde (8,1) komşuluk kullanan kalıplarında %90'ından biraz azını oluşturduğunu fark etmiştir [74].



Şekil 2.4 P=8, R=1 olan genişletilmiş LBP operatörünün örneği

x_c LBP operatörü üzerindeki merkez piksel, x_p merkez pikselin komşuları, R merkez piksele uzaklığı, P işleme sokulan komşu sayısını ve $u(y)$ ' nin merkez piksel ve komşuları arasında olan ilişkiyi ifade ettiğini kabul edersek; LBP matematiksel olarak aşağıdaki gibi ifade edilir.

$$u(y) = \begin{cases} 1, & y \geq 0 \\ 0, & y < 0 \end{cases} \quad (2.1)$$

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p \quad (2.2)$$

LBP histogramı oluşturulurken düzgün örüntüler kullanılır. Yani tanımlamada kullanılan düzgün örüntüler ikili LBP kodunda 0-1 veya 1-0 geçiş sayısı iki veya daha az olanlar kullanılmaktadır. Örneğin 00000000 veya 11111111 örüntüleri 0 geçişe sahiptir, 11000111 örüntüsü iki geçişe sahiptir. Bu tür örüntülere düzgün örüntüler denilmektedir. 11101011 gibi bir örüntü dört tane geçişe sahip olduğu için düzgün örüntü değildir. LBP histogramı oluşturulurken histogramda her bir düzgün örüntü için bir bölme, düzgün olmayan bütün örüntülerin hepsi bir bölmede toplanmaktadır. Yapılan çalışmalarda düzgün örüntülerin araştırılan doku yüzeylerinde bazen %90'ın üzerinde olduğu görülmüştür [75]. 8 komşuluk için 256 tane farklı örüntü oluşabilmektedir ve bunların 58 tanesi düzgün örüntüdür. Bu durumda LBP histogramı 59 tane bölmeye sahip olacaktır. $U(i)$ üretilen örüntülerden düzgün olan örüntüleri tutan dizidir. LBP histogramı aşağıdaki şekilde ifade edilir.


$$H_i = \sum_{x_c \in I(x,y)} f\{LBP_{P,R}(x_c, y_c) = U(i), i = 0,1,2, \dots, n-1 \quad (2.3)$$

$$f\{y\} = \begin{cases} 1, y \text{ yanlı} \text{ş ise} \\ 0, y \text{ do} \text{ğru ise} \end{cases} \quad (2.4)$$

2.2.2. Gri seviye Eş-oluşum Matrisi (GLCM)

1973'de Haralick, kayaların sınıflandırılması için eş-oluşum matrisini önermiştir [76]. Günümüzde de farklı özellik çıkarım uygulamalarında sıklıkla kullanılmaktadır. GLCM yoğunluk dağılımı, komşu piksellerin bağıl konumu hakkında bilgi vermektedir. Yani yoğunluk değeri i olan bir piksel ile belirli uzaklık ve açıda komşu piksel olarak bilinen j 'nin ne sıklıkta olduğunu göstermektedir. Bu yöntemin en önemli paradoksu elde edilen matrisin orijinal görüntüden daha güçlü olup olmadığıdır [77]. GLCM kullanmanın asıl problemi dokunun yapısal bilgilerini etkili bir şekilde yakalamak için uygun ölçek ve uyum parametresini seçmektir.

GLCM $N \times N$ ' lik bir kare matristir ve bir resim içerisindeki gri değerlerin iki komşu piksellerdeki d mesafesiyle birlikte oluşum sayısını belirli bir açıya ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) göre görülme sıklığını ifade etmektedir. Şekil 2.5'de d mesafeleri ve θ açılarının geometrik ilişkileri gösterilmektedir.



Şekil 2.5. d=2 iken GLCM için olası yön açılarının gösterimi

Tahmin edilen olasılık dağılımlarının bazı çiftler arasında basit ilişkiler vardır. $P^T(d, \theta)$ ‘yi $P(d, \theta)$ ‘nın transpozu olarak kabul edersek;

$$P(d, 0^0) = P^T(d, 180^0) \quad (2.5)$$

$$P(d, 45^0) = P^T(d, 225^0) \quad (2.6)$$

$$P(d, 90^0) = P^T(d, 270^0) \quad (2.7)$$

$$P(d, 135^0) = P^T(d, 315^0) \quad (2.8)$$


$P(d, 180^0)$, $P(d, 225^0)$, $P(d, 270^0)$, $P(d, 315^0)$ ’ nin içerdiği bilgilerin dokunun tanımına hiçbir katkısı yoktur. Uzaklık olarak genellikle 1 veya 2 seçilmektedir. $M \times N$ komşuluğa sahip gri seviyeye bir giriş görüntüsünün 0 dan $G-1$ ’e kadar G tane gri seviye içeriyorsa GLCM matrisinin de satır ve sütun sayısı G ’ye eşittir. GLCM matrisi oluşturulurken giriş görüntüsündeki piksellerin belirli bir açı ve uzaklıktaki komşuları ile aynı yoğunluk değerini kaç kez oluşturduklarını hesaplar. Yani i ve j gibi iki tane yoğunluğun belirli uzaklık ve açıda $(\Delta x, \Delta y)$ meydana gelme sıklığından hesaplanmaktadır. $P(i, j | \Delta x, \Delta y)$ matris elemanını iki pikselin frekansını belirtmektedir. Matematiksel olarak aşağıda gösterildiği gibi ifade edilmektedir;

$$A = \begin{cases} 1 & \text{eğer } f(m, n) = i \text{ ve } f(m + \Delta x, n + \Delta y) = j \\ 0 & \text{diğer durumlarda} \end{cases} \quad (2.9)$$

$$P(i, j | \Delta x, \Delta y) = \frac{\sum_{n=1}^{N-\Delta y} \sum_{m=1}^{M-\Delta x} A}{(M - \Delta x)(N - \Delta y)} \quad (2.10)$$

$$P(i, j | \Delta x, \Delta y) = \frac{\sum_{n=1}^{N-\Delta y} \sum_{m=1}^{M-\Delta x} A}{(M - \Delta x)(N - \Delta y)} \quad (2.11)$$

Şekil 2.6 ‘da dört gri seviyeye sahip bir giriş görüntüsünün ofset değerleri $d=1$, $\theta=0^0$ alındığı durumda eş-oluşum matrisinin nasıl oluşturulduğuna ait bir örnek gösterilmektedir.



Şekil 2.6. Eş oluşum matrisinin oluşturulması sürecinin örneği

GLCM doku örneklerinin boyutuna çok duyarlıdır. Bu yüzden doku seviyelerin sayısı genellikle azaltılır. 16 gri seviye dokunun ayırt edilebileceği için yeterlidir [77]. Normalleştirilmiş eş oluşum matrisleri elde edilen matristeki her pikselin toplam sayıya bölünmesiyle elde edilir. Bu matris elde edildikten sonra çeşitli özellikler hesaplanır. Haralick ve ark. GLCM’ den hesaplanan on dört tane özellik önermiştir. Daha sonra başka kişilerde yeni özellikler ekleyerek literatüre katkıda bulunmuşlardır. Haralick matrisi oluştururken dört yönün her biri için ayrı ayrı hesaplanıp elde edilen özelliklerin ortalaması alınmasını önermiştir. Ancak genelde 0^0 yön komşuluğu ile enerji, entropi, hareketsizlik, kontrast ve korelasyon’ un denetimsiz doku elde edilmesinde etkili olduğu ispatlanmıştır [78]. Aşağıda bazı özellikler ve açıklamaları verilmiştir;

- Açısal ikinci Moment/ Enerji: Doku homojenliğini gösterir.

$$Q_1 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} [C(i, j)]^2 \quad (2.12)$$

- Entropi: Rastlantısallık derecesini göstermektedir. Homojen olan görüntüler yüksek entropi gösterirken, homojen olmayan görüntüler düşük entropi gösterir.

$$Q_2 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} C(i,j) \log_2 C(i,j) \quad (2.13)$$

- Kontrast/ İkinci Dereceden Unsur Farkı Momenti: Kontrast doku değerini gösterir.

$$Q_3 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} k^2 \{C(i,j)^2\} \quad (2.14)$$

- Korelasyon: Korelasyon matristeki gri seviye değerlerin bağımlılığını hesaplar.

$$Q_4 = \frac{\sum_{i=1}^N \sum_{j=1}^N (ij) C(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.15)$$

- Homojenlik/Ters Fark Momenti: Birinci derece ters eleman farkı momentini gösterir.

$$Q_5 = \sum_{i,j=0}^{N-1} \frac{C_{ij}}{1 + (i - j)^2} \quad (2.16)$$

- Ortalama:

$$Q_6 = \sum_{i=2}^{2N} i C(i) \quad (2.17)$$

- Toplam entropi:

$$Q_7 = - \sum_{n=2}^{2N} C(i) \log C(i) \quad (2.18)$$

- Varyans: Bu gri ton varyansının bir ölçüsüdür.

$$Q_8 = \sum_i^N \sum_j^N (i - \mu)^2 C(i, j) \quad (2.19)$$

- Benzersizlik:

$$Q_9 = \sum_i^N \sum_j^N C_{ij} |i - j| \quad (2.20)$$

Uygulamalarda bu özelliklerin hepsi aynı anda kullanılmak zorunda değildir. Örneğin [79]'de dokuma ürünlerinin sınıflandırmasında homojenlik, kontrast, entropi ve enerji özellikleri kullanarak gerçekleştirilmiştir.

2.2.3. Gabor Dalgacık Filtresi

Gabor dalgacıkları dürtü yanıtı bir Gauss fonksiyonuyla çarpılan bir sinüzoidal dalga tarafından tanımlanan filtredir. Gabor dalgacıkları frekans ve yönelim karakteristiklerine göre insan görsel sistemiyle büyük benzerlik gösterir [80]. Gabor dalgacık bölütleme ve doku analizi için sıklıkla kullanılmaktadır [81]. Birçok dalgacık tabanlı yöntem arasında gabor fonksiyonları en uygun çözüm sağlar [82]. Gabor dalgacık filtresi hem uzaysal hem de frekans domainindeki yerel özellikleri ayıklamak için kullanılmaktadır [83]. Gabor dalgacık doku yapısını farklı yer ve yönlerde en uygun biçimde temsil eder.

Dalgacıkların ana avantajı çeşitli çerçeve boyutlarına sahip olmalarıdır [84]. Düşük frekanslar için geniş, yüksek frekanslar için dardır.

2-D Gabor çekirdek 2-D Gaussian fonksiyonundan modüle edilen belirli bir frekans ve oryantasyonda karmaşık bir sinüzoidal fonksiyondur [56]. 2-D Gabor çekirdek matematiksel olarak aşağıdaki gibi tanımlanmaktadır;

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right] \exp(j2\pi Wx) \quad (2.21)$$

σ_x ve σ_y Gaussian'ın büyük ve küçük genişliklerini, W Gabor fonksiyonunun radial frekansıdır. Gabor dalgacık filtresi aşağıdaki formül ile elde edilir;

$$\psi_{mn}(x, y) = a^{-m} g(\tilde{x}, \tilde{y}) \quad (2.22)$$

Denklemdaki m ölçek, n yönelimdir ($m=1,2,\dots,M-1$, $n=1,2,\dots,N-1$).

$$\tilde{x} = a^{-m}(x \cos\theta + y \sin\theta) \quad (2.23)$$

$$\tilde{y} = a^{-m}(-x \sin\theta + y \cos\theta) \quad (2.24)$$

$a > 1$ olduğunda M toplam ölçek sayısı, N kendine bezeyen Gabor filtre bankındaki toplam yönelim sayısıdır. Her yönelim için n, açısı aşağıdaki gibi hesaplanır;

$$\theta = (n\pi)/N \quad (2.25)$$

Ölçek faktörü a^{-m} enerjinin m'den bağımsız olmasını sağlar. Bu yüzden Gabor filtre bankındaki bütün filtreler ölçek ve yönelimlerine bağlı olmadan aynı enerjiye sahiptir.

$$E_{mn} = \int \int_{-\infty}^{\infty} |\psi_{mn}(x, y)|^2 dx dy \quad (2.26)$$

Küçük konvolüsyon maskeleri ile uygun filtre tasarımı mekânsal alanda Gabor filtrelerinin etkin bir şekilde uygulanmasını sağlar [85]. Kusur tespiti için uygun bir Gabor filtresi tasarlamak amacıyla Bondnarova ve arkadaşları esnek şekil, yönelim ve frekansa sahip bir Gabor filtresi kullanmıştır [56]. Uygulamaya bağlı olarak filtre parametreleri ayarlanabilir. Bu filtreyi kullanarak çok çeşitli yerel kusurlar tespit edilebilir. Yukarıdaki denklemlerdeki değişkenler aşağıdaki gibi tanımlanmıştır;

$$\sigma_{x,m,n} = \frac{(a+1)\sqrt{2\ln 2}}{2\pi a^m(\alpha-1)U_l} \quad (2.27)$$

$$\sigma_{y,m,n} = \frac{1}{2\pi \tan \frac{\pi}{2N} \sqrt{\frac{U_h^2}{2 \ln 2} - \left(\frac{1}{2\pi\sigma_{x,m,n}}\right)^2}} \quad (2.28)$$

$$W_{m,n} = a^m U_l \quad (2.29)$$

$$a = (U_h/U_l)^{\frac{1}{M-1}} \quad (2.30)$$

a bir ölçek faktörüdür. U_h ve U_l ilgili üst ve alt frekansı temsil eder. Bir görüntü pikseli, bu pikseldeki Gabor filtresinin cevabına göre kusurlu veya kusursuz olarak sınıflandırılacaktır. Bir T görüntüsünün her pikseli için frekans cevabını belirlemek için, ayrık görüntü Gabor filtresinin gerçek ve sanal kısmı ile evrilir. Ortaya çıkan karmaşık görüntü öğelerinin mutlak değerini, bir ara özellik matrisi oluşturmak için alabiliriz. Bu özellik matrisi, görüntü T ile ilişkili frekans yanıtını veya enerjiyi karakterize eder. Görüntü $T(x, y)$ için boyutu $P \times Q$ ise Gabor dalgacık dönüşümü aşağıdaki formül ile elde edilir;

$$G_{mn}^T(x, y) = \sum_s \sum_t T(x - s, y - t) g_{mn}^* \quad (2.31)$$

Bu filtre, kusur tespiti için giriş görüntüsüne en iyi cevaba sahiptir. Filtrelenen her görüntünün ortalama ve standart sapması bir özellik vektörü olarak hesaplanır ve alınır [86]. Bu büyüklükler görüntünün farklı yönelim ve ölçekteki enerji içeriğini temsil etmektedir [87]. Yönelim ve ölçekte elde edilen sonuçlar özellik vektörü olarak adlandırılır.

$$f(x) = \{\mu_{00}, \sigma_{00}, \mu_{01}, \sigma_{01} \dots\} \quad (2.32)$$

3. LBP-GLCM-GABOR DALGACIK DOKU ANALİZİ TEKNİKLERİNİN KARŞILAŞTIRILMASI


Kalite kontrol uygulamalarında en önemli soru, hangi özellik çıkarım tekniğinin uygulama için en uygun olanıdır. Bu sorunun yanıtını bulabilmek için var olan yöntemlerin eksik ve iyi yönlerinin ortaya çıkarılması gerekmektedir. Doku analizi teknikleri literatürde çeşitli uygulamalarda sıklıkla kullanılan yöntemlerdir. Çalışmada literatürde var olan LBP, GLCM, Gabor Dalgacık filtresi yöntemlerinin karşılaştırılması gerçekleştirilmiştir. Uygulama yapılırken iki farklı veri seti kullanılmıştır. Karşılaştırma işlemi için yapılan çalışmada görüntü iyileştirmesi gerçekleştirilmemiştir. NEU veri tabanı gri skala görüntülerden oluştuğu için herhangi bir ön işlem gerçekleştirilmemiştir. Kumaş veri tabanında ise ön işlem olarak sadece gri skala görüntüye dönüştürülme işlemi gerçekleştirilmiştir. Gri seviye giriş görüntüsüne özellik çıkarım yöntemleri uygulanmıştır. Elde edilen sonuçlar k en yakın komşu algoritması ve destek vektör makinaları ile sınıflandırma işlemi gerçekleştirilmiştir. Sonuçlar karşılaştırılarak hangi yöntem ile sınıflandırmada daha iyi sonuçlar elde edildiği belirlenmiştir.

3.1. Uygulamada Kullanılan Veri Tabanları

Uygulamada Northeastern University (NEU) yüzey hataları ve kumaş görüntülerinden oluşan iki veri tabanı kullanılmıştır. NEU veri tabanı sıcak haddelenmiş çelik şeritlerin yüzey hatalarından oluşmaktadır. Altı farklı yüzey hatası içermektedir. Bu kusurlar haddelenmiş kabuk, yamalar, çatlaklar, oyuklar, kalıntı ve çiziklerdir. Her bir yüzey hatası üç yüz tane örnek resimden oluşmaktadır. Görüntüler 200x200 piksel ve 1.800 gri tonlamalı görüntülerden oluşmaktadır. Kullanılan veri tabanında aydınlatma değişiklikleri ve malzeme değişikliği vardır. Bu durum sınıf içi kusurlarda gri tonların değişmesine sebep olmaktadır.

Kumaş görüntüleri desenli bir kumaşın sağlam ve üzerinde yırtık ve leke olan görüntülerden oluşmaktadır. Veri tabanı her bir sınıfında yetmiş dört tane örnek resimden oluşmaktadır. Görüntüler karanlık ortamda sağ ve soldan ışıklandırılarak elde edilmiştir. Kamera kumaşa paralel şekilde tutularak elde edilmiştir. Görüntüler 16 MP çözünürlüğe sahip kamera tarafından elde edilmiştir ve aynı ortamda elde edildiği için aydınlatma

değişikliği olmamıştır. Fakat görüntü üzerindeki desenler her zaman aynı konumda bulunmamaktadır. Görüntüler 200x200 piksel renkli görüntülerden oluşmaktadır. Şekil 3.1’de her iki sınıfa ait örnekler gösterilmektedir.



Şekil 3.1. Kullanılan iki veri tabanına ait görüntü örnekleri

Görüntüler bölütleme işlemine ihtiyaç duymadığı için sadece özellik çıkarım teknikleri kullanılmıştır. Yapılan çalışmada veri setleri özellik çıkarım yöntemleri kullanılarak elde edilen özellik vektörleri kullanılarak oluşturulmaktadır. Her bir resim için elde edilen bu özellikler kaydedilerek hangi sınıfa ait olduğunu belirten bir etiket eklenmiştir. Şekil 3.2 ‘de oluşturulan bir veri seti örneği bulunmaktadır.

result - Excel																			Oturum	
Dosya Giriş Ekle Sayfa Düzeni Formüller Veri Gözden Geçir Görünüm Power Pivot Ne yapmak istediğinizi söyleyin...																				
Access'ten Web'den Metinden Diğer Tablolardan Varolan Yeni Formül Son Kaynaklar Sorgulan Göster Tümlen Yenile Ozellikler Bağlantılar Düzene Bağlantılar Sırala Filtre Temizle Yenden Uygula Gelmiş Metni Sütunlar Dönüştür Hızlı Doldurma Yineleineni Kaldır Birleştir Veri Doğrulama Veri Modelini Yonet Durum Çözümleme Sayfası Tahmin Gruplandır Grubu Çöz Topla																				
U59																				
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	
9	cr	0,15063	1,87884	0,38139	0,78112	3,37104	0,99416	6,71558	26,4914	2,16699	0,38139	0,69209	-0,35304	0,77881	0,82152	0,01563	0,26394	0,36301	0,97049	
10	cr	0,15863	1,70879	0,56154	0,53268	4,63453	0,99146	9,25472	58,7821	2,15299	0,56154	0,81187	-0,14569	0,536	0,76495	0,01563	0,24682	0,4927	0,90359	
11	cr	0,15053	1,79607	0,53093	0,61212	4,45117	0,99192	8,88654	52,4801	2,21353	0,53093	0,79406	-0,19459	0,61709	0,7732	0,01563	0,27091	0,4727	0,91416	
12	cr	0,16554	1,63373	0,58543	0,45693	4,73324	0,9911	9,45689	62,7722	2,09546	0,58543	0,81993	-0,10603	0,45792	0,75522	0,01563	0,28417	0,51326	0,91083	
13	cr	0,12758	1,81118	0,73874	0,4998	5,58582	0,98884	11,1786	89,9632	2,38452	0,73874	0,89815	-0,11428	0,50106	0,72267	0,01563	0,20679	0,5997	0,82553	
14	cr	0,13858	1,95955	0,37833	0,80891	3,33887	0,9942	6,65121	25,5858	2,24518	0,37833	0,68978	-0,38015	0,80792	0,8226	0,01563	0,22114	0,36066	0,95583	
15	cr	0,14092	1,94616	0,39144	0,78911	3,31061	0,994	6,59356	24,9119	2,24169	0,39144	0,69881	-0,3559	0,78918	0,81679	0,01563	0,24848	0,37265	0,95091	
16	cr	0,14543	1,95616	0,36545	0,82077	3,19496	0,9944	6,36328	23,1272	2,23428	0,36545	0,68228	-0,39956	0,82097	0,83001	0,01563	0,22318	0,34631	0,94781	
17	cr	0,13368	1,87209	0,60874	0,615	5,04026	0,99076	10,0624	69,6337	2,35149	0,60874	0,83752	-0,1825	0,61409	0,75294	0,01563	0,26902	0,52237	0,85045	
18	cr	0,14405	1,79847	0,59881	0,57026	4,76354	0,99091	9,51432	61,7217	2,27068	0,59881	0,82991	-0,16047	0,57224	0,75392	0,01563	0,26333	0,51836	0,87444	
19	cr	0,17235	1,60674	0,59545	0,42664	4,77758	0,99095	9,54732	64,5343	2,07792	0,59545	0,8276	-0,09366	0,4298	0,75423	0,01563	0,31417	0,51717	0,9174	
20	cr	0,13706	1,98358	0,37452	0,81678	3,30566	0,99426	6,58351	24,8646	2,26375	0,37452	0,68507	-0,39287	0,81907	0,82281	0,01563	0,21265	0,35942	0,94312	
21	cr	0,1563	1,67117	0,6326	0,45283	4,8291	0,9904	9,65932	65,4902	2,16934	0,6326	0,84689	-0,10076	0,45358	0,74524	0,01563	0,29144	0,53977	0,89649	
22	cr	0,16543	1,64852	0,59846	0,45818	4,78736	0,99091	9,56134	64,2227	2,12181	0,59846	0,82987	-0,10641	0,46063	0,75398	0,01563	0,30366	0,51826	0,90753	
23	cr	0,12484	1,94744	0,52692	0,70465	4,27733	0,99197	8,53505	46,4355	2,36009	0,52692	0,79094	-0,25869	0,70999	0,77374	0,01563	0,22371	0,47096	0,89219	
24	cr	0,12648	1,81824	0,73394	0,5085	5,66274	0,98891	11,3395	92,9062	2,3858	0,73394	0,89725	-0,11965	0,51238	0,72448	0,01563	0,21237	0,59581	0,82568	
25	cr	0,1413	1,76076	0,66119	0,50356	5,04465	0,98999	10,0932	71,4321	2,27878	0,66119	0,86336	-0,123	0,50817	0,74026	0,01563	0,28083	0,55422	0,86841	
26	cr	0,10454	2,14905	0,48753	0,81268	3,79965	0,99256	7,57672	34,1714	2,52635	0,48753	0,7658	-0,3564	0,81658	0,78476	0,01563	0,1853	0,44455	0,85428	
27	cr	0,14089	1,76125	0,67682	0,49531	5,23698	0,98975	10,4681	77,8149	2,28863	0,67682	0,87004	-0,1187	0,50112	0,73614	0,01563	0,27354	0,56424	0,86628	

Şekil 3.2. Oluşturulan veri seti örneği

3.2. Karşılaştırılan Yöntemler


3.2.1. Gri Seviye Eş- Oluşum Matrisi (GLCM)

GLCM ile görüntü üzerinden özellik çıkarımı işlemi gerçekleştirilebilmesi için görüntünün gri skala görüntü olması gerekmektedir. GLCM yönteminde eş-oluşum matrisi elde edildikten sonra sınıflandırma işlemini gerçekleştirebilmek için Haralick ve arkadaşlarının önerdiği istatistiksel özellik çıkarım yöntemleri uygulanmaktadır. Sınıflandırmada kullanılacak en uygun özellikleri bulmak için farklı ayarlar test edilmektedir. Bu sayede hangi ayarlarda daha iyi sonuçlar elde edileceğinin araştırılması yapılmaktadır. Aşağıdaki tabloda değiştirilen ayarlar gösterilmiştir. Yapılan çalışma kapsamında çeşitli özellikler çıkarılarak hangi özellikler ile daha iyi sonuçlar elde edildiği belirlenmiştir. Tablo 3.1’ de uygulamada kullanılan ayarlar ve Haralick özellik çıkarım yöntemleri gösterilmiştir.

Tablo 3.1. Uygulamada kullanılan GLCM yönteminin ayarları

Yön (offset)	Uzaklık (distance)	Özellikler
[0,1]	1	Enerji
[-1,1]	1	Kontrast
[-1,0]	1	Toplam entropi
[-1,-1]	1	Korelasyon
[0,1]	2	Varyans
[-1,1]	2	Homojenlik
[-1,0]	2	Ortak maksimum
[-1,-1]	2	Ters fark momenti
[0,1]	2	Toplam ortalama
[-1,1]	2	Toplam varyans
[-1,0]	2	Entropi
[-1,-1]	2	Fark varyansı
		Fark entropisi
		IMC1
		IMC2
		Benzersizlik

Aşağıdaki Şekil 3.3 ’ de GLCM uygulamasına ait işlemlerin bir örneği gösterilmektedir.



Şekil 3.3. GLCM yöntemini uygulamasına ait örnek gösterim


3.2.2. Yerel İkili Örüntü (LBP)

Bu çalışmada orijinal LBP kullanılarak hem döndürme değişmezliğinin sınıflandırma üzerinde etkisi olup olmadığı hem de malzeme değişikliği olmamasının sınıflandırma üzerine etkisi incelenmektedir. Tablo 3.2’de temel LBP yönteminin dönüdrme değişmezli varken ve yokken elde edilecek çıktı sayıları gösterilmiştir.

Tablo 3.2. Uygulamada kullanılan LBP ayarları ve elde edilen çıktı boyutu

Daire İçindeki Komşu Sayısı	Yarıçap	Döndürme Değişmezliği	Çıktı
8	1	Var	10
8	1	Yok	59

LBP ile görüntü üzerinden özellik çıkarımı işlemi gerçekleştirilebilmesi için görüntünün gri seviye görüntü olması gerekmektedir. Alınan görüntü LBP ile işlendikten sonra bir özellik histogramı elde edilmektedir. Elde edilen bu değerler sınıflandırma için kullanılan özelliklerdir. Normalde bir görüntüden 256 veri elde edilmektedir. Rastgele oluşan verileri çıkardığımız zaman döndürme değişikliği yokken 10 tane, döndürme değişikliği varken 59 tane veri elde edilmektedir. Aşağıdaki Şekil 3.4 ’de yapılan işlemin bir örneği gösterilmektedir.



Şekil 3.4. LBP yönteminin uygulanmasına ait örnek


3.2.3. Gabor Dalgacık Filtresi

Gabor özellik vektörleri yönelim ve ölçeğe bağlı olarak matrisin her birine ait istatistiksel değişkenlerinin bir vektör oluşturacak şekilde birleştirilmesi ile oluşur [88]. Yapılan çalışmada farklı yönelim ve ölçeklerde nasıl sonuçlar verdiği incelemiştir. Aşağıdaki tabloda yönelim ve ölçeklerde oluşan özellik sayıları örneği verilmiştir. Yapılan çalışmada L1 norm ve normalleştirme işlemi gerçekleştirilmiştir. Çalışmada alt ve üst merkezi frekans $U_h = 0,5$ $U_l = 0,005$ seçilmiştir. Tablo 3.3’ de uygulamada kullanılan Gabor dalgacık filtresine ait ayarlar gösterilmiştir.

Tablo 3.3. Uygulamada kullanılan Gabor dalgacık filtresine ait ayarlar

Yönelim	Ölçek	Çıktı
4	3	24
8	5	80
5	3	30
8	3	48
9	3	54

Yerel doku bölgeleri uzaysal olarak homojen kabul edilir ve dönüşüm katsayılarının büyüklüğünün ortalaması ve standart sapması bölgeyi sınıflandırmak için kullanılmaktadır [81]. Yönelim dört, ölçek üç seçildiğinde yirmi dört özellik, yönelim beş, ölçek sekiz seçildiği zaman seksen bir özellik elde edilmiştir. Aşağıdaki Şekil 3.5’ de Gabor dalgacık filtresi ile gerçekleştirilen uygulamanın bir örneği gösterilmektedir.



Şekil 3.5. Gabor dalgacık yöntemi uygulamasına ait bir örnek

3.3. Sınıflandırma Sonuçları

Yapılan çalışmada LBP, GLCM, Gabor Dalgacık yöntemleri NEU veri tabanı ve oluşturulan kumaş veri tabanı üzerinde ayrı ayrı gerçekleştirilmiştir. Elde edilen özellikler iki farklı sınıflandırma yöntemi (K en yakın komşu ve Destek vektör makinaları) kullanılarak doğruluk oranları, hassasiyetleri ve anmaları tek tek hesaplanarak tablolar şeklinde ayrı başlıklar altında gösterilmiştir.

3.3.1. GLCM

GLCM yöntemi Tablo 3.2’de gösterilen ayarlara teker teker ayarlanarak her ayarlama hangi sonuçlar elde edildiği incelenmiştir. Özellik çıkarımı işlemi tabloda gösterilen on yedi yöntemin hepsi kullanılarak elde edilmiştir. Her bir ayarda NEU veri seti ve kumaş veri seti kullanılarak özellikler elde edilmiştir. Daha sonra elde edilen özellikler KNN sınıflandırıcı ve DVM sınıflandırıcılar kullanılarak karmaşıklık matrisi elde edilmiştir. Tablo 3.4 ve Tablo 3.5’de NEU veri tabanından elde edilen, Tablo 3.6 ve Tablo 3.7’de kumaş veri tabanından elde edilen karmaşıklık matrisi sonuçları gösterilmektedir. Tablo 3.4 ‘de NEU veri tabanının GLCM kullanılarak her bir ayarda elde edilen veri setlerin KNN sınıflandırıcıları kullanılarak elde edilen karmaşıklık matrisinden hesaplanan değerler gösterilmektedir.

Tablo 3.4. NEU veri tabanı kullanılarak GLCM’ nin farklı ayarlarda elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%92	%91.5	%91.7
[-1,1]	1	%92.8	%92.7	%92.3
[-1,0]	1	%92.1	%92.3	%92.2
[-1,-1]	1	%93.2	%93	%92.8
[0,1]	2	%91.3	%91,3	%91,3
[-1,1]	2	%93,4	%93,4	%92,7
[-1,0]	2	%91.9	%91,8	%91,9
[-1,-1]	2	%93,3	%93,3	%93,3

Tablo 3.5 ‘de NEU veri tabanının GLCM kullanılarak elde edilen sonuçların DVM sınıflandırıcısı kullanılarak oluşturulan karmaşıklık matrisinden hesaplanan sonuçları verilmiştir.

Tablo 3.5. NEU veri tabanı kullanılarak GLCM’ nin farklı ayarlarda elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%91.1	%90.8	%90.5
[-1,1]	1	%91.2	%91.5	%91
[-1,0]	1	%91.1	%91.5	%91
[-1,-1]	1	%91.6	%91.5	%92
[0,1]	2	%90.1	%90	%90
[-1,1]	2	%91,2	%91,3	%91,2
[-1,0]	2	%90,2	%90,1	%90,1
[-1,-1]	2	%91,4	%91,4	%91,4

Kumaş veri setleri KNN ve DVM sınıflandırma yöntemleri kullanılarak doğruluk, hassasiyet ve anma sonuçları elde edilmiştir. Tablo 3.6’ de KNN sınıflandırıcısı kullanılarak elde edilen sonuçlar, Tablo 3.7’de DVM sınıflandırıcısı ile elde edilen sonuçlar gösterilmektedir.

Tablo 3.6. Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%93.9	%94	%94
[-1,1]	1	%95.2	%94	%93
[-1,0]	1	%91.8	%92	%93
[-1,-1]	1	%95.9	%96	%96
[0,1]	2	%92.5	%92,8	%92,5
[-1,1]	2	%95,9	%96	%95,9
[-1,0]	2	%91,8	%92,1	%91,9
[-1,-1]	2	%93,9	%94	%93,9

Tablo 3.7. Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda elde edilen özelliklerin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%90.5	%88	%88
[-1,1]	1	%97.3	%98	%97
[-1,0]	1	%91.8	%91	%92
[-1,-1]	1	%93.9	%96	%96
[0,1]	2	%87,8	%87,8	%87,8
[-1,1]	2	%94,6	%94,7	%94,5
[-1,0]	2	%93,2	%93,4	%93,2
[-1,-1]	2	%93,2	%93,5	%93,2

3.3.2. LBP

LBP yöntemi döndürme değişmezliği varken ve yokken NEU veri tabanı ve kumaş veri tabanı kullanılarak veri setleri oluşturulmuştur. Döndürme değişmezliği bulunan LBP sınıflandırması işleminde 59 tane özellik elde edilmiştir. Döndürme değişmezliği kullanılmadığı uygulamada 10 tane özellik elde edilmiştir. Oluşturulan veri setleri DVM ve KNN sınıflandırıcılar kullanılarak karmaşıklık matrisi elde edilmiştir. Oluşturulan karmaşıklık matrisinden doğruluk, hassasiyet ve anma değerleri hesaplanmıştır. Tablo 3.8 ‘de NEU veri tabanı kullanılarak DVM ile gerçekleştirilen Tablo 3.9 ‘da ise KNN ile gerçekleştirilen sınıflandırma sonuçları verilmiştir.

Tablo 3.8. NEU veri tabanı kullanılarak LBP’ nin farklı ayarlarda elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Döndürme Değişmezliği	DVM	Hassasiyet	Anma
Yok	%95.6	%96	%95,7
Var	%92.9	%93.4	%92.8

Tablo 3.9. NEU veri tabanı kullanılarak LBP’ nin farklı ayarlarda elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları

Döndürme Değişmezliği	KNN	Hassasiyet	Anma
Yok	%95.1	%95	%95
Var	%91.9	%92	%91.9

Kumaş veri tabanını LBP özellik çıkarım yöntemi kullanılarak oluşturulan kumaş veri setini Tablo 3.10 ‘da KNN sınıflandırıcısı ile elde edilen karmaşıklık matrisi ile hesaplanan sonuçlar ve Tablo 3.11 ‘de DVM ile gerçekleştirilen sınıflandırmadan elde edilen karmaşıklık matrisinden hesaplanan sonuçlar verilmiştir.

Tablo 3.10. Kumaş veri tabanı kullanılarak LBP’ nin farklı ayarlarda elde edilen özelliklerin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Döndürme Değişmezliği	KNN	Hassasiyet	Anma
Yok	%98.6	%98.6	%98.6
Var	%91.8	%92	%91.5

Tablo 3.11. Kumaş veri tabanı kullanılarak LBP’ nin farklı ayarlarda elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Döndürme Değişmezliği	DVM	Hassasiyet	Anma
Yok	%99.3	%99.3	%99.3
Var	%87.8	%87.5	%87.5

3.3.3. Gabor Dalgacık Filtresi

Tablo 3.3’de verilen ayarlar teker teker ayarlanarak Gabor dalgacık filtresi hem NEU veri tabanı hem de kumaş veri tabanı için teker teker kullanılarak veri setleri elde edilmiştir. Tablo 3.12’ de DVM sınıflandırıcısı kullanılarak elde edilen sonuçlar verilmiştir.

Tablo 3.12. NEU veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Ölçek + Oryantasyon	DVM	Hassasiyet	Anma
(3,4)	%86,5	%86,5	%86,5
(5,8)	%85,7	%85,7	%85,7
(3,5)	%86,1	%86	%86,1
(3,8)	%86,6	%87,1	%88,1
(3,9)	%86,6	%86,7	%86,5

Farklı oryantasyon ve ölçeklerdeki Gabor dalgacık filtresi kullanılarak elde edilen NEU veri setinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçlar Tablo 3.13’ de verilmiştir.

Tablo 3.13. NEU veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları

Ölçek + Oryantasyon	KNN	Hassasiyet	Anma
(3,4)	%79,6	%79,5	%79,6
(5,8)	%78,4	%78,5	%78,4
(3,5)	%78,2	%78,1	%79,7
(3,8)	%77,9	%78	%77,95
(3,9)	%78,3	%78,2	%78,3

Kumaş veri tabanı farklı oryantasyon ve ölçeklerdeki Gabor dalgacık filtresi kullanılarak kumaş veri setleri oluşturulmuştur. Tablo 3.14 ‘de DVM sınıflandırıcı ile elde edilen karmaşıklık matrisleri kullanılarak hesaplanan sınıflandırma sonuçları verilmiştir.

Tablo 3.14. Kumaş veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Ölçek + Oryantasyon	DVM	Hassasiyet	Anma
(3,4)	%79,6	%80,2	%79,7
(5,8)	%81	%81,8	%81
(3,5)	%79,6	%80,2	%79,7
(3,8)	%81	%81,8	%81
(3,9)	%81,6	%83	%81,7

Farklı ölçek ve oryantasyonlarda kullanılan Gabor dalgacık filtresinden elde edilen kumaş veri setleri kullanılarak KNN sınıflandırma işleminden sonra elde edilen karmaşıklık matrisinden hesaplanan sonuçlar Tablo 3.15’de verilmiştir.

Tablo 3.15. Kumaş veri tabanının farklı ölçek ve oryantasyonlarda Gabor dalgacık filtresinden elde edilen özelliklerinin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Ölçek + Oryantasyon	KNN	Hassasiyet	Anma
(3,4)	%85,7	%85,7	%85,7
(5,8)	%86,4	%86,8	%86,5
(3,5)	%91,8	%92	%91,9
(3,8)	%89,8	%90,2	%89,8
(3,9)	%88,4	%88,6	%88,5

3.4. Sonuçların Değerlendirilmesi

İyi sonuçlar elde edilebilmesi için veri girdileri ve çıktılarının iyi anlaşılması gerekmektedir. Çıktının doğrulanması için k katlamalı çapraz doğrulama kullanılmaktadır. Bu yöntem başarısının sınanması için girilen veri kümesini k katına böler, test için bir katı tutulur, diğerleri ise eğitimde kullanılır. Bu işlem k değeri kadar devam etmektedir. Yapılan çalışmada k değeri 5 seçilmiştir.

Sınıflandırmada performans ölçütleri karışıklık matrisi üzerinden hesaplanmaktadır. Tablo 3.16’ da ikili sınıflandırma için karmaşıklık matrisi örneği verilmektedir.

Tablo 3.16. Karmaşıklık matrisi örneği

GERÇEK SINIFLAR	TAHMİN SINIFLARI		
		DOĞRU	YANLIŞ
	DOĞRU	DOĞRU POZİTİF	YANLIŞ NEGATİF
	YANLIŞ	YANLIŞ POZİTİF	DOĞRU NEGATİF

Sınıflandırmadaki temel değerlendirme ölçütü doğruluk oranıdır, diğerleri hassasiyet ve anmanın hesaplanmasıdır. Hassasiyet doğru sınıflandırılmış pozitif örneklerin sayısının toplam pozitif örneklere oranıdır. Anma ise doğru sınıflandırılan pozitif örneklerin toplam pozitif ve toplam pozitif tahmin edilen örneklere oranıdır.

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.1)$$

$$Hassasiyet = \frac{DP}{DP + YN} \quad (3.2)$$

$$Anma = \frac{YN}{DP + YP} \quad (3.3)$$

GLCM özellik çıkarım algoritması her iki sınıflandırmada da iyi sonuçlar vermektedir. NEU veri tabanı kullanılarak elde edilen sonuçlar göz önüne alındığı zaman en iyi sonucu yönelim 135° seçildiği zaman elde edilmiştir. Uzaklık bir seçildiği zaman KNN sınıflandırması ve DVM karşılaştırıldığı zaman KNN ile daha yüksek doğruluk oranları elde edilmiştir.

Kumaş görüntüleri ilk önce 400x2000 piksel alınarak GLCM ile özellik çıkarımı gerçekleştirilmiştir. Daha sonra aynı görüntüler 200x200 piksele dönüştürülmüştür. Yapılan bu işlem sonucunda görüntü küçültüldüğü zaman doğruluk oranı yükseldiği gözlemlenmiştir.

Tablo 3.17. NEU veri tabanı kullanılarak iki farklı yönelimde uzaklık birken GLCM özellik çıkarım algoritmasının DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma	Alınan Görüntü Büyüklüğü
[0,1]	1	%85	%85	%85	4000x2000 piksel
[0,1]	1	%90.5	%88	%88	200x200 piksel
[-1,1]	1	%87.1	%87	%87	4000x2000 piksel
[-1,1]	1	%97.3	%98	%97	200x200 piksel

Kumaş veri tabından GLCM ile elde edilen sonuçlar incelendiği zaman en iyi sonuç 45° yönelim seçildiği ve DVM ile sınıflandırılma sonucunda elde edilmiştir.

Tablo 3.18. NEU veri tabanı kullanılarak farklı yönelimlerde uzaklık birken GLCM özellik çıkarım algoritmasının DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%90.5	%88	%88
[-1,1]	1	%97.3	%98	%97
[-1,0]	1	%91.8	%91	%92
[-1,-1]	1	%93.9	%96	%96

Sınıflandırıcılar göz önünde bulundurulduğu zaman GLCM ile elde edilen NEU veri setinden KNN ile gerçekleştirilen sınıflandırmada DVM' ye göre daha iyi sonuçlar elde edilmiştir. Kumaş veri seti ile yapılan çalışmada DVM ile elde edilen sonuçlarda daha iyi sınıflandırma gerçekleştiği görülmüştür. LBP ile yapılan çalışmada ise DVM ile gerçekleştirilen sınıflandırmada daha iyi sonuçlar elde edilmiştir. Gabor dalgacık filtresi kullanılarak gerçekleştirilen uygulamalarda NEU veri setinde DVM ile daha iyi sonuçlar elde edilirken kumaş veri seti kullanılarak elde edilen sonuçlarda KNN ile daha iyi sonuçlar elde edilmiştir.

GLCM ile gerçekleştirilen uygulama sonuçlarında farklı sınıflandırma algoritmalarında farklı yönelim ve sonuçlarda en iyi sonuçlar elde edilmiştir. NEU veri seti ile KNN sınıflandırıcısı kullanılan uygulamada 45^0 yönelim ve iki uzaklık seçildiğinde en iyi sonuç elde edilirken DVM sınıflandırıcısında 135^0 yönelim ve iki uzaklık seçildiğinde en iyi sonuç elde edilmiştir. Kumaş veri seti kullanılan uygulamada KNN sınıflandırıcısı ile elde edilen sonuçlarda en iyi sonuç 135^0 ve iki uzaklıkta daha iyi sonuç elde edilmiştir. DVM ile yapılan uygulamada 45^0 yönelim ve bir uzaklıkta daha iyi sonuçlar elde edilmiştir.

LBP ile yapılan çalışmada KNN sınıflandırıcısında da DVM kullanılan sınıflandırma işleminde de döndürme değişmezliği var olan uygulamalar daha iyi sonuç vermiştir. Gabor dalgacık filtresi ile elde edilen sonuçlarda NEU veri seti elde edilmesi için oryantasyon ve ölçek değerleri KNN sınıflandırıcısında (3,4), DVM sınıflandırıcısında (3,8) en iyi sonuçlar elde edilmiştir. Kumaş veri setinde ise DVM sınıflandırıcısında (3,5), KNN sınıflandırıcısında ise ölçek ve oryantasyonları (3,8) ve (5,8) uygulamaları aynı ve en iyi sonuçlar elde edilmiştir.

Çalışma yapılan bilgisayar işlemci hızı 2,6 GHz'dir. NEU veri tabanı ile gerçekleştirilen çalışmada LBP ile gerçekleştirilen çalışmada her bir görüntüyü ortalama 0,02 saniyede işlemektedir. 1800 görüntü toplamda 14,4 saniyede işlenmiştir. GLCM ile

gerçekleştirilen uygulamada işlem süresi her bir görüntü için 0,018 saniye sürmektedir. Toplam 41,7 saniyede tüm görüntüler işlenmiştir. Gabor dalgacık filtresi kullanılan uygulama 0,03 saniyede, toplamda ise 108 saniyede gerçekleşmiştir. Kumaş veri tabanı ile gerçekleştirilen uygulamada her görüntü için LBP 0,007 saniye, GLCM 0,006 saniye, Gabor dalgacık filtre ile 0,07 saniyede işlenmiştir.

Üç yöntemin en iyi sonuçları karşılaştırıldığı zaman hem NEU veri seti hem de kumaş veri seti ile yapılan çalışmalarda en iyi doğruluk oranı LBP ile elde edilmiştir. Uygulama zamanı göz önünde bulundurulduğu zaman en hızlı işlem GLCM uygulamasında elde edilmiştir.



4. YEREL İKİLİ SINIFLANIRICI KULLANILARAK GELİŞTİRİLMİŞ BİR YAKLAŞIM

Tezin bu bölümünde LBP kullanılarak geliştirilen bir özellik çıkarım yöntemi tanıtılmaktadır. Literatürde var olan LBP yöntemi, Sobel kenar çıkarım algoritmasının kenar çıkarımı için belirli katsayılar kullanarak işlemini gerçekleştirmesinden ilham alınarak geliştirilmiştir. Önerilen yöntem NEU ve kumaş veri seti ile test edilmiş ve başarılı sonuçlar elde edilmiştir.

4.1. Önerilen Yöntem

Temel LBP operatörü ile özellik çıkarılırken 3x3'lük pencere kullanarak sadece merkezdeki pikselin komşuları ile ilişkisi göz önünde tutulmaktadır. Ortadaki piksel ile komşu piksellerin değerleri karşılaştırılarak eğer karşılaştırılan piksel büyükse 1 küçükse 0 yazılmaktadır. Matematiksel olarak aşağıdaki gibi gösterilmektedir.

$$u(y) = \begin{cases} 1, & y \geq 0 \\ 0, & y < 0 \end{cases} \quad (4.1)$$

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p \quad (4.2)$$

Sobel operatörde LBP gibi uygulanması kolay ve verimli bir yöntemdir. Sobel operatörü özellikle bilgisayar görmesi ve görüntü işlemede sıklıkla kullanılmaktadır. Bu operatör kenarlara karşılık gelen yüksek mekânsal frekans bölgelerini vurgular. Sobel operatörde iki tane 3x3 çekirdekler bulunmaktadır. Sobel uygulamada bu çekirdekler giriş görüntüsüne uygulanmaktadır. Fakat bu çalışmada G_x çekirdeği ve LBP' nin karşılaştırışına yapılmış değerleri birleştirilmiştir.

Yapılan çalışmanın ilk aşamasında LBP'de de olduğu gibi merkez piksel ile komşu pikseller karşılaştırılarak komşu piksel büyük veya eşitse '1' değilse '0' yazılmaktadır. Şekil 4.1' de Temel LBP operatörünün piksel değerlerini bulması ile ilgili gerçekleştirdiği işlem gösterilmektedir.

90	200	140
180	172	100
50	181	151

→

0	1	0
1	172	0
0	1	0

Şekil 4.1. Temel LBP operatörü ile komşu piksellerin bulunması

Rakesh [89] yaptığı çalışmada katsayıları hesaplariken merkez ile komşu pikseller arasındaki en büyük farka sahip olan pikseli bulmaktadır. En büyük pikselden başlanarak saat yönünde hesaplama yapılır ve elde edilen değer merkez piksele yazılır.

$$D = \arg \max_{(0,1,2,\dots,8)} |g_k - g_m| \quad (4.3)$$

Yapılan çalışmada hesaplama yapılacak değerler ile Sobel kenar çıkarma algoritmasının G_x çekirdeği çarpılarak yeni bir merkez piksel elde edilmiştir. Bu hesaplama yapılırken aradaki fark en büyük olan değerden itibaren yapılmaktadır. Katsayılar da en büyük değerden başlanılarak çarpılmaktadır. Şekil 4.3’de yapılan bu işlem ile ilgili bir örnek gösterilmiştir.

90	200	140
180	172	100
50	181	151

→

0	1	0
1	172	0
0	1	0

×

-2	-1	0
-1	172	1
0	1	2

Şekil 4.2. Çalışmanın yapılmasına ait örnek

Bu yöntem matematiksel olarak aşağıdaki gibi ifade edilmektedir. $(G_x)_D$ hesaplanan katsayıya bağlı olarak karşılık gelen G_x değeridir.

$$SLBP = \sum_{p=0}^8 s(g_k - g_m) \cdot 2^D \cdot (G_x)_D \quad (4.4)$$

4.2. Deneysel Sonuçlar

Yapılan çalışmada NEU veri tabanı ve kumaş veri tabanı kullanılarak gerçekleştirilmiştir. Veri tabanlarına ait bilgiler Bölüm 3’ de verilmiştir. Bu çalışmada önerilen yöntem iki farklı şekilde uygulanmıştır ve LBP algoritmasından daha iyi sonuçlar elde edilmiştir. Tablo 4.1’de önerilen yöntem ile elde edilen NEU veri setinin DVM ve KNN sınıflandırma sonuçları verilmiştir.

Tablo 4.1. NEU veri tabanı kullanılarak önerilen yöntem ile elde edilen KNN ve DVM sınıflandırma sonuçları

Sınıflandırıcı	Doğruluk	Hassasiyet	Anma
DVM	%96,2	%96,3	%96,7
KNN	%95,4	%95,6	%95,5

Tablo 4.2’ de önerilen yöntem ile elde edilen kumaş veri setinin DVM ve KNN sınıflandırma sonuçları verilmiştir.

Tablo 4.2. Kumaş veri tabanı kullanılarak önerilen yöntem ile elde edilen KNN ve DVM sınıflandırma sonuçları

Sınıflandırıcı	Doğruluk	Hassasiyet	Anma
DVM	%99,3	%99,3	%99,3
KNN	%100	%100	%100

4.3 Bölüm Değerlendirmesi

Endüstriyel ürünlerin hatalı ve hatasız olarak sınıflandırılması işleminin görüntü üzerinden gerçekleştirilmesi için var olan yöntemler incelenmiştir. Bu bölümde LBP yöntemi kullanılarak yeni bir özellik çıkarım yöntemi elde edilmiştir. Yöntem iki farklı

veri tabanı kullanılarak sonuçlar elde edilmiştir. Bölüm 3’de LBP yönteminden elde edilen sonuçlar verilmiştir. LBP yöntemi ve önerilen yöntem karşılaştırıldığında iki veri tabanında da iki sınıflandırma işleminde de LBP yönteminden daha iyi sonuçlar elde edildiği görülmüştür. NEU veri tabanının LBP’ nin döndürme değişmezliği olmadığı durumda elde edilen doğruluk oranları KNN sınıflandırıcısı kullanıldığında %95,1 ve DVM sınıflandırıcısı kullanıldığında %95,6 elde edilmiştir. Önerilen yöntem DVM sınıflandırıcısı %96,2 KNN sınıflandırıcısı %95,4 elde edilmiştir. Kumaş veri tabanının LBP’ nin döndürme değişmezliği olmadığı durumda elde edilen doğruluk oranları KNN sınıflandırıcısı kullanıldığında %98,6 ve DVM sınıflandırıcısı kullanıldığında %99,3 elde edilmiştir. Önerilen yöntem DVM sınıflandırıcısı %99,3 KNN sınıflandırıcısı %100 elde edilmiştir. Önerilen yöntemde LBP de işlem süresi aynıdır.


5. GRİ SEVİYE EŞ OLUŞUM MATRİSİ KULLANARAK ELDE EDİLEN YENİ BİR ÖZELLİK ÇIKARIM YÖNTEMİ

Tezin bu bölümünde aynı gruba ait ürünlerin sınıflandırılması için yeni bir özellik çıkarım yöntemi önerilmektedir. GLCM endüstriyel ürünlerin hata tespitinde sıklıkla kullanılan bir doku analizi yöntemidir. Bu yöntem ile eş oluşum matrisleri oluşturulmaktadır. Daha sonra oluşturulan bu matrislerin her birinden Haralick' in önerdiği istatistiksel özellik çıkarım yöntemleri kullanılarak özellikler elde edilmektedir. Bu bölümde yeni bir özellik çıkarım yöntemi önerilmiştir. Önerilen yöntem NEU veri tabanı ve kumaş veri tabanı üzerinde hem tek kullanılmıştır hem de üçüncü bölüm de kullanılan on yedi özellik ile birlikte kullanılmış ve başarılı sonuçlar elde edilmiştir.

5.1. Önerilen Yöntem

Doku özellikleri piksellerin gri seviyeleri ve komşuluk ilişkilerinden faydalanılarak elde edilen özelliklerdir. GLCM' de çok kullanılan doku özellik çıkarım yöntemlerinden birisidir ve yoğunluk dağılımı, komşu piksellerin bağıl konumu hakkında bilgi verir. Tüm yönlerde hesaplama yapmaya gerek yoktur. 0^0 , 45^0 , 90^0 ve 135^0 yönleri tüm yönlere ait bilgileri içermektedir yani 180^0 , 225^0 , 270^0 ve 315^0 'nin doku tanımına hiçbir katkısı yoktur. Daha önceki çalışmalar incelendiğinde uzaklık genelde 1 veya 2 seçilmektedir. Bu çalışmada da uzaklık 1 iken ve 2 iken 0^0 , 45^0 , 90^0 , 135^0 yönlerde elde edilen özellikler hem KNN sınıflandırıcı hem de DVM sınıflandırıcılar kullanılarak sonuçlar elde edilmiştir.

Eş oluşum matrisi yoğunluk değeri i olan bir piksel ile belirli uzaklık ve açıdaki komşu piksel olarak bilinen yoğunluk değeri j 'nin ne sıklıkta olduğunu göstermektedir. Bir giriş görüntüsünden elde edilen bu yoğunluk bilgileri ile $N \times N$ ' lik bir kare matrisi oluşturulur. Elde edilen eş- oluşum matrisi resim içerisindeki gri değerlerin iki komşu piksellerdeki d mesafesiyle birlikte oluşum sayısını belirli bir açıya ($0^0, 45^0, 90^0, 135^0$) göre görülme sıklığını ifade etmektedir. Şekil 5.1.' de 1 mesafe ve θ açılarının geometrik ilişkileri gösterilmektedir.



Şekil 5.1. GLCM'nin $0^\circ, 45^\circ, 90^\circ, 135^\circ$ yönleri örnekleri

M x N komşuluğa sahip gri seviyeye bir giriş görüntüsünün G tane gri seviye içeriyorsa eş- oluşum matrisinin de satır ve sütun 0 dan G-1'e kadar olur. Eş- oluşum matrisi oluşturulurken giriş görüntüsündeki piksellerin belirli bir açı ve uzaklıktaki komşuları ile aynı yoğunluk değerini kaç kez oluşturduklarını hesaplar. Yani i ve j gibi iki tane yoğunluğun belirli uzaklık ve açıda $(\Delta x, \Delta y)$ meydana gelme sıklığından hesaplanmaktadır. $P(i, j | \Delta x, \Delta y)$ matris elemanını iki pikselin frekansını belirtmektedir. Matematiksel olarak aşağıda gösterildiği gibi ifade edilmektedir;

$$A = \begin{cases} 1 & \text{eğer } f(m, n) = i \text{ ve } f(m + \Delta x, n + \Delta y) = j \\ 0 & \text{diğer durumlarda} \end{cases} \quad (5.1)$$

$$P(i, j | \Delta x, \Delta y) = \frac{\sum_{n=1}^{N-\Delta y} \sum_{m=1}^{M-\Delta x} A}{(M - \Delta x)(N - \Delta y)} \quad (5.2)$$

Şekil 5.2'de dört gri seviyeye sahip bir giriş görüntüsünden $d=1, \theta=0$ alındığı durumda eş- oluşum matrisi oluşturulmasına ait bir örnek gösterilmektedir.

sonular tablolar halinde gsterilmiřtir. Yapılan alıřma kapsamında yeni bir zellik ıkarım yntemi elde edilmiřtir. nerilen bu yntemler hem tek tek hem de bu on yedi zellik ile birlikte kullanıldıđı zaman elde edilen sonular deđerlendirilmektedir. NEU veri tabanı kullanılarak sadece nerilen yntem ile elde edilen veri seti Tablo 5.1 ve Tablo 5.2’de iki farklı sınıflandırıcı kullanılarak elde edilen dođruluk, hassasiyet ve anma sonuları verilmektedir.

Tablo 5.1. NEU veri tabanı veri tabanı kullanılarak GLCM’ nin farklı ayarlarda nerilen yntem ile elde edilen zelliđin KNN sınıflandırıcısı kullanılarak elde edilen sonuları

Ynelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%47,8	%47,7	%47,8
[-1,1]	1	%47,2	%47,5	%47,2
[-1,0]	1	%49,7	%49,4	%49,7
[-1,-1]	1	%49,1	%49,1	%49,1
[0,1]	2	%47,7	%47,3	%47,7
[-1,1]	2	%47,7	%47,7	%46,2
[-1,0]	2	%45,5	%45,5	%45,3
[-1,-1]	2	%46,9	%47	%46,8

Tablo 5.2. NEU veri tabanı veri tabanı kullanılarak GLCM’ nin farklı ayarlarda nerilen yntem ile elde edilen zelliđin DVM sınıflandırıcısı kullanılarak elde edilen sonuları

Ynelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%55,4	%55,1	%55,45
[-1,1]	1	%51,7	%50,8	%51,7
[-1,0]	1	%51,4	%52,2	%54,2
[-1,-1]	1	%48,8	%47,3	%53,2
[0,1]	2	%51,2	%53,1	%51,2
[-1,1]	2	%47,3	%47,2	%47
[-1,0]	2	%51,9	%51	%52
[-1,-1]	2	%51,4	%52,2	%51,3

Kumař veri tabanı kullanılarak sadece nerilen yntem ile elde edilen veri setini KNN sınıflandırıcısı kullanılarak elde edilen dođruluk, hassasiyet ve anma sonuları Tablo 5.3’ de verilmiřtir.

Tablo 5.3. Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%75,5	%75,6	%75,6
[-1,1]	1	%50,3	%49,7	%50,3
[-1,0]	1	%76,2	%76,5	%76,2
[-1,-1]	1	%63,9	%64	%64
[0,1]	2	%73,5	%73,5	%73,5
[-1,1]	2	%50,3	%50,3	%50,4
[-1,0]	2	%71,4	%71,5	%71,5
[-1,-1]	2	%51	%49,8	%51

Kumaş veri tabanı kullanılarak sadece önerilen yöntem ile elde edilen veri setini DVM sınıflandırıcısı kullanılarak elde edilen doğruluk, hassasiyet ve anma sonuçları Tablo 5.4’ de verilmiştir.

Tablo 5.4. Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%71,4	%71,5	%71,5
[-1,1]	1	%44,9	%44,7	%42,2
[-1,0]	1	%59,2	%59,2	%59,2
[-1,-1]	1	%53,7	%54	%53,8
[0,1]	2	%72,1	%72,2	%72,1
[-1,1]	2	%47,6	%47,1	%47,6
[-1,0]	2	%56,5	%56,6	%56,5
[-1,-1]	2	%44,9	%57,7	%44,8

GLCM uygulamalarında birden fazla özellik çıkarım yöntemi beraber kullanılarak doğruluk oranı mümkün olduğunca arttırılmaktadır. Bu çalışmada da NEU veri tabanı kullanılarak Bölüm 3’ de de gösterilen 17 özellik çıkarım yöntemi ve önerilen yöntem ile tüm yönlerde ve iki farklı uzaklıkta GLCM yöntemi ile elde edilen veri setini KNN sınıflandırıcısı kullanılarak elde edilen doğruluk, hassasiyet ve anma sonuçları Tablo 5.5’ de DVM sınıflandırıcısı kullanılarak elde edilen doğruluk hassasiyet ve anma sonuçları Tablo 5.6’ de verilmiştir.

Tablo 5.5. NEU veri tabanı kullanılarak GLCM’ nin farklı ayarlarda on yedi özellik ve önerilen yöntem ile elde edilen özelliğin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%92,5	%92,45	%92,5
[-1,1]	1	%93,1	%93,1	%93,12
[-1,0]	1	%92,1	%92	%92,1
[-1,-1]	1	%93,9	%93,9	%93,9
[0,1]	2	%91,7	%91,4	%91,4
[-1,1]	2	%93,5	%93,5	%93,5
[-1,0]	2	%92,2	%92,3	%92,2
[-1,-1]	2	%93,3	93,3	%93,3

Tablo 5.6. NEU veri tabanı kullanılarak GLCM’ nin farklı ayarlarda on yedi özellik ve önerilen yöntem ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%91,2	%91,2	%91,2
[-1,1]	1	%91,4	%91,46	%91,45
[-1,0]	1	%91,6	%91,6	%91,6
[-1,-1]	1	%91,8	%91,8	%91,3
[0,1]	2	%90,3	%90,3	%90,4
[-1,1]	2	%91,7	%91,6	%91,7
[-1,0]	2	%90,8	%90,8	%90,8
[-1,-1]	2	%91,6	%91,3	%91,7

Bölüm 3’ de doku analizi yöntemlerinin karşılaştırılması uygulamasında GLCM yöntemi için kullanılan literatürde önerilmiş 17 özellik çıkarım yöntemi bu çalışmada da kullanılmıştır. Bu sayede yapılan çalışmanın gerçek uygulamalar için katkısının anlaşılması amaçlanmaktadır. Bu 17 özellik çıkarım yöntemi ve önerilen yöntem ile tüm yönlerde ve iki farklı uzaklıkta GLCM ile elde edilen kumaş veri setini veri seti KNN sınıflandırıcısı kullanılarak elde edilen doğruluk, hassasiyet ve anma sonuçları Tablo 5.7’ de verilmiştir. Tablo 5.8 ‘ de ise bu 17 özellik çıkarım yöntemi ve önerilen yöntem ile tüm yön ve iki farklı uzaklıkta GLCM ile elde edilen kumaş veri setinin DVM sınıflandırıcısı kullanılarak elde edilen doğruluk, hassasiyet ve anma sonuçları verilmiştir.

Tablo 5.7. Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda önerilen yöntem ve on yedi özellik çıkarım yöntemi ile elde edilen özelliğin KNN sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%95,2	%95,3	%95,3
[-1,1]	1	%94,6	%94,7	%94,6
[-1,0]	1	%90,5	%90,8	%90,6
[-1,-1]	1	%95,9	%96	%96
[0,1]	2	%91,8	%92	%91,8
[-1,1]	2	%93,9	%93,9	%94,1
[-1,0]	2	%92,5	%92,6	%92,5
[-1,-1]	2	%95,9	%95,6	%95,9

Tablo 5.8. Kumaş veri tabanı kullanılarak GLCM’ nin farklı ayarlarda önerilen yöntem ve on yedi özellik çıkarım yöntemi ile elde edilen özelliğin DVM sınıflandırıcısı kullanılarak elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%90,5	%90,5	%90,5
[-1,1]	1	%97,3	%97,4	%97,3
[-1,0]	1	%93,2	%93,4	%93,2
[-1,-1]	1	%94,9	%94,7	%94,5
[0,1]	2	%87,8	%87,8	%87,7
[-1,1]	2	%95,2	%95,3	%95,3
[-1,0]	2	%91,8	%92	%91,8
[-1,-1]	2	%94,6	%94,7	%94,6

5.3 Bölüm Değerlendirmesi

Önerilen yöntem iki veri tabanı için de kullanılarak iyi sonuçlar elde edilmiştir. NEU veri tabanı için KNN sınıflandırıcı daha iyi sonuçlar verirken kumaş veri tabanı için DVM veri tabanı kullanılması daha iyi sonuçlar elde edilmesini sağlamaktadır. Uygulamada Bölüm 3’de verilen özellik çıkarım yöntemleri ile birlikte kullanılarak karşılaştırma yapılabilmesi sağlanmıştır. NEU veri tabanı göz önünde bulundurulduğunda önerilen yöntemin tüm yönlerde ve iki sınıflandırıcıda doğruluk oranlarını arttırdığı görülmüştür. Önerilen yöntem tek başına kullanıldığında doğruluk oranının KNN sınıflandırıcısında en düşük doğruluk oranı %45,5 en yüksek doğruluk oranı %49,1 olmuştur. DVM’de ise en düşük %47,3 en yüksek %55,4 doğruluk oranına ulaşmıştır. Kumaş veri tabanında önerilen yöntem tek başına kullanıldığında KNN sınıflandırıcısında en düşük %50,3 en yüksek

%75,6 doğruluk oranlarına ulaşılmıştır. DVM’de en kötü %44,9 en iyi %72,1 doğruluk oranlarına ulaşılmıştır. Bölüm 3’de kullanılan özellik çıkarım yöntemleri ile birlikte kullanıldığında NEU veri tabanında doğruluk oranlarının arttığı görülmüştür. Kumaş veri tabanında ise tek başına kullanıldığı zaman KNN’de en kötü %50,3 en iyi %76,2 doğruluk oranlarına ulaşılmıştır. DVM sınıflandırışı kullanıldığında en kötü %44,9 en iyi %72,1 doğruluk oranına ulaşılmıştır. Bölüm 3’de verilen özellik çıkarım yöntemleri ile birlikte kullanıldığında bazı yönlerde doğruluk oranları artmış bazılarında değişmemiştir. Uygulama süresi yaklaşık olarak 0,006sn’dır. İki veri tabanında da tek başına kullanıldığında daha önce önerilmiş olan ve günümüzde kullanılan özellik çıkarım yöntemleri ile kıyaslandığında kullanılabilecek bir yöntem olduğu görülmüştür.



6. GERÇEK ZAMANLI ÇALIŞABİLİR SİSTEM TASARIMI

Tezin bu bölümünde gerçek zamanlı çalışılabilir bir sistem tasarımı önerilmektedir. Bu bölümde gerçekleştirilen uygulama Bölüm 6'daki yöntemin daha iyi bir sonuç vermesi sağlanmaktadır. Kullanılan veri tabanlarında görüntüde sınıflandırmayı bozacak bir arka plan olmadığı için görüntü bölütleme işlemi gerekmemektedir. Daha önceki doğruluk oranları yüksek olduğu için görüntü iyileştirme işlemi yapılmamıştır. Gerçekleştirilen çalışmada kullanılan bütün özellikler doğruluk oranını yükseltmemektedir. Sonucu kötü etkileyen özellikler çıkarılarak daha iyi sonuçlar elde edilmiştir.

6.1 Önerilen Yöntem

Bölüm 5'de yapılan çalışma hem hız hem de doğruluk oranı açısından gerçek hayatta kullanılabilecek özelliklere sahiptir. Fakat çalışma incelendiğinde kullanılan 17 özelliğin hepsi sınıflandırmanın doğruluk oranını aynı oranda arttırmamaktadır hatta bazı özellikler sınıflandırmanın doğruluk oranını düşürmektedir. Bunun dışında bazı özellikler bir veri tabanında iyi sonuçlar verirken bir başka veri tabanında kötü sonuçlar verebilmektedir.



Şekil 6.1. Sınıflandırma için kullanılan yöntemin akış diyagramı

Şekil 6.1’ de yapılan işlemin akış diyagramı gösterilmektedir. Özellik çıkarım işleminden sonra özellik seçimi işlemi gerçekleştirildiğinde daha iyi sonuçlar elde edilmiştir.

6.2 Deney Sonuçları

Kumaş veri tabanı kullanılarak sadece önerilen yöntem ile elde edilen veri seti Tablo 6.1 ve Tablo 6.2’de iki farklı sınıflandırıcı kullanılarak elde edilen doğruluk, hassasiyet ve anma sonuçları verilmektedir.

Tablo 6.1. Önerilen sistemden elde edilen kumaş veri seti DVM sınıflandırıcısı ile elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%97,3	%95,9	%97,3
[-1,1]	1	%97,3	%97,2	%97,3
[-1,0]	1	%93,9	%93,9	%93,9
[-1,-1]	1	%93,2	%93,2	%93,2
[0,1]	2	%93,2	%93,1	%93,2
[-1,1]	2	%97,3	%97,2	%97,3
[-1,0]	2	%93,2	%93,2	%93,2
[-1,-1]	2	%95,9	%95,8	%95,8

Tablo 6.2. Önerilen sistemden elde edilen kumaş veri seti KNN sınıflandırıcısı ile elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%95,9	%95,9	%95,9
[-1,1]	1	%95,9	%95,9	%95,8
[-1,0]	1	%95,2	%95,2	%95,1
[-1,-1]	1	%96,6	%96,4	%96,6
[0,1]	2	%97,3	%97,2	%97,2
[-1,1]	2	%98,6	%9,6	%98,6
[-1,0]	2	%93,9	%93,9	%93,8
[-1,-1]	2	%98	%97,9	%98

NEU veri tabanı kullanılarak sadece önerilen yöntem ile elde edilen veri seti Tablo 6.3 ve Tablo 6.4’de iki farklı sınıflandırıcı kullanılarak elde edilen doğruluk, hassasiyet ve anma sonuçları verilmektedir.

Tablo 6.3. Önerilen sistemden elde edilen NEU veri seti KNN sınıflandırıcısı ile elde edilen sonuçları

Yönelim	Uzaklık	DVM	Hassasiyet	Anma
[0,1]	1	%91,9	%91,9	%91,8
[-1,1]	1	%92	%91,9	%92
[-1,0]	1	%92,1	%92	%92,1
[-1,-1]	1	%92,4	%92,4	%92,4
[0,1]	2	%90,8	%90,8	%90,7
[-1,1]	2	%91,9	%91,8	%91,9
[-1,0]	2	%91	%91	%91
[-1,-1]	2	%92,2	%92	%92,1

Tablo 6.4. Önerilen sistemden elde edilen NEU veri seti KNN sınıflandırıcısı ile elde edilen sonuçları

Yönelim	Uzaklık	KNN	Hassasiyet	Anma
[0,1]	1	%93,3	%93,2	%93,2
[-1,1]	1	%94	%94	%93,9
[-1,0]	1	%92,6	%92,7	%92,5
[-1,-1]	1	%93,6	%93,5	%93,6
[0,1]	2	%92,8	%92,7	%92,8
[-1,1]	2	%94,3	%94,2	%94,2
[-1,0]	2	%93	%92,9	%93
[-1,-1]	2	%93,6	%93,5	%93,5

6.2 Bölüm Değerlendirmesi

Yapılan çalışmada bazı özellikler çıkarılarak doğruluk oranı artmıştır. NEU veri tabanında 17 özelliğin çoğu kullanılırken Kumaş veri tabanında daha az özellik ile daha iyi sonuçlar elde edilmiştir. Yani bazı özellikler sınıflandırma yaparken sınıflandırma doğruluğunu kötü etkilemektedir. Bölüm 5’de önerilen yöntem iki veri tabanında da genellikle doğruluk oranını arttırdığı görülmektedir. Fakat arttırmadığı durumlarda ise sınıflandırmayı kötü etkilemediği görülmüştür. Bu durum önerilen yöntemin yüzey hataları tespiti için uygun bir yöntem olduğunu ispatlamaktadır.

7. SONUÇLAR

Kabul edilmemesi gereken ürünlerin kabul edilmesi ya da kabul edilmesi gereken ürünlerin hatalı olarak tanımlanması sistemin güvenilirliğini olumsuz yönden etkilemektedir. Bu tür hataların olabildiğince az olması sistemin gerçek hayatta kullanılabilmesi için en önemli kıstaslarından birisidir. Bunun yanında sistemlerden hızlı ve uygun maliyetli olması da beklenmektedir. Bu çalışmada endüstriyel ürünlerin kalite kontrol işlemi için literatürde kullanılmış olan özellik çıkarım yöntemleri incelenerek yeni bir özellik çıkarım yöntemi önerilmesi amaçlanmıştır. Bu amaç doğrultusunda giriş bölümünde görsel denetim kullanılan yayınlar ve çalışmaları bir araya getiren derleme makaleler incelenmiştir. Elde edilen bilgiler doğrultusunda endüstride ürünlerin kontrol edilen özellikleri belirlenmiş, özellik çıkarımın ne olduğu, kalite kontrol için kullanılan özellik çıkarım yöntemlerinin hangi çalışmalarda kullanıldığı verilmiştir.

İkinci bölümde görme tabanlı kalite kontrol yöntemi açıklanmıştır. Tipik bir endüstriyel kontrol sistemlerinde görüntünün elde edilmesi, görüntü iyileştirmesi-bölütleme işlemi, özellik çıkarımı ve sınıflandırma aşamaları gerçekleştirilmektedir. İkinci bölümün devamında sık kullanılan üç farklı doku özellik çıkarım yöntemlerinin matematiksel modelleri açıklanmıştır.

Üçüncü bölümde ikinci bölümde matematiksel modelleri tanıtılan doku özellik çıkarım yöntemlerinin NEU ve kumaş veri tabanları kullanılarak elde edilen iki farklı sınıflandırma sonuçları gösterilmiş ve karşılaştırmaları yapılmıştır. En iyi sonuçlar LBP yöntem ile elde edilmiştir.

Dördüncü bölümde literatürde var olan temel LBP yönteminin geliştirilmesi için bir yöntem önerilmektedir. Yöntem iki farklı veri tabanı kullanılarak gerçekleştirilmiştir. Karmaşıklık matrisleri iki farklı sınıflandırma yöntemi kullanılarak gerçekleştirilmiştir. Önerilen yöntem ile bütün uygulamalarda doğruluk oranlarında artış sağlanmıştır.

Beşinci bölümde GLCM yöntemi için literatürde olmayan yeni bir özellik çıkarım yöntemi önerilmiştir. Çalışmada hem önerilen yöntemin tek kullanıldığında elde edildiği sonuçları hem de bölüm üçte kullanılan on altı yöntem ile birlikte kullanıldığında elde edilen sonuçlar gösterilmiştir. Önerilen yöntem bütün yönler ve iki ayrı uzaklıkta denenmiştir. Çalışma iki farklı veri tabanı üzerinde gerçekleştirilmiştir. Önerilen yöntem yüzey hataları için kullanılabilecek bir yöntem olduğu görülmüştür.

Altıncı bölümde özellik çıkarım yönteminden sonra özellik seçimi işlemi gerçekleştirilmiştir. GLCM yönteminde genellikle özellik seçimi işlemi gerçekleştirilmektedir. Bu işlem ile doğruluk oranı yükselmektedir. Yapılan çalışmada NEU veri tabanı için doğruluk oranlarının %93' den daha fazla olduğu ve kumaş veri tabanında doğruluk oranının %90,8' den daha fazla olduğu ve gerçek zamanlı uygulanabilecek bir sistem olduğu görülmüştür. Özellik seçimi işlemi yapıldığında her iki sınıf için Bölüm 5 'de önerilen yöntemin doğruluk oranlarını yükselttiği ve yüzey hataları için kullanılabilir bir yöntem olduğu görülmüştür.



KAYNAKLAR

- [1] **Brosnan, T. ve Sun, D. W.**, 2002. Inspection and grading of agricultural and food products by computer vision systems—a review, *Computers and electronics in agriculture*, 36(2-3), 193-213.
- [2] **Brosnan, T., ve Sun, D. W.**, 2004. Improving quality inspection of food products by computer vision—a review., *Journal of food engineering*, 61(1), 3-16.
- [3] **Laucka, A., Andriukaitis, D., Valinevicius, A., Navikas, D.**, 2016. Computer vision system for defects detection in PET preform, *In Methods and Models in Automation and Robotics (MMAR), 2016 21st International Conference on IEEE.* (pp. 1280-1285).
- [4] **Malamas, E. N., Petrakis, E. G., Zervakis, M., Petit, L. ve Legat, J. D.**, 2003. A survey on industrial vision systems, applications and tools., *Image and vision computing*, 21(2), 171-188.
- [5] **Davidson, V. J., Ryks, J. ve Chu, T.**, 2001. Fuzzy models to predict consumer ratings for biscuits based on digital image features, *IEEE Transactions on Fuzzy Systems*, 9(1), 62-67.
- [6] **Pastor-Lopez, I., de-la-Pena-Sordo, J., Santos, I. ve Bringas, P. G.**, 2015. Surface defect categorization of imperfections in high precision automotive iron foundries using best crossing line profile. In *Industrial Electronics and Applications (ICIEA), 2015 IEEE 10th Conference on* (pp. 339-344). *IEEE*.
- [7] **Tian, S., Xiangwei, M., Shuxiang, S. ve Jianhui, L.**, 2017. Automatic sorting system design for long bamboo batten. In *Control Science and Systems Engineering (ICCSSE), 2017 3rd IEEE International Conference on* (pp. 233-238). *IEEE*..
- [8] **Whelan, P.**, 1991. Quality vision. *Technology Ireland*, 23(2), 23.
- [9] **Kumar, A.**, 2008. Computer-vision-based fabric defect detection: A survey. *IEEE transactions on industrial electronics*, 55(1), 348-363.
- [10] **Haralick, R. M.**, 1979. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5), 786-804.
- [11] **Hira, Z. M., ve Gillies, D. F.**, 2015. A review of feature selection and feature extraction methods applied on microarray data. *Advances in bioinformatics*, 2015.
- [12] **Rodenacker, K. ve Bengtsson, E.**, 2003. A feature set for cytometry on digitized microscopic images. *Analytical Cellular Pathology*, 25(1), 1-36.
- [13] **Khalid, S., Khalil, T. ve Nasreen, S.**, 2014. A survey of feature selection and

- feature extraction techniques in machine learning. In *Science and Information Conference (SAI)*, 2014 (pp. 372-378). IEEE.
- [14] **Lei, B. J., Hendriks, E. A., Reinders, M. J. T.**, 1999. On feature extraction from images. *MCCWS Project Information and Communication Theory Group*.
 - [15] **Storcheus, D., Rostamizadeh, A. ve Kumar, S.**, 2015. A survey of modern questions and challenges in feature extraction. In *Feature Extraction: Modern Questions and Challenges* (pp. 1-18).
 - [16] **Motoda, H. ve Liu, H.**, 2002. Feature selection, extraction and construction. *Communication of IICM (Institute of Information and Computing Machinery, Taiwan) Vol, 5*, 67-72.
 - [17] **Iwanowski, M., Skoneczny, S. ve Szostakowski, J.**, 1997. Image feature extraction using mathematical morphology. In *Applications of Digital Image Processing XX* (Vol. 3164, pp. 565-573). *International Society for Optics and Photonics*.
 - [18] **Xie, X.**, 2008. A review of recent advances in surface defect detection using texture analysis techniques. *ELCVIA Electronic Letters on Computer Vision and Image Analysis*, 7(3).
 - [19] **Trier, Ø. D., Jain, A. K. ve Taxt, T.**, 1996. Feature extraction methods for character recognition-a survey. *Pattern recognition*, 29(4), 641-662.
 - [20] **Yang, W., Yan, X., Zhang, L. ve Sun, C.**, 2010. Feature extraction based on fuzzy 2DLDA. *Neurocomputing*, 73(10-12), 1556-1561.
 - [21] **Nixon, M. S. ve Aguado, A. S.**, 2012. Feature extraction & image processing for computer vision. *Academic Press*.
 - [22] **Fu, W., Johnston, M. ve Zhang, M.**, 2014. Low-level feature extraction for edge detection using genetic programming. *IEEE transactions on cybernetics*, 44(8), 1459-1472.
 - [23] **ping Tian, D.**, 2013. A review on image feature extraction and representation techniques, *International Journal of Multimedia and Ubiquitous Engineering*, 8(4), 385-396.
 - [24] **Elnemr, H. A., Zayed, N. M., Fakhreldein, M. A.**, 2016. Feature extraction techniques: Fundamental concepts and survey. In *Handbook of Research on Emerging Perspectives in Intelligent Pattern Recognition, Analysis, and Image Processing* (pp. 264-294). IGI Global.
 - [25] **Isabelle, G.**, 2006. Feature Extraction Foundations and Applications. *Pattern Recognition*.

- [26] **Ngan, H. Y., Pang, G. K., ve Yung, N. H.,** 2011. Automated fabric defect detection—a review. *Image and Vision Computing*, 29(7), 442-458.
- [27] **Zhang, X., Xu, W., Pan, R., Liu, J. ve Gao, W.,** 2011. Fabric defect detection based on projected transform for feature extraction. In *Distributed Computing and Applications to Business, Engineering and Science (DCABES), 2011 Tenth International Symposium on* (pp. 192-196). IEEE.
- [28] **Hassan, M. H. ve Diab, S. L.,** 2010. Visual inspection of products with geometrical quality characteristics of known tolerances. *Ain Shams Engineering Journal*, 1(1), 79-84.
- [29] **Brosnan, T. ve Sun, D. W.,** 2002. Inspection and grading of agricultural and food products by computer vision systems—a review. *Computers and electronics in agriculture*, 36(2-3), 193-213.
- [30] **Majumdar, S.,** 1997. Classification of cereal grains using machine vision.
- [31] **Kiss, I. C., Nemeth, G., Chetverikov, D. ve Böröczky, L.,** 1995. On feature extraction for texture analysis. *Periodica Polytechnica Electrical Engineering*, 39(2), 115-130.
- [32] **Tiwari, V. ve Sharma, G.,** 2015. Automatic fabric fault detection using morphological operations on bit plane. *International Journal of Computer Science and Network Security (IJCSNS)*, 15(10), 30.
- [33] **Dong, S., Wang, Y., Zhang, H.,** Capsule segmentation algorithm based on Wavelet Analysis and Constrained Gradient Search. *space*, 2, 2.
- [34] **Gomes, J. F. S. ve Leta, F. R.,** 2012. Applications of computer vision techniques in the agriculture and food industry: a review. *European Food Research and Technology*, 235(6), 989-1000.
- [35] **Mak, K. L., Peng, P. ve Yiu, K. F. C.,** 2009. Fabric defect detection using morphological filters. *Image and Vision Computing*, 27(10), 1585-1592.
- [36] **Sun, D. W. (Ed.),** 2012. Computer vision technology in the food and beverage industries. *Elsevier*.
- [37] **Kaur, M., ve Dhingra, S.,** 2017. Comparative analysis of image classification techniques using statistical features in CBIR systems. In *I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC), 2017 International Conference on* (pp. 265-270). IEEE.
- [38] **Semary, N. A., Tharwat, A., Elhariri, E., ve Hassanien, A. E.,** 2015. Fruit-based tomato grading system using features fusion and support vector machine. In *Intelligent Systems' 2014* (pp. 401-410). Springer, Cham.
- [39] **Zhang, X., Cui, J., Wang, W., ve Lin, C.,** 2017. A study for texture feature

extraction of high-resolution satellite images based on a direction measure and gray level co-occurrence matrix fusion algorithm. *Sensors*, 17(7), 1474.

- [40] **Liu, F., ve Picard, R. W.**, 1996. Periodicity, directionality, and randomness: Wold features for image modeling and retrieval. *IEEE transactions on pattern analysis and machine intelligence*, 18(7), 722-733.
- [41] **Nanni, L., Brahnam, S., Ghidoni, S., Menegatti, E., ve Barrier, T.**, 2013. Different approaches for extracting information from the co-occurrence matrix. *PloS one*, 8(12), e83554.
- [42] **Pawar, M. M., ve Deshpande, M. M.**, 2012. Skin defect detection of pomegranates using color texture features and DWT. In *Computing and Communication Systems (NCCCS), 2012 National Conference on* (pp. 1-5). IEEE.
- [43] **Ruiz, L. A., Fdez-Sarria, A., ve Recio, J. A.**, 2004. Texture feature extraction for classification of remote sensing data using wavelet decomposition: a comparative study. In *20th ISPRS Congress (Vol. 35, No. part B, pp. 1109-1114)*.
- [44] **Tou, J. Y., Tay, Y. H., ve Lau, P. Y.**, 2009. Recent trends in texture classification: a review. In *Symposium on Progress in Information & Communication Technology (Vol. 3, No. 2, pp. 56-59)*.
- [45] **Akarsu, B., Parlak, K. Ş., Karaköse, M.**, 2016, An Improved Approach In Texture Feature Extraction Techniques For Vision Based Quality Control Applications , *7rd International Conference on Advanced Technology &Sciences (ICAT'18), Antalya, Türkiye*
- [46] **Song, K. Y., Kittler, J., ve Petrou, M.**, 1996. Defect detection in random colour textures. *Image and vision computing*, 14(9), 667-683.
- [47] **Kavitha, V., ve Devi, M. R.**, 2018. Citrus Fruit Feature Extraction using Colpromatix Color Code Model. *Global Journal of Computer Science and Technology*.
- [48] **Kekre, H. B., Mishra, D., & Desai, V.**, 2014. Detection of defective pharmaceutical capsules and its types of defect using image processing techniques. In *Circuit, Power and Computing Technologies (ICCPCT), 2014 International Conference on* (pp. 1190-1195). IEEE.
- [49] **Azim, G. A.**, 2015. Identification of textile defects based on GLCM and neural networks. *Journal of Computer and Communications*, 3(12), 1.
- [50] **Mahram, A., Shayesteh, M. G., ve Jafarpour, S.**, 2012. Classification of wood surface defects with hybrid usage of statistical and textural features. In *Telecommunications and Signal Processing (TSP), 2012 35th International Conference on* (pp. 749-752). IEEE.

- [51] **Kunakornvong, P., Tangkongkiet, C., ve Sooraksa, P.,** 2014. Defect detection on air bearing surface with gray level co-occurrence matrix. In *Information and Communication Technology, Electronic and Electrical Engineering (JICTEE), 2014 4th Joint International Conference on* (pp. 1-4). IEEE.
- [52] **Güneş, E. O., Aygün, S., Kırıcı, M., Kalateh, A., ve Çakır, Y.,** 2014. Determination of the varieties and characteristics of wheat seeds grown in Turkey using image processing techniques. In *Agro-geoinformatics (Agro-geoinformatics 2014), Third International Conference on* (pp. 1-4). IEEE.
- [53] **Kiratiratanapruk, K., ve Sinthupinyo, W.,** 2011. Color and texture for corn seed classification by machine vision. In *Intelligent Signal Processing and Communications Systems (ISPACS), 2011 International Symposium on* (pp. 1-5). IEEE.
- [54] **Nasirzadeh, M., Khazael, A. A., ve bin Khalid, M.,** 2010. Woods recognition system based on local binary pattern. In *Computational Intelligence, Communication Systems and Networks (CICSyN), 2010 Second International Conference on* (pp. 308-313). IEEE.
- [55] **Alimohamadi, H., ve Ahmadyfard, A.,** 2009. Detecting skin defect of fruits using optimal Gabor wavelet filter. In *Digital Image Processing, 2009 International Conference on* (pp. 402-406). IEEE.
- [56] **Alimohamadi, H., Ahmadyfard, A., ve Shojaee, E.,** 2009. Defect detection in textiles using morphological analysis of optimal Gabor wavelet filter response. In *Computer and Automation Engineering, 2009. ICCAE'09. International Conference on* (pp. 26-30). IEEE.
- [57] **Liu, H., ve Han, J.,** 2006. Defect detection in textiles using optimal Gabor wavelet filter. In *Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress on* (Vol. 2, pp. 10005-10007). IEEE.
- [58] **Salem, Y. B., & Nasri, S.,** 2010. Automatic recognition of woven fabrics based on texture and using SVM. *Signal, image and video processing*, 4(4), 429-434.
- [59] **Abbaspour-Gilandeh, Y., ve Azizi, A.,** 2016. Identifying Irregular Potatoes by Developing an Intelligent Algorithm Based on Image Processing. *Tarım Bilimleri Dergisi*, 22(1), 32-41.
- [60] **Saludes-Rodil, S., Baeyens, E., ve Rodríguez-Juan, C. P.,** 2015. Unsupervised classification of surface defects in wire rod production obtained by eddy current sensors. *Sensors*, 15(5), 10100-10117.
- [61] **Kunttu, I., Lepistö, L., Rauhamaa, J., ve Visa, A.,** 2006. Fourier-based object description in defect image retrieval. *Machine Vision and Applications*, 17(4), 211-218.

- [62] **Wang, L., Li, A., ve Tian, X.,** 2013. Detection of Fruit Skin Defects Using Machine Vision System. In *Business Intelligence and Financial Engineering (BIFE), 2013 Sixth International Conference on* (pp. 44-48). IEEE.
- [63] **Wang, L., Tian, X., Li, A., ve Li, H.,** 2013. Machine vision applications in agricultural food logistics. In *Business Intelligence and Financial Engineering (BIFE), 2013 Sixth International Conference on* (pp. 125-129). IEEE.
- [64] **Lestrel, P. E. (Ed.),** 2008. *Fourier descriptors and their applications in biology*. Cambridge University Press.
- [65] **Lo Bianco, M.,** 2015. *New shape and texture descriptors for an improved germplasm characterization of the most representative Mediterranean vascular flora, by image analysis technology* (Doctoral dissertation, Università degli Studi di Cagliari).
- [66] **Kakkar, H., ve Kaur, L.** A Review of Image Processing Methods for Fruit Disease Detection.
- [67] **Jiang, J., Cheng, J., ve Tao, D.,** 2012. Color biological features-based solder paste defects detection and classification on printed circuit boards. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2(9), 1536-1544.
- [68] **Blasco, J., Cubero, S., Gómez-Sanchís, J., Mira, P., ve Moltó, E.,** 2009. Development of a machine for the automatic sorting of pomegranate (*Punica granatum*) arils based on computer vision. *journal of food engineering*, 90(1), 27-34.
- [69] **Sun, D. W. (Ed.),** 2016. *Computer vision technology for food quality evaluation*. Academic Press.
- [70] **Zhang, H., ve Li, D.,** 2014. Applications of computer vision techniques to cotton foreign matter inspection: A review. *Computers and electronics in agriculture*, 109, 59-70.
- [71] **Szeliski, R.** 2010. *Computer vision: algorithms and applications*. Springer Science & Business Media.
- [72] **Golnabi, H., ve Asadpour, A.,** 2007. Design and application of industrial machine vision systems. *Robotics and Computer-Integrated Manufacturing*, 23(6), 630-637.
- [73] **Sklansky, J.,** 1978. Image segmentation and feature extraction. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(4), 237-247.

- [74] http://www.scholarpedia.org/article/Local_Binary_Patterns, *Local Binary Patterns*, Matti Pietikäinen, 25.05.2018
- [75] **Nabiyev, V. V., ve Günay, A.**, 2010. LBP yardımıyla görüntüdeki kişinin yaşının bulunması. *Cankaya University Journal of Science and Engineering*, 8(1).
- [76] **Sebastian, V., Unnikrishnan, A., ve Balakrishnan, K.**, 2012. Gray level co-occurrence matrices: generalisation and some new features. *arXiv preprint arXiv:1205.4831*.
- [77] **Albregtsen, F.**, 2008. Statistical texture measures computed from gray level coocurrence matrices. *Image processing laboratory, department of informatics, university of oslo*, 5.
- [78] **Kandaswamy, U., Schuckers, S. A., ve Adjero, D.**, 2011. Comparison of texture analysis schemes under nonideal conditions. *IEEE Transactions on Image Processing*, 20(8), 2260-2275.
- [79] **Ben Salem, Y., ve Nasri, S.**, 2009. Automatic classification of woven fabrics using multi-class support vector machine. *Research Journal of Textile and Apparel*, 13(2), 28-36.
- [80] **Acar, E., Çalışkan, A., ve Sezgin, N.**, 2012. Gabor Dalgacık Dönüşümü Tabanlı Yapay Sinir Ağı Modeli İle Zambak Yaprağı İmgelerinde Pas Hastalıklarının Tespiti. *Journal of Life Sciences*, 1(2).
- [81] **Basturk, A., Ketencioglu, H., Yugnak, Z., ve Yuksel, M. E.**, 2007. Inspection of defects in fabrics using Gabor wavelets and principle component analysis. In *Signal Processing and Its Applications, 2007. ISSPA 2007. 9th International Symposium on* (pp. 1-4). IEEE.
- [82] **Mokhtar, U., Ali, M. A., Hassenian, A. E., ve Hefny, H.**, 2015. Tomato leaves diseases detection approach based on support vector machines. In *Computer Engineering Conference (ICENCO), 2015 11th International* (pp. 246-250). IEEE.
- [83] **Abdulrahman, M., Gwadabe, T. R., Abdu, F. J., ve Eleyan, A.**, 2014. Gabor wavelet transform based facial expression recognition using PCA and LBP. In *Signal Processing and Communications Applications Conference (SIU), 2014 22nd* (pp. 2265-2268). IEEE.
- [84] **Hu, J., Li, D., Duan, Q., Han, Y., Chen, G., ve Si, X.**, 2012. Fish species classification by color, texture and multi-class support vector machine using computer vision. *Computers and electronics in agriculture*, 88, 133-140.
- [85] **Arivazhagan, S., Ganesan, L., ve Bama, S.**, 2006. Fault segmentation in fabric images using Gabor wavelet transform. *Machine Vision and Applications*, 16(6), 356.

- [86] **Salem, Y. B., ve Nasri, S.,** 2010. Automatic recognition of woven fabrics based on texture and using SVM. *Signal, image and video processing*, 4(4), 429-434.
- [87] **Jain, N., ve Salankar, S. S.** Content Based Image Retrieval Using Gabor Texture Feature and Color Histogram.
- [88] **Sweidan, A. H., El-Bendary, N., Hassanien, A. E., Hegazy, O. M., ve Mohamed, A. E. K.,** 2015. Water quality classification approach based on bio-inspired Gray Wolf Optimization. In *Soft Computing and Pattern Recognition (SoCPaR), 2015 7th International Conference of* (pp. 1-6). IEEE.
- [89] **Mehta, R., ve Egiazarian, K.,** 2016. Dominant rotated local binary patterns (DRLBP) for texture classification. *Pattern Recognition Letters*, 71, 16-22.
- [90] **Sivakamasundari, G., & Seenivasagam, V.,** 2018. Classification of leaf diseases in apple using support vector machine. *International Journal of Advanced Research in Computer Science*, 9(1).
- [91] **Patil, J. K., ve Kumar, R.,** 2011. Color feature extraction of tomato leaf diseases. *International Journal of Engineering Trends and Technology*, 2(2), 72-74.
- [92] **Kuang, H., Ding, Y., Li, R., ve Liu, X.,** 2018, Defect detection of bamboo strips based on LBP and GLCM features by using SVM classifier. In *2018 Chinese Control And Decision Conference (CCDC)*. IEEE.
- [93] **Akarsu, B., Parlak, K. Ş., Karaköse, M.,** 2016, A Fast Detection Approach for Road Defects Using Image Processing, *3rd International Conference on Advanced Technology & Sciences (ICAT'16), Konya, Türkiye, Eylül, 2016*.

ÖZGEÇMİŞ

1989 yılında Elazığ’ da doğan Büşra AKARSU, ilköğretim ve lise öğrenimini Elazığ’da tamamladı. 2008 yılında kazandığı Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünden 2013 yılında mezun oldu. 2015 yılında Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim dalında yüksek lisans yapma hakkı kazandı. 2016–2017 yıllarında SAN-TEZ projesinde bursiyer öğrencisi olarak çalıştı. 2017 yılından itibaren Niğde Ömer Halisdemir Üniversitesinde araştırma görevlisi olarak çalışmaya devam etmekte.

