

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**MAKİNE ÖĞRENMESİ YAKLAŞIMLARI KULLANILARAK
DENİM KUMAŞLARDA KUSUR TESPİTİ**

ZEYNEP PINAR

KOCAELİ 2020

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ YAKLAŞIMLARI KULLANILARAK
DENİM KUMAŞLARDA KUSUR TESPİTİ

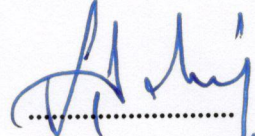
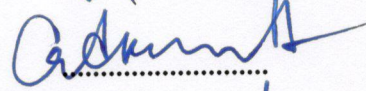
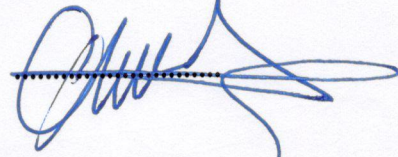
ZEYNEP PINAR

Dr. Öğr. Üyesi (Doç.) Suhap ŞAHİN
Danışman, Kocaeli Üniversitesi

Dr. Öğr. Üyesi Orhan AKBULUT
Jüri Üyesi, Kocaeli Üniversitesi

Dr. Öğr. Üyesi Oktay AYTAR
Jüri Üyesi, Bolu Abant İzzet Baysal Üniversitesi

Tezin Savunulduğu Tarih: 15.01.2020

ÖNSÖZ VE TEŞEKKÜR

Bu çalışmada kumaş kalite kontrolünün tekstildeki önemi vurgulanmış ve denim kumaş çeşidi üzerinde Python programlama dili ile geliştirilen görüntü işleme metodları kullanılarak hata tespit çalışması yapılmıştır. Tespit edilen hata verileri üzerinde sınıflandırma ve kümeleme algoritmalarının çalıştırılması ile hatalı veya temiz olarak ayrımı sağlanmıştır.

Bu çalışmanın sağlanmasında yol göstericiliği, bilgisini benimle paylaşması, sabrı ve güveni için, danışman hocam saygıdeğer Dr. Suhap ŞAHİN'e,

Aynı şekilde, her türlü destek ve yardımda bulunan, bilgilerini benimle paylaşan Arş. Gör. Fidan KAYA GÜLAĞIZ ve Arş. Gör. Mehmet Ali ALTUNCU hocama,

Bu çalışmada kullanılan verilerin toplanmasında yardımlarını esirgemeyen GÜNCEL YAZILIM firması yönetimi ve manevi destekleri için tüm çalışma arkadaşlarıma,

Tüm hayatım boyunca beni her koşulda destekleyen, her adımda arkamda olan, maddi manevi desteklerini esirgemeyen annem Ayşe PINAR ve babam Mehmet PINAR'a,

Benim için ilerleyici güç sağlayan, desteği ile her türlü başarıyı takdir eden sevgili nişanlım Anıl KARADENİZ'e teşekkür ederim.

Ocak – 2020

Zeynep PINAR

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
TABLolar DİZİNİ	iv
SİMGELER VE KISALTMALAR DİZİNİ	v
ÖZET.....	vi
ABSTRACT.....	vii
GİRİŞ	1
1. TEKSTİLDE KALİTE KONTROL.....	2
1.1. Kumaş Kalite Kontrolü	2
1.1.1. Denim kumaşlarda kalite kontrol	2
1.2. Denim Kumaşlarda Hata Tanımları	5
1.2.1. İplik hataları	5
1.2.2. İhzar - indigo hataları	6
1.2.3. Dokuma hataları	7
1.2.4. Terbiye hataları	7
1.3. Denim Kumaşlarda Sık Rastlanan Hata Çeşitleri.....	8
2. LİTERATÜR İNCELEMESİ.....	10
3. MATERYAL METOT	18
3.1. Ağırlık Toplama	18
3.2. Histogram Eşitleme	20
3.3. Fourier Analizi	22
3.4. K-Means Algoritması	23
3.5. J-48 Karar Ağacı Algoritması	24
3.6. Lojistik Regresyon	25
3.7. Naive Bayes Sınıflandırma.....	26
3.8. Derin İleri Beslemeli Sinir Ağı	26
4. BULGULAR VE TARTIŞMA	28
4.1. Görüntülerin Elde Edilmesi.....	28
4.2. Görüntü İşleme Yöntemlerinin Uygulanması	29
4.3. Özellik Matrisinin Elde Edilmesi	30
4.4. Sınıflandırma ve Kümeleme İşlemleri	33
5. SONUÇLAR VE ÖNERİLER	38
KAYNAKLAR	39
KİŞİSEL YAYIN VE ESERLER	43
ÖZGEÇMİŞ	44

ŞEKİLLER DİZİNİ

Şekil 1.1. Manuel kalite kontrol masası	2
Şekil 1.2. Denim kumaş üretim iş akışı	3
Şekil 1.3. Tekstilde kaliteyi etkileyen faktörler	4
Şekil 1.4. Uçuntu hatası	6
Şekil 1.5. Gevşek çözgü hatası.....	6
Şekil 1.6. Pamuklama hatası	7
Şekil 1.7. Terbiye bozuk kenar hatası	8
Şekil 3.1. Pamuklama hatası içeren denim kumaş görüntüsü	20
Şekil 3.2. Griye dönüştürülmüş denim kumaş görüntüsü	20
Şekil 3.3. Histogram eşitleme yapılmış görüntü	22
Şekil 3.4. Pamuklama hatasında Hızlı Fourier Dönüşümü	23
Şekil 3.5. DFF Sinir ağı yapısı	27
Şekil 4.1. Hatalı kumaş fotoğraflarının elde edilmesi.....	28
Şekil 4.2. Temiz kumaş görüntüsü Hızlı Fourier Dönüşümü sinyal grafiği	29
Şekil 4.3. Hatalı kumaş görüntüsü Hızlı Fourier Dönüşümü sinyal grafiği.....	29
Şekil 4.4. Genel iş akışı.....	30
Şekil 4.5. Ara hatası için Fourier spektrumu	31
Şekil 4.6. Karmaşıklık matrisi.....	36

TABLÖLAR DİZİNİ

Tablo 1.1 Denim kumaşlarda sık görülen 15 hata çeşidi	8
Tablo 3.1. DFF Sinir ağı parametreleri	27
Tablo 4.1. Kumaş görüntü işleme aşamaları	33
Tablo 4.2. Sınıflandırma yöntemlerine ait hata oranları	34
Tablo 4.3. Kümeleme yöntemine ait hata oranları	34
Tablo 4.4. J48 yöntemine ait doğruluk değerleri	34
Tablo 4.5. Lojistik Regresyon yöntemine ait doğruluk değerleri	35
Tablo 4.6. DFF Neural Network yöntemine ait doğruluk değerleri.....	35



SİMGELER VE KISALTMALAR DİZİNİ

F_i	: Hata başlangıç değeri
F_t	: Hata tepe değeri
F_s	: Hata bitiş değeri
p_1	: Hata başlangıç değeri ile tepe değeri arası mutlak uzaklık değeri, (cm)
p_2	: Hata tepe değeri ile bitiş değeri arası mutlak uzaklık, (cm)
p_3	: Hata başlangıç değeri ile bitiş değeri arası mutlak uzaklık, (cm)
H	: Hatalı kumaş sınıf etiketi
T	: Temiz kumaş sınıf etiketi

Kısaltmalar

ADD	: Ayrık Dalgacık Dönüşümü
BA	: Bayes Ağları
CoHOG	: Co-occurrence Histograms of Oriented Gradients (Eş oluşum Yönlü Histogram Yönelimleri)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
DFE	: Deep Feedforward Neural Network (Derin İleri Beslemeli Sinir Ağı)
DFT	: Discrete Fourier Transform (Ayrık Fourier Dönüşümü)
FCM	: Fuzzy C-Means (Bulanık C-Ortalamalar)
FFT	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
GPU	: Graphic Processing Unit (Grafik İşlem Birimi)
HOG	: Histograms of Oriented Gradients (Yönlü Histogram Yönelimleri)
KA	: Karar Ağaçları
KEYK	: K En Yakın Komşuluk
PCA	: Principle Component Analysis (Temel Bileşenler Analizi)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
UTİB	: Uludağ İhracatçı Birlikleri Genel Sekreterliği
YSA	: Yapay Sinir Ağları

MAKİNE ÖĞRENME YAKLAŞIMLARI KULLANILARAK DENİM KUMAŞLARDA KUSUR TESPİTİ

ÖZET

Tekstil sektöründe, mamul kumaş üzerindeki üretim hatalarının tespiti, kalite kontrol aşamasında yapılan en önemli ve maliyetli işlerdendir. Kumaşlar konfeksiyon aşamasına gelmeden kontrol edilir ve hatalı kısımlar kumaşın içinden parça halinde kesilerek alınır. Bu durum fireye yani üretimde düşüşe yol açmaktadır. Eğer kontrol esnasında fark edilememiş veya parça alımı ile fireye ayırlanamamış kusurlar varsa bu kumaşlarda ikinci kaliteye düşmektedir. Kalite kontrol sonrası top kesim işleminde ayrılan hatalı parça kumaşlar veya fark edilmeyerek müşteriye gönderilmiş ikinci kalite ürünler ciddi maliyetlere sebep olmaktadır. İnsan gözüyle yapılan kalite kontrol işlemi, iş gücü ve zaman olarak oldukça maliyetli olmasına rağmen başarı istenildiği kadar yüksek değildir. Bu nedenle kalite kontrol aşamasında otomatik ve akıllı sistemlerin kullanımı için çalışmalar yapılmaktadır. Bu çalışmada, %100 pamuk ipliğinden üretilmiş ve indigo boyarmaddesi ile boyanmış olan denim kumaşlardaki hataların tespiti ve sınıflandırılması için görüntü işleme yöntemleri önerilmektedir. Yapılan çalışmada görüntü işleme algoritmaları kullanılarak hata tespiti yapılan kumaş görüntülerinden, özellik çıkarımı ile sayısal veri elde edilmiştir. Oluşturulan özellik matrisi beş farklı algorithmada incelenmiş, hatalı ve hatasız görüntünün ayrımı sağlanmıştır. Yapılan karşılaştırmalarda en iyi performans gösteren algoritmanın J48 Karar Ağacı Algoritması olduğu görülmüştür.

Anahtar Kelimeler: Denim, Görüntü İşleme, Kalite Kontrol.

DEFECT DETECTION IN FABRICS USING MACHINE LEARNING APPROACHES

ABSTRACT

In the textile sector, the detection of production defects on the finished fabric is one of the most important and costly works performed during the quality control stage. The fabrics are checked before they come to the ready to wear stage and the faulty parts are cut into pieces from the fabric. This situation leads to loss of production. If there are any defects that cannot be noticed during the inspection or cannot be separated these fabrics fall to the second quality. After quality control, faulty piece fabrics separated in the finished fabric inspection & roll machine or second quality products sent to the customer unnoticed cause serious costs. Although the quality control process performed by the human eye is quite costly in terms of labor and time, its performance is not as high as desired. For this reason, studies are carried out for the use of automatic and intelligent systems in the quality control stage. In this study, image processing methods are proposed for the detection and classification of defects in denim fabrics produced from 100% cotton yarn and dyed with indigo dyestuff. In this study, numerical data were obtained from feature images which were detected by using image processing algorithms. The feature matrix was examined using five different algorithms and the distinction between error and error-free image was provided. The best performing algorithm was found to be the J48 Decision Tree Algorithm and Logistic Regression.

Keywords: Denim, Image Processing, Quality Control.

GİRİŞ

Kullanılacak bir mal veya ürünün kullanım amaçlarına uygunluk derecesi kalite olarak adlandırılmaktadır. Ürünün alıcının isteklerini karşılaması, memnuniyetini sağlaması kalite standartlarını belirlemektedir (URL-1).


Tekstilde ürün kalitesi, kumaşın hammaddesi olan iplikten başlayarak her aşamada önemle takip edilmektedir. Kumaş hatalarının sebepleri temelde iplik hatalarına dayandığı gibi farklı birçok neden gösterilmektedir. Kumaş hataları ve hata puanlaması ile kalite sınıfları belirlenmekte ve düşük kalite kumaş üretimleri maliyetleri ciddi derecede etkilemektedir. Bu da tekstilde kalite kontrolün önemini artırmaktadır (Kısaoğlu, 2006).

Kumaş hataları giyim endüstrisindeki hataların %85'ini oluşturmaktadır. Eğitimli bir kalite kontrol elemanı hataların %70'ini belirleyebilir. Otomatik sistemler maliyeti düşürürken kaliteyi artırmaktadır. EVS ve Zelleweger Uster firmaları insanın tipik kumaş kontrolünde ancak hataların %40–60 arasında tespit edebildiğini ifade etmektedir. Her iki firmanın sistemleri %80–95 oranında hata tespiti yapabilmektedir. İyi bir kumaş kontrolcüsünün yetişmesi yıllar sürerken, otomatik kontrol sistemlerin kurulması ve çalıştırılması birkaç hafta almaktadır (Dorrity et al., 1995).

1. TEKSTİLDE KALİTE KONTROL

1.1. Kumaş Kalite Kontrolü

Tekstilde hata kontrolü genellikle mamul kumaş için yapılmaktadır. Işıklı kontrol makinaları (Şekil 1.1) üzerinden akan kumaştaki hataları, göz taraması ile kontrol eden personeller bulunmaktadır. Kumaş yüzeyinde görülen her hata eğer düzeltilebilir bir hata ise, makine durdurularak düzeltme veya fire alma işlemi yapıldıktan sonra kontrole devam edilmektedir. Kumaş topunda gelen tüm hatalar personeller tarafından manuel giriş ile ilgili programa kaydedilir ve bitiminde birim metreye düşen hata sayısı baz alınarak kalite sınıfı belirlenmektedir.



Şekil 1.1. Manuel kalite kontrol masası

1.1.1. Denim kumaşlarda kalite kontrol

Denim kumaş çeşidi ile dünya 1850'li yıllarda işçi elbisesi olarak tanışmıştır. 1940'lar da denim giysi üreticilerinin dünya piyasasındaki rekabeti, 1960'lar da başlayan farklı model arayışları, üreticilerin farklı yıkama teknikleri ve farklı renklendirme uygulamaları ile günümüze kadar uzanmıştır. Türkiye'nin denim

kumaş ile tanışması II. Dünya Savaşı sonlarına denk gelmektedir. Amerikan üslerinin kurulması ile askeri elbise olarak kullanılan denim giysiler, Türkler tarafından da rağbet görmüş ve 1958 yılında markalaşmıştır. İlerleyen yıllarda Türkiye'nin tekstil üretimi ülkesi olarak nitelendirilmesi ile denim üretimine yapılan yatırımlar birçok uluslararası markanın üretimlerini Türkiye'ye çekmesini sağlamıştır. Böylece artan üretim ve rekabet anlayışı doğrultusunda kaliteli ürün çıkarma sektörde önemli bir nokta haline gelmiştir (UTİB, 2019).

Denim kumaşlarda kullanılan kalite sistemlerinden 4 puan hata sistemi değerleri;

1 puanlık hatalar: 7,5 cm ve daha küçük hatalar,

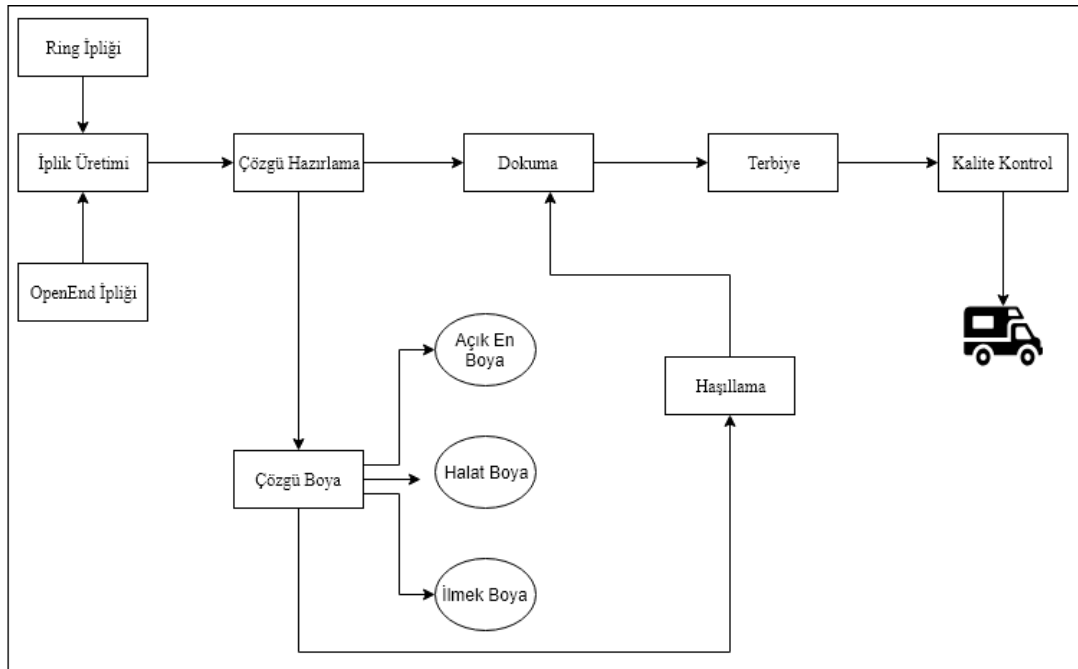
2 puanlık hatalar: 7,5-15 cm arasındaki hatalar,

3 puanlık hatalar: 15-22,5 cm arasındaki hatalar,

4 puanlık hatalar: 22,5 cm'den büyük hatalar olarak hesaplanmaktadır (Gürarda, 2015).

Bu puanlama değerlerine göre kumaş toplarının kalite sınıfı 1.kalite, 1A, 2A ve parça kumaş olmak üzere belirlenir.

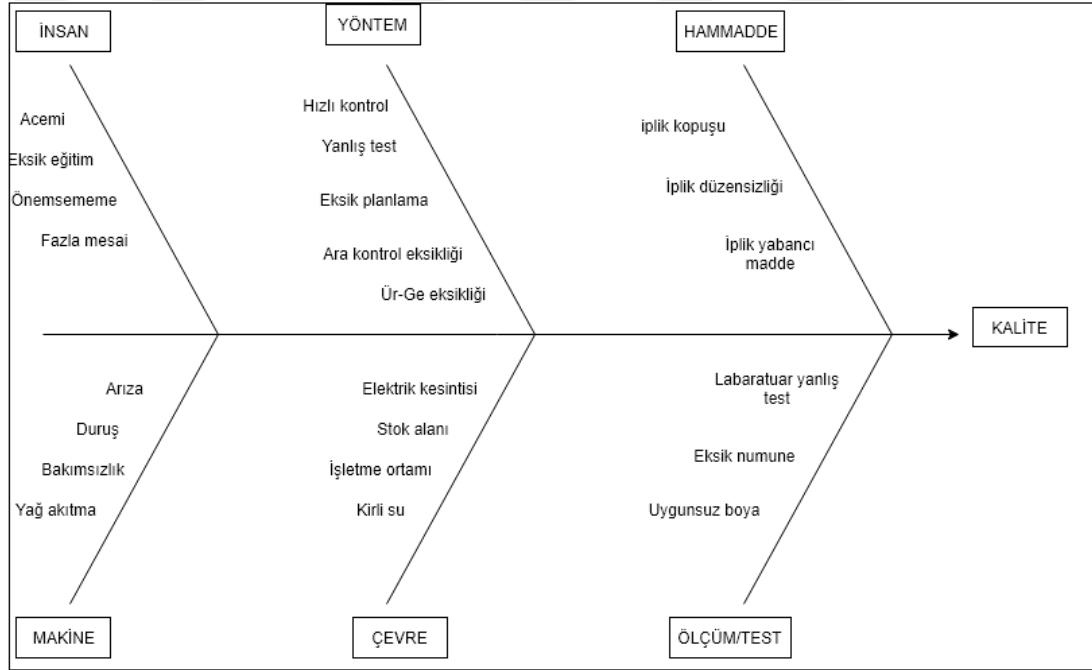
Denim üretimi yapan bir tekstil fabrikasında iplikten başlayarak kalite kontrol aşamasına kadar olan işlemlerin akış diagramı Şekil 1.2'de gösterilmiştir.



Şekil 1.2. Denim kumaş üretim iş akışı

Pamuk, denim üretiminin temel hammaddesi olmakla beraber, bir dizi işlem sonrası kumaş üretimi gerçekleşmektedir. İplikten kaynaklı olarak başlayan ve ilerleyen her bir aşamada kumaşa hataya neden olacak birçok durum oluşmaktadır.

Kumaş hataları literatürde 200'ün üzerinde tanımlanmaktadır fakat pratikte 40-50 kadarı kalite kontrol kartlarına işlenmektedir (Ala ve arkadaşları, 2015). Bu nedenle hataların sıklığı ve türleri geniş bir zaman aralığında takip edilmelidir. Denim işletmelerinde mamul kumaş elde edilirken, iplikten kalite kontrol aşamasına kadar olan süreçte (Şekil 1.2) çeşitli sebeplerden kumaş hataları oluşmaktadır. Şekil 1.3.'de kumaş hatalarına sebep olabilecek faktörler balık kılıçığı diagramı olarak gösterilmiştir.



Şekil 1.3. Tekstilde kaliteyi etkileyen faktörler

Gözle hata tespitinde, operatörün dikkat dağınıklığı, değerlendirmenin objektifliği, işlem zamanı ile birlikte uzun vadede kalitesizliğin maliyete olan etkileri ele alındığında otomatik sistemlerin geliştirilme çalışmalarının sürdürülmesi gerekmektedir (Kısaoğlu, 2006).

1.2. Denim Kumaşlarda Hata Tanımları

Atkı ve çözümlü ipliklerinin dik açılı ve örgü teknikleri ile bir düzen içerisinde birleştirilerek dokuma tezgahlarında tekstil yüzeyi meydana getirilmektedir (Çakır, 2010).

Denim kumaş yapısını diğer kumaşlardan ayıran özelliği çözümlü ipliklerinin indigo boyarmaddesi ile boyanmış olmasıdır. Atkısı boyanmamış ham pamuk ipliği ile çözümlü iplikleri bir araya gelerek denim kumaş yapısı oluşmaktadır (Çakır, 2010). Bu nedenle denim kumaşların kalite standartlarını etkileyen temel sebepler; atkı ve çözümlü ipliklerinin özellikleri, dayanıklılığı, kopuş oranları ve dokuma makinesinin duruşlarından kaynaklanır.

Denim kumaş üretimi aşamalarında hatalar proses bazında gruplanmış ve bunlar; iplik hataları, ihzar-indigo hataları, dokuma hataları, terbiye hataları ve diğer hatalar olarak tanımlanmaktadır.

1.2.1. İplik hataları


Pamuk hammaddesinin işlem göerek iplik haline dönüştürülmesi ile denimde seri çözümlü prosesi başlamaktadır. Her bir iplik bobininin çözümlüye uygun uzunluk ve kalınlıklara göre dizilmesi ile belirlenen sıklıkta iplikler leventlere sarılarak seri çözümlü oluşturulmaktadır. Bu seri çözümlü dikey düzendeki ipliklerdir. Yanlış sıklık, ipliğin yanlış dizimi gibi sebeplerden çözümlü hataları oluşmaktadır. Bu nedenle kumaşın boyuna doğru çeşitli uzunluklarda, top boyunca veya noktasal şekilde çözümlü hataları görülmektedir. Çözümlü hataları genellikle kumaş boyu çözümlüsü bitene kadar devam etmektedir.

Atkı iplikleri, dokuma makinesine bağlanan seri çözümlülerin belirlenen düzende aralarından yatay olarak geçmesiyle kumaş oluşumunu sağlamaktadır. Atkı hataları kumaşın eninde görülen hatalardır. Kumaşın eni boyunca, bir kısmında veya noktasal olarak görülmektedir.

Tanımlanan bazı iplik hataları; atkı iplik düzensizliği, kalın atkı-çözümlü, uçuntu, yabancı elyaf, likra patlağı, ince atkı-çözümlü, atkı kopması, nepsli iplik, bobin

değişimi, atkı-çözgü şantuk balık, düğüm, likrasız atkı, atkı sıyırması, atkı yığılması, gergin-gevşek, atlama-dalma vb.

Şekil 1.4’de iplik kaynaklı hata örneği olarak uçuntu hatası gösterilmiştir.




Şekil 1.4. Uçuntu hatası

1.2.2. İhzar - indigo hataları

Seri çözgü, haşılama ve tahar işlemleri denimde ihzar prosesi olarak bilinmektedir (Buluklu, 2006). Çekilen seri çözgü leventleri birleştirilerek boyama teknelerinden geçirilmektedir. Bu işlemler ile dokumaya girecek çözgü levendi oluşturulmaktadır.

Tanımlanan bazı ihzar hataları; boya abrajı, çift çözgü, gevşek çözgü, haşıl lekesi, düğüm, indigo yağ-kir lekesi, pamuklama, uçuntu vb.

Şekil 1.5’de ihzar hata grubundan gevşek çözgü hata örneği gösterilmiştir.



Şekil 1.5. Gevşek çözgü hatası

1.2.3. Dokuma hataları

Dokuma hataları çözgü yönünde görülmektedir. Tarak dizimi, atkı hazırlama gibi dokuma hazırlık aşamasından kaynaklı hatalardır. Dokuma makinalarındaki duruş, arıza, leke gibi durumlarda hataya sebep olmaktadır.

Tanımlanan bazı dokuma prosesi hataları; atkı düğümü, atlama-dalma, boncuklama, çift atkı, çift çözgü, atkı kaçığı, çözgü kaçığı, çözgü ucu, sık seyrek, yarım atkı, gergin-gevşek, makine duruş izi, bozuk kenar, yağ-kir lekesi, delik-yırtık, pamuklama vb.

Şekil 1.6'da dokuma hata grubuna ait pamuklama hatası gösterilmiştir.



Şekil 1.6. Pamuklama hatası

1.2.4. Terbiye hataları

Denim kumaşlara endüstriyel yıkama işlemleri uygulanarak son görünümleri elde edilmektedir. Bu işlemler kumaşı katma değerli hale getirmektedir. Yıkama proseslerinin doğruluğu, sıcaklık değerleri ve boya alım miktarları kalite kontrol işlemleri ile terbiye işleminden çıktığında kontrol edilmektedir. Terbiye işlemlerinde kumaşı oluşturan pamuk ipliğinin her aşamada aynı boya emilimini sağlaması oldukça zordur. Bu nedenle de kumaşlarda renk varyasyonları oluşmaktadır (Köksal, 2015). Boya işlemleri dışında makine, insan kaynaklı hata ve duruşlar terbiye işlemleri sonrası yapılan kontrollerde gözden kaçmakta ve kalite kontrol işlemi sırasında operatörler tarafından yeniden kontrol edilmektedir.

Sık görülen terbiye hataları; apre lekesi, fil derisi, duruş izi, yağ-kir lekesi, delik-yırtık, sanfor kırığı, kıvrık kenar, boya almamış yer vb.

Şekil 1.7’de terbiye işlemlerinde kumaşa katma değer sağlayan sanfor aşamasında makineden kaynaklanan terbiye bozuk kenar hatası gösterilmiştir.



Şekil 1.7. Terbiye bozuk kenar hatası

1.3. Denim Kumaşlarda Sık Rastlanan Hata Çeşitleri

Denim kumaşlarda kalite kontrol aşamasında sık rastlanan hatalar için istatistiksel bir çalışma yapılmış ve en çok görülen 15 hata çeşidi listelenmiştir. Bu istatistiksel çalışmada kullanılan veriler, tekstil firmalarına yönelik yazılım sistemleri geliştiren Güncel Yazılım firmasının, Leo Textile Quality Control aracına kalite kontrol operatörleri tarafından manuel gözlem ile girişi yapılan kumaş hatalarının kayıt verileri kullanılarak elde edilmiştir.

8 adet kalite kontrol makinası ile çalışan bir denim işletmesinde, 15 gün boyunca girilen hata kodları incelenerek sık karşılaşılan hatalar Tablo 1.1’de gösterilmiştir.

Tablo 1.1. Denim kumaşlarda sık görülen 15 hata çeşidi

Hata Adı	Adet	Yüzde (%)
Çözümlü Kaçığı	5972	18,46
Yarım Atkı	4371	13,51
Atkı Kaçığı	4346	13,43
Atlama Dalma	4187	12,94

Tablo 1.1. (Devam) Denim kumaşlarda sık görülen 15 hata çeşidi

Hata Adı	Adet	Yüzde (%)
Boncuklama	4108	12,70
Sık Seyrek	2686	8,30
Çözücü Ucu	2152	6,65
Gergin Gevşek	1313	4,05
Düğüm	751	2,32
Uçuntu	737	2,28
Pamuklama	658	2,03
Kırık	654	2,02
Delik Yırtık	333	1,02
Leke	52	0,16
Boya Almamış Yer	43	0,13

Tablo 1.1’de çıkan sonuçlara göre en çok karşılaşılan hataların iplik kaynaklı, kumaş dokusunu etkileyen hatalar olduğu görülmüştür.

2. LİTERATÜR İNCELEMESİ

Görüntü işleme günümüzde endüstriyel otomasyon, güvenlik, sağlık ve trafik denetim gibi alanlarda çeşitli yöntemlerde kullanılmaktadır (Altuncu, 2015). Tüm bu kullanım alanları ile birlikte tekstilde önemli bir işlem olan kumaş kalite kontrolü için çeşitli çalışmalar yapılmış ve yapılmaya devam edilmektedir.

Turan (2017), görüntü işleme algoritmalarını eş zamanlı süreçlere ayırarak, kablosuz ağ üzerinden gerçekleşmesi üzerine çalışmalar yapmış, analiz ve test sonuçlarının yapılacak akademik çalışmalara ışık tutması amacıyla önerilerde bulunmuştur. Yapılan tüm karşılaştırma ve analiz sonuçlarına göre görüntü işleme algoritmalarının çalışma süresi için orijinal resmin jpeg formatında en kısa sürede, bitmap formatında en uzun sürede işlem gördüğü belirtilmiştir.

Hanbay (2016) tarafından yapılan çalışmada, tekstil sektöründeki kumaş hatalarının saptanması ve tekstil kalite kontrol sürecinin daha verimli hale getirilmesi amacıyla görüntü işleme yöntemleri kullanılmıştır. Bu amaçla yuvarlak örgü makinesi üzerinde gerçek zamanlı çalışan kumaş hata tespit sistemi gerçekleştirilmiştir. Yuvarlak örgü makinesi üzerine kurulan görüntü alma sistemi ile 6 farklı kumaş çeşidinden 10 farklı kumaş hatası bulunan veri tabanı oluşturulmuş ve bu veri tabanı üzerinde hem frekans hem de uzaysal alanda doku analiz yöntemleri kullanılmıştır. Literatüre kazandırılan GDF-HOG, Eig(Hess)-HOG, ikinci mertebe HOG, Eig(Hess)-CoHOG, GM-CoHOG ve yüzey etiketleme temelli CoHOG olmak üzere 6 yeni öznitelik çıkarma algoritması bilinen algoritmalar ile detaylı olarak karşılaştırılmış ve bunlara ek olarak Fourier, Dalgacık ve Shearlet dönüşüm yöntemleri kullanılarak kumaş görüntülerinin belirli istatistiksel öznitelikleri çıkartılarak sınıflandırılmaları sağlanmıştır. Sınıflandırıcı olarak YSA (Yapay Sinir Ağları) kullanılmıştır. Uzaysal alanda GM-CoHOG algoritmasının en yüksek sınıflandırma başarısına sahip olduğu sonucuna varılmıştır.

Coşkun (2015), tarafından yapılan çalışmada, yünlü kumaşlar üzerinde bulunan neps hatalarının online görüntü işleme metodları kullanılarak çizgi tarama kameraları ile

tespit edilmesi sağlanmıştır. Görüntü işleme çalışmalarının çoğu, kumaş hatalarının incelenmesi ve sınıflandırılması ile ilgilidir, ancak bu çalışma, robotik bir makine tarafından neps temizleme işlemi için kullanılacak neps ve konumlarını belirlemek için online görüntü işleme çalışmaları içermektedir. Klasik görüntü işleme yöntemleri denenmiş ve neps hatası üzerinde en iyi performans gösteren metot belirlenmiştir. Seçilen yöntem bilgisayar kontrollü bir neps temizleyici robot üzerinde denenmiştir. Görüntü işleme metodları için MATLAB ve C ++ derleyicisi tarafından her bir yöntem için yazılım programları hazırlanmıştır. Sonuç olarak, Morfolojik Operasyon metodu neps tipi hataları belirlemek için en uygun yöntem olarak seçilmiştir. Bu nedenle, temel bir görüntü işleme yöntemi olarak kullanılırken, Wigner Distribution yardımcı yöntem olarak kullanılmıştır.

Büyükbaşakal (2010) tarafından yapılan çalışmada, dokuma hatalarının tespiti için operatör kullanılması zaman alıcı ve yüksek hassasiyet sağlamaması nedeniyle otomasyon sistemine odaklanılmıştır. Bu amaçla dokuma hatalarının algılanması, sınıflandırılması için kumaş resimleri kullanılarak, temel bileşenler analizi (PCA) ve yapay sinir ağları (YSA) tabanlı yöntem geliştirilmiştir. Önerilen yöntemde kumaş kusurlarının bilgisayar ortamında tespit edilerek görüntü işleme yöntemleri ve temel bileşen analiz yöntemi ile hatalı bölgeye ait öznitelik vektörünün oluşturulması ve bu vektörün yapay sinir ağına uygulanarak hatanın sınıflandırılmasına dayandırılmaktadır. Sınıflanan hatalar bilgisayarda depolanmakta ve yeni hatanın tespiti için kullanılmaktadır. Dört adet hata grubu için inceleme yapılmıştır. Gereken yazılım Matlab ortamında geliştirilmiş ve yapılan testler sonucunda %66-%100 oranında sınıflandırma başarısı elde edilmiştir.

Güler (2012) tarafından yapılan bir diğer çalışmada, örüntü tanıma yöntemi kullanılarak kumaş hatalarını otomatik olarak tespit edebilen ve sınıflandırma yapabilen bir sistem geliştirilmiştir. Görüntü işleme için Ayrık Dalgacık Dönüşümü (ADD) yöntemi kullanılmıştır. Sınıflandırma için Yapay Sinir Ağlarının ileri beslemeli, geri yayımlı çok katmanlı algoritması kullanılmaktadır. Geliştirilen sistem Merkezi İşlem Birimi (CPU) ve Grafik İşlem Birimi (GPU) üzerinde çalıştırılarak performans değerlendirmesi yapılmıştır. GPU hızını değerlendirmek için NVIDIA GTX 480 ekran kartı kullanılmış ve kartın programlanması için gereken yazılım MATLAB ortamında geliştirilmiştir. Bu yazılım örüntü tanıma

işlem basamaklarını içermektedir. Yapılan hız ve performans testleri sonucunda GPU'nun, CPU'dan daha hızlı ve verimli çalıştığı sonucuna varılmıştır.

Demirer (2010) tarafından yapılan çalışmada, dikiş büzümlerinin hazır giyim endüstrisinde önemli bir kalite faktörü olduğundan yola çıkılarak kalite kontrol yöntemi önerilmiştir. Dikiş büzümlerinin objektif olarak değerlendirilmesi amacıyla ölçüm sistemi ve değerlendirme yöntemi geliştirilmiştir. Ölçüm sistemi çizgi lazer, kamera, hareketli platform ve bilgisayardan oluşmaktadır. Çizgi lazer ile dikiş büzülmesi olmuş kumaş yüzeyi hareketli platform üzerinde taranmakta ve kamera ile elde edilen görüntüler bilgisayara aktarılmaktadır. Aktarılan kumaş görüntüleri 3 boyutlu olarak modellenmektedir. Elde edilen hesaplama sonuçları mevcut sayısal durumlarla karşılaştırılarak dikiş büzülme dereceleri hızlı ve yeterli hassasiyet ile hesaplanmıştır.

Yıldız (2014) tarafından yapılan çalışmada, tekstil endüstrisindeki kalite kontrolün, alt ve üstten ışıklı masalarda kalite kontrol elemanlarının göz denetimiyle yapılmasından kaynaklı, hataların gözden kaçabilme olasılığının yüksek olmasından dolayı yeni yöntem arayışına girilmiştir. Hata tespiti gözle yapıldığından uzun zaman almakta ve hata sınıflandırması kişiden kişiye fark gösterdiğinden objektif olamamaktadır. Bu nedenle yapay görme sistemleri ve görüntü işleme algoritmaları üzerine çalışılmıştır. Kumaş hataları üzerinde görüntü işleme yöntemleri çalıştırılmış ve hatalı bölge tespit edildikten sonra şekilsel ve histogram özellikleri çıkarılmıştır. Bu özellikler kullanılarak Fuzzy C-Means (FCM) algoritması ile kümeleme yapılmıştır. Böylece hatalı bölgenin koordinatları belirlenmiştir. Hatalı görüntüler üzerinde Fourier Analizi, Gabor Filter ve Dalgacık Dönüşümü Yöntemleri ile uygulamalar yapılmıştır. En iyi sonuç veren Fourier Tabanlı görüntü işleme olmuştur. Poplin kumaş üzerinde birçok hata tespiti yapılabilirken, denim ve kaşe kumaş çeşitlerinde algoritmalar cevap vermemiş ve sınırlı sayıda hatayı tanıyabilmiştir. İkinci çalışma olarak görüntü üzerinden değil, hatalı kumaşların videoları üzerinde hata yakalama çalışması yapılmıştır. Hata K En Yakın Komşu (KEYK), Bayes Ağları (BA) ve Karar Ağaçları (KA) algoritmaları kullanılarak anlık olarak sınıflandırılmıştır. Üç farklı kumaş tipinde farklı hata çeşitlerine sahip video üzerinden anlık hata tespiti, sınıflandırma ve yer tespiti yapılmıştır. Sınıflandırma için her bir hata türünden 6 görüntü eğitim verisi olarak kullanılmıştır. KEYK

algoritmasının uygulanmasıyla ortalama %90'lık başarı elde edilmiştir. Diğer algoritmalara göre en iyisi olduğu sonucuna varılmıştır.

Titrek (2016) tarafından yapılan çalışmada, görüntü işleme algoritmaları ile yapılan hata tespit sistemlerinde çoğunlukla makine öğrenmesi kullanılmakta ve her bir malzeme için makinenin eğitilmesi gerektiğinden zaman alıcı olduğuna vurgu yapılmıştır. Aynı zamanda maliyetli bulunan bu yöntemde kumaş desenlerinin kendini tekrarladığı da göz önüne alınarak eğitim aşaması yerine taslak çıkartarak otomatikleşmesi sağlanmıştır. Elde edilen taslak ile test örnekleri frekans alanında basit şekilde karşılaştırılmıştır. Bu yöntem online ve tamamen optimize edilmiş gerçek zamanlı bir hata tespit sistemi olarak gösterilmiştir. Hata tespiti için Fourier Dönüşümünden yararlanılmıştır.

Tekstilde kumaşların görüntülerinden kumaş kusurlarının tespiti ve ekstraksiyonuna yeni bir yaklaşım sunan bir bildiride, tekstil sektöründe kalite kontrolün önemli bir sorun olduğu ve otomatik görsel denetim sistemlerinin yetersiz olduğundan yola çıkılmıştır. Kumaş hatalarının tespiti için görüntü önce bit düzeylerine ayrılmış, daha alt bit düzlemlerinin hataların yeri ve şekli hakkında daha fazla bilgi taşıdığı bulunmuştur. Ardından hatanın matematiksel morfoloji ile kesin yeri bulunmuştur. Algoritma, TILDA I görüntü veri tabanının çeşitli görsel kalitelere sahip bir alt kümesi üzerinde test edilmiştir. Algoritma parametrelerinin değişikliklerine göre performans değerlendirmesi yapılmıştır. Sonuç olarak bitplane ayrıştırma ve matematiksel morfolojiye dayanan yeni bir kumaş hata tespiti ve lokalizasyon algoritması önerilmiştir. Algoritma, hesaplama süresi ve doğruluk açısından varolan yapılara göre daha üstün çalışmaktadır (Priya ve diğ.,2011).

Tekstil kumaş endüstrisi, dokuma gibi alanlarda iyi bir kumaş ile karışmış olabilecek kusurlu iplikler, renk ve gözenek eşitsizliği, gibi hasarlı zeminleri tespit edebilecek filtreleme dayalı kumaşlar için otomatik hata tespit yöntemi öneren bir diğer çalışmada, izleme işlemi kumaş ayrıntılarını yakalamak amacıyla web kamerası ile yapılmıştır. Kumaştaki önemli doku özelliklerinin çıkarılması amacıyla önceden eğitilmiş Gabor dalgacık ağı kullanılmıştır. Yapılan çalışma ile tekstilde kalite kontrol aşamasının hızlı olmasına ve insan kontrolünden daha iyi bir denetim yapılmasına katkıda bulunulmuştur (George ve diğ., 2014).

Görüntü işleme teknikleri kullanılarak basit ve verimli şekilde kumaş hatalarının tespiti ve sınıflandırılması için sistem geliştirilen bir çalışmada, düz bir tarayıcı ile elde edilen kumaş örneklerinin görüntülerini analiz eden Matlab'da geliştirilmiş bir program kullanılarak çözümlü ve atkıdaki hataları tespit eden inceleme süresi önerilmiştir. Dokuma kusurlarıyla ilgili tüm bilgiler bir veri tabanında saklanmıştır. Yapılan çalışmada üç kumaş hatasının (eksik iplikler, yağ lekeleri ve delikler) tespiti için görüntü işleme ve sinir ağlarına dayalı bir sistem uygulanması önerilmiştir. Sistem dört aşamaya göre çalışmaktadır. Görüntü yakalanır, parazit ortadan kaldırılır ve görüntü analizi ile görüntünün keskinliği artırılır. Daha sonra düz çizgi oranı, karanlık alanların oranı ve boşluk oranını karakterize eden üç parametre belirlenir. Son olarak kumaş hatasını tanımak amacıyla sinir ağı kullanılmaktadır. Çalışma diğer hata türlerinin gerçek zamanlı olarak bulunması ve birden fazla hata içeren kumaşların iyileştirilmesi içinde geliştirilebilecek yöntemlere basamak olarak sunulmuştur (Saklı ve diğ., 2014).

(Hanbay ve diğ.,2014) tarafından yapılan çalışmada, tekstilde kumaş kalite kontrolü için kullanılan hata tespit sistemlerinin özellikleri, matematiksel formülasyonları, güçlü ve zayıf yönleri incelenmiştir. Yöntemler sınıflandırılmış ve yediye ayrılarak yapısal, istatistiksel, spektral, model tabanlı, öğrenme, melez ve karşılaştırma olarak belirlenmiştir. İncelenen her metod için ayrıca gürültü hassasiyeti, güvenilirlik, döndürme/ölçekleme bağımsızlığı ve başarı oranı sonuçları ile birlikte bir kalite analizi sunulmaktadır. Yapılan bu incelemeler sonucunda kumaş kalite kontrolünde verimli, maliyeti düşük ve kesin sonuçlar vererek hızlı çalışan bir sistem bulunamamıştır. Ayrıca dokuma ve örgü makinalarında gerçek zamanlı çalışarak tespit yapan sistemlerin oldukça az sayıda olduğu belirtilmiştir. Spektral yaklaşımlarda ise hızlı ve doğru sonuçlar alınmasına rağmen sadece düz kumaş görüntülerinde verimli çalıştığı sonucuna varılmış ve literatür eksiklikleri ortaya konulmuştur.

Dokunmuş kumaş yapılarının otomatik olarak tanımlanması, kumaş yapı bloklarının ayrılmasına yönelik bir çalışmada, birkaç farklı dokuma içeren kumaş yapısının görüntü tanımlama sürecinde ayrımı yapmak için el yöntemi kullanılmaktadır. Hatanın otomatik olarak bulunmasını sınırlandıran bu uygulamaya yeni bir yaklaşım olarak, kumaş dokuma bloklarının otomatik olarak konumlandırılmasını sağlayacak

yöntemler araştırılmıştır. Bu yöntemler; Gauss bulanıklığı, insan-bilgisayar etkileşimi, K-means kümeleme algoritması ve maksimizasyondur. Yapılan çalışmalara göre bu yöntemler farklı kumaş yapılarının, dokunmuş yapı bloklarını, kumaş görüntüsünün tüm parçasından otomatik olarak bulmuş ve ayıklamıştır. Birkaç düzensiz yapı alanına sahip karmaşık kumaş görüntüsünde verimli ve doğru çalışmaktadır (Liu ve diğ., 2014).

Tekstil endüstrisindeki hata bulma sistemlerinin incelendiği bir çalışmada, kullanılan sistemlerin hala insan gözüyle hata tespiti yapıldığı görülmüştür. Bu nedenle biyolojik olarak insan gözünden esinlenerek oluşturulmuş bir bilgisayar sistemi olan yapay görmenin kumaş kusurlarını bulmada hangi aşamalarda kullanılabileceği araştırılmıştır. Kamera veya sensörler ile alınan verilerin anlamlı hale getirilmesiyle yapay görme gerçekleştirilir. Kumaş dokuma kusurları, kumaş üzerindeki lekeler, pamuk ve liflerin ayrımı gibi konularda yapay görme sistemleri kullanılmaktadır. Tüm bu sistemler incelenerek, kumaş hatalarının tümünü tespit edebilen bir yapıya rastlanmamıştır. Yaklaşımların test sonuçlarının istenen düzeyde olmadığı, tespit oranının yüksek olduğunda da maliyetlerin fazlaştığı sonucuna varılmış ve bu alanda çalışmaların devam etmesine vurgu yapılmıştır (Karataş ve diğ., 2016).

Otomatik hata tespit sistemlerinden Cyclops kontrol sistemi, tezgah üzerinde dokunmaya devam eden kumaştaki hata tespitini tezgaha entegre edilmiş kamera yardımı ile belirlemektedir. Sistem atkı ve çözümlü hatalarını %70 başarı bulmaktadır. Qualimaster sistemi, hatalı bölgelerin kumaş topundan kesimi için hata haritasını belirlemektedir. Büyük topların daha küçük toplara bölünmesini optimize ederek hata haritası ve puanlama kriterine göre topun nereden kesilmesi gerektiğini belirler. Elbit I-TEX kontrol sistemi, hataları 300 m/dak kontrol hızında tespit ederek hatanın koordinatlarını harita üzerinde kaydeder. Aynı zamanda hatanın dijital görüntüsü sistem tarafından saklanmaktadır (Gürarda, 2015).

Denim kumaşlarda hata tespiti için Gabor filtresi ve eşikleme metotları kullanılarak bir algoritma geliştirilen bir çalışmada, Gabor filtresi ile hatalı bölge vurgulanarak hatasız bölgeler sönmüştür ve çift eşikleme metodu kullanılarak görüntü ikili (binary) forma dönüştürülmüştür. Morfolojik yöntemler ile gürültüler temizlenmiş hatalı bölgeler ortaya çıkarılmıştır. Çözümlü kaçı, atkı kaçı, delik, lekeli iplik ve

düğüm hatalarını içeren her bir hata için 30 görüntüden oluşturulmuş veritabanı ile çalışılmıştır (Çelik ve diğ.,2013).

Liu ve Qu (2008) kumaş hatalarını incelemek için dalgacık dönüşümü ve yapay sinir ağlarını kullanmıştır. Düz beyaz kumaş üzerinde yağ lekesi, çözgü kaçığı ve atkı kaçığı hatalarını tespiti üzerine çalışılmıştır. 256x256 çözünürlükteki kamera ile alınan görüntüler dalgacık dönüşümü için bilgisayara iletilmiş ve elde edilen görüntü yapay sinir ağlarına girdi olarak verilmiştir. Sınıflandırma başarı %95'e kadar çıkmıştır.

Campbell ve diğ., (1999) boyalı ve normal kumaşlarda hata tespiti için, istatistiksel model tabanlı yaklaşım ile noktasal hataların tespiti üzerine çalışılmıştır. İkinci aşamada hataların tekrarlayan dokuma desenleri içindeki rastgele dağılımı incelenmiş ve arka plandaki farklılıklar Fourier doku analizi ile ayırt edilmiştir. Hata ayırımı yapıldıktan sonra kümeleme algoritmaları ile hatalar sınıflandırılmıştır.

Viladimir ve diğ., (2019) çalışmalarında dijital görüntü işlemeye dayalı, OpenCV kütüphanesi ve Python programlama dili kullanarak hata tespiti ve sınıflandırma yapmışlardır. Kumaşlardaki atkı ve çözgülerin örme düzenindeki farklılıkları saptayarak beş adet kumaş görüntüsü üzerinde yedi farklı hata tespit edilmiş %95 oranında doğru sonuca ulaşılmıştır.

Jianxia ve diğ., (2007) hata tespit sistemlerinde özellik çıkarımının önemli bir temel olduğuna dikkat çekmiştir. Kumaş hatalarında alan parametresi, sınır çevresi, merkez koordinatlarının tanımlanarak hata konumunun belirlenmesi üzerine çalışılmıştır. Hata alanlarının belirlendiği görüntüler gri seviyede olduğundan renk hatalarının saptanmasında bulunan özellik çıkarımı yetersiz kalmıştır.

Zang ve Li, (2009) çalışmalarında görüntü mesafesi farkı aritmetiği olarak yeni bir kumaş hata tespit yöntemi sunmaktadır. Kontrol için kullanıcının kumaş tipine bağlı olarak sistemin kontrol parametrelerini ayarlamasına izin verilmektedir. Görüntünün gri seviyeye dönüştürülmesi ve eşik değeri tanımlanması ve görüntü piksellerinin karşılaştırılmasına dayalı bu sistem 30'dan fazla yaygın hata türünü %92 oranında doğru tespit etmektedir. Görüntü farkı mesafesi aritmetiği gri seviye görüntüye

dayandığından yabancı renk iplikleri tespit edememekte ve kumaş üzerinde oluşan gölgeleri hata olarak algıladığından tam tespit yapamamaktadır.

Hata tespiti için kumaş tiplerinin çeşitliliği, örgü teknikleri ve tanımlanmış hata sayısının çok fazla olması her sistemin başarı alanını daraltmaktadır. Belirli hataları, belirli kumaşlarda saptayan sistemler bulunmaktadır ancak az görüntü ile sınırlı tespitler yapılabilmektedir. Tekstil alanının geneline hitap edecek az maliyetli ve kullanılabilir bir sistem eksikliği devam etmektedir.

Bu çalışmada, denim kumaş kalite kontrolü sırasında en çok rastlanan hata gruplarından (Ala ve ark.,2015) alınan kumaş görüntülerinin hatalı ve hatasız olarak ayrılmasında, sınıflandırma ve karar algoritmalarından en iyi performansa sahip olanın tespit edilmesi amaçlanmıştır. Gerçekleştirilen çalışmanın ileride ürüne dönüştürülebilmesi açısından, kullanılan yöntemler Phyton dili kullanılarak kodlanmıştır. Literatürde kalite kontrol aşamasında hata tespiti yapan sistemlerden, ürüne dönüştürülmüş Cyclops kontrol sistemi, Elbit Vision I-TEX kontrol sistemi ve Uster FabricScan kontrol sistemlerinin manuel hata tespit yöntemleri ile karşılaştırılması üzerine çalışmalar yapılmış avantaj ve dezavantajları ortaya koyulmuştur (Kısaoğlu, 2006). Ancak tarama hızı, kendi kumaş taşıma ünitesini içeren ek makine ve yüksek işçilik gereksinimleri sebebi ile de kullanışlı olmamakla beraber yüksek maliyet gerektirmektedir. Tüm bu örnekler göz önünde bulundurulduğunda tez çalışmasında önerilen hata tespit sisteminin başarısının yüzde 87 oranında olması, 20 çeşit farklı hata içeren veri seti içerisinde hatalı kumaşları tespit edebilmesi ve maliyetli bir ek donanım gerektirmemesi sebebiyle ileride yapılacak ürüne dönüştürme süreçlerine kaynak sağlamaktadır.

3. MATERYAL METOT

Bu çalışmada tekstil kalite kontrolünde hata ayırımı için en iyi performansa sahip algoritmalar üzerine arařtırmalar yapılmıřtır. Denim iřletmesi kalite kontrol blmnden elde edilen 20 çeřit kumař hatası için 52 adet hatalı ve 25 adet temiz kumař grnts olmak zere, 77 adet denim kumař veritabanı olarak kullanılmıřtır. Hata tespiti için ncelikle grnt iřleme yntemlerinden faydalanarak hatanın grntden ayırt edilmesi zerine algoritmalar Python'da kodlanmıřtır.

Hata tespiti iin kullanılacak grnt iřleme ve zellik ıkarım algoritmaları;

1. Ađırlık Toplama
2. Histogram Eřitleme
3. Fourier Analizi

Hatalı ve temiz grntlerin ayırımında kullanılacak kmeleme ve sınıflandırma algoritmaları ařađıdaki gibidir;

1. K-Means Algoritması
2. J48 Karar Algoritması
3. Lojistik Regresyon
4. Naive Bayes Algoritması
5. Derin İleri Beslemeli Sinir Ađı (DFF)

3.1. Ađırlık Toplama

Grnt iřlemede kullanılan renkli bir bařka adıyla RGB (Red, Green, Blue) resimlerin griye dnřtrlmesi diđer algoritmaların alıřtırılması iin kolaylık sađlamaktadır ve genellikle griye dnřtrlmř resim zerinden grnt iřleme yapılmaktadır.

Gri tonlu grntlerde, gri tonunun renk aralıkları $G=\{0,1,2,\dots,255\}$ řeklinde ifade edilmektedir ve 256 adet farklı gri tonu bulunmaktadır. 256 adet gri tonu bir byte olarak Denklem (3.1) ve (3.2) ile ele alınırřa;

$$1\text{byte}=8\text{ bit} \quad (3.1)$$

$$2^8=256 \quad (3.2)$$

adet gri tonundan 0 deęeri siyah ve 255 de beyaza karřılık gelmektedir. Aęırlık toplama ile griye dđnüştürme yönteminde R, G, B kanallarının kendine özđü aęırlıkları uygulanmaktadır. Sırasıyla R, G, B kanallarının aęırlıkları; 0,2126, 0,7152, 0,0722 'dir. Griye dđnüştürme işleminde görüntü piksel piksel Denklem (3.3)'de ele alınmaktadır. Buna göre;

$$Y=\frac{1}{3}(R+G+B) \quad (3.3)$$

denkleminde renkli görüntünün kırmızı, yeřil ve mavi bileřenlerinin aritmetik ortalaması alınarak, Denklem (3.4) ile hesaplanmaktadır (Kanan ve Cottrell, 2012).

$$Y=0,2989R + 0,5870G + 0,1140B \quad (3.4)$$


Python'da aęırlık toplama yöntemi ile resmi griye dđnüştürme adımları ařaęıdaki gibidir;

1. Pil paketinden 'image' kütüphanesi projeye dahil edilir,
2. Resmin çözünürlüğünün genişlik ve yükseklik boyutu deęişkenlere atanır,
3. Çözünürlük deęerleri ile matris oluşturulur,
4. Her pikselin renk deęeri R, G, B deęişkenlerine atanır,
5. Gri tonları R, G, B deęişkenlerinin deęerlerine göre ayarlanır,
6. Her piksel için ayarlanan kırmızı, yeřil, mavi tonuna karřılık gelen gri tonun yine sırasıyla piksel piksel görüntüye işlenir.

Şekil 3.1'de aęırlık toplama yöntemi uygulanarak gri seviyeye dđnüştürülecek pamuklama hatası içeren, Şekil 3.2'de ise gri seviyeye dđnüştürülmüş denim kumař gösterilmiştir.



Şekil 3.1. Pamuklama hatası içeren denim kumaş görüntüsü



Şekil 3.2. Griye dönüştürülmüş denim kumaş görüntüsü

3.2. Histogram Eşitleme

Histogram eşitleme metodu, Otsu metodunun geliştirilmiş hali olarak, hata belirlenecek görüntülerde kullanılmaktadır. Düşük işlem maliyeti ve yüksek çalışma performansı sayesinde önemli avantaja sahiptir. Griye dönüştürülmüş görüntüler hakkındaki piksel bilgisini veren en iyi yöntemlerden olarak kabul edilmektedir (Hanbay, 2016).

Histogram kavramı, görüntünün içerdiği piksel değerlerinin ağırlığını belirten grafiksel bir gösterimdir. Görüntü islemede histogramlar kullanılarak resim daha

belirgin hâle getirilebilir. Daha net bir görüntü için histogramın daha ayırık ve düzgün bir yapıya gelmesi sağlanmalıdır.

g_0, g_1, \dots, g_{L-1} gri değerlerine sahip bir dijital görüntünün histogramı için (3.5) denklemindeki ayırık fonksiyon tanımlanmaktadır. n_k , gri değerlere sahip piksellerin toplam sayısı ve n görüntüdeki toplam piksel sayısı olmak üzere;

$$p(g_k) = \frac{n_k}{n} \quad (3.5)$$

Histogram, dijital bir görüntüde genel bir tanım görünümü elde edilmesini sağlamaktadır. Bir görüntünün gri değerlerini rastgele bir değişken olan R varsayarsak histogram tahmini bir olasılık yoğunluğu verir. Başka bir deyişle eşitlik (3.6) olarak ifade edilmektedir.


$$P(R=g_k) \sim p(g_k) \quad (3.6)$$

Bu durumda histogram eşitlenmiş bir görüntüdeki gri değerli piksellerin toplam olasılık değeri 1 olmaktadır.

Python'da histogram eşitleme yönteminin uygulama adımları aşağıdaki gibidir;

1. Görüntü parametre olarak gönderilir ve renk histogramı hesaplanır,
2. Histogram değerlerini tutacak 256 elemanlık matris tanımlanır,
3. Görüntünün tüm pikselleri için histogram 1 arttırılarak histogram matrisi bulunur,
4. Renk aralıkları toplam boyuta bölünerek renk frekansları bulunur,
5. Kümülatif dağılım fonksiyonu hesaplanır,
6. Görüntüden alınan piksel değerleri ile kümülatif dağılım fonksiyonundan alınan değerler eşlenir.

Şekil 3.2'de gri seviyedeki pamuklama hatası görüntüsüne histogram eşitleme yöntemi uygulanarak Şekil 3.3'deki görüntü elde edilmiştir.



Şekil 3.3. Histogram eşitleme yapılmış görüntü

3.3. Fourier Analizi

Herhangi bir sinyalin sinüs ve kosinüs dalgalarının çeşitli genlik ve frekanslarla toplamından elde edilebileceğini Fourier teoremi açıklamaktadır. Görüntü uzayındaki tekrarlı ve düzenli desene sahip kumaşlar ile uzaysal frekanstaki spektrumları arasındaki ilişki, iki boyutlu Fourier dönüşümü kullanılarak kurgulanmaktadır. $N \times N$ iki boyutlu bir $f(x, y)$ görüntüsü için, x, y uzaysal koordinatlarında gri seviyeyi temsil etsin. $F(n, m)$ Ayrık Fourier Dönüşümüne karşılık gelen genel denklem (3.7)'de gösterilmiştir.


$$F(n,m) = \frac{1}{N^2} \sum_{y=0}^{N-1} \sum_{x=0}^{N-1} f(x,y) \times e^{-\frac{j2\pi(xn+ym)}{N}} \quad (3.7)$$

Ayrık Fourier Dönüşümünün hesaplama süresi genellikle fazla olduğundan Hızlı Fourier Dönüşümü (FFT) kullanılmaktadır. Hızlı Fourier Dönüşümü temelde Ayrık Fourier Dönüşümünün (DFT) aynısı olup hesaplama süresinin azalması için yeniden kurgulanmış bir yöntemdir (Chan ve diğ., 2000).

Görüntü işleme ile hata tespitinde griye çevirme ve histogram eşitleme ile basite indirgenmiş resimde öznelik çıkarımı yapılmaktadır. Öznelik çıkarım metodları dört yaklaşım ile ele alınmaktadır. Bunlar; istatistiksel yaklaşımlar, spektral yaklaşımlar, model tabanlı yaklaşımlar ve yapısal yaklaşımlardır (Mahajan ve diğ., 2009). Spektral yaklaşımlarda görüntünün, uzaysal domaindeki gri seviye değerleri Gabor filtreleme, Fourier dönüşümü ve Dalgacık dönüşümü gibi işlemler ile farklı

domainlere dönüştürülür. Elde edilen bu bilgiler öznitelik çıkarımı yapılarak sınıflandırma algoritmaları için girdi olarak alınmaktadır (Hanbay ve diğ., 2014). Kumaş orijinalliğini tespit etme üzerine yapılan bir çalışmada, Fourier dönüşümü ile kumaş dokusunun periyodik yapısı analiz edilerek hata varlığının saptanması ve güç spektrumundan yararlanarak kumaşın orjinal olup olmadığı bilgisine varılmıştır. Gri seviyedeki görüntüyü büyüklük ve faza dönüştürmek için Hızlı Fourier dönüşümü kullanılmaktadır (Norislina ve diğ., 2011). Görüntülerin frekans bileşenlerini karakterize ederek periyodik özelliklerin elde edilmesinde kullanılır. Spektrumda yüksek enerji iniş çıkışlarının yoğunluğu hata tespitinin yapılması için olanak sağlamaktadır. Aynı zamanda Fourier spektrumunun büyüklüğü mutlak değerli olduğundan kumaşın x ve y yönündeki hareketlerinden etkilenmemekte, sadece kumaş dokusundan etkilenmektedir. Böylece gerçek zamanlı hata tespitinde de kullanılması uygundur (Hanbay ve diğ., 2014).

Şekil 3.4’de pamuklama hatası için histogram eşitleme yapılmış görüntüde Hızlı Fourier Dönüşümü sonucunda elde edilen sinyal grafiği gösterilmiştir.



Şekil 3.4. Pamuklama hatasında Hızlı Fourier Dönüşümü

3.4. K-Means Algoritması

Kullanılan en yaygın kümeleme algoritmalarından biri olan K-Means algoritması her verinin sadece bir kümeye dahil olabilesine izin vermektedir (Davidson, 2002).

K-Means algoritması için öncelikle verinin kaç kümeye bölüneceği belirlenir. Oluşturulacak kümelerin kendi içlerinde benzerlikleri yüksek ve kümeler arasındaki benzerliğin düşük olması hedeflenmektedir. Küme içi benzerlik kümedeki verilerin ortalama değeri ile ölçülmektedir ve bu da kümenin ağırlık merkezidir. K-means algoritması n tane nesneyi k adet kümeye bölmektedir (Yıldız ve diğ., 2010).

K-means algoritmasının uygulama adımları dört adımda özetlenmektedir;

1. Veriler uygun k adet kümeye bölünür; $\{C_1, C_2, \dots, C_k\}$
2. Küme merkezleri hesaplanır;

$$w_i = \frac{1}{K_i} \sum_{j=1}^{K_i} w_{ij} \quad , \quad i=1,2,\dots,K \quad (3.8)$$

3. Bulunan her bir küme merkezi w_i için;

3.a. Tüm nesnelerin merkeze olan uzaklıkları denklem (3.9) ile hesaplanır.

$$\|w_i - \bar{w}_t\| \leq \|w_i - \bar{w}_j\| \quad , \quad j=1,\dots,K, \quad j \neq i \quad (3.9)$$

3.b. Elde edilen sonuca göre her nesne k adet kümeden kendilerine en yakın olan kümeye yerleştirilir.

4. Küme merkezleri stabilize olana kadar 2. ve 3.adımlar tekrar edilir (Pena ve diğ.,1999).

3.5. J-48 Karar Ağacı Algoritması

J48 bir karar ağacı algoritmasıdır ve öznitelik vektörünün çeşitli durumlar için davranış şeklini tespit etmektedir. Algoritma hedef değişkenin tahmini için kurallar oluşturur. Elde edilen kural ağacı ile verilerin sınıflandırılması kolaylıkla yapılabilir duruma gelir. (Kaur ve diğ., 2014).

Karar ağacı oluşturma süreci temelde ağaç oluşturma ve ağaç budama olarak iki basamaktan oluşmaktadır. Ağaç oluşturmada, kök düğümünden başlayarak her yinelemede seçilecek niteliğe göre farklı dallar oluşur. Ayrım yapacak nitelik kalmayana kadar bu süreç devam eder. Düğümlerdeki nesnelere ne kadar homojen dağılırsa dallanma yapısı o kadar verimli olacaktır (Coşkun, 2010).

Algoritma adımları;

1. MaxBilgi değişkenini sıfıra eşitle.
2. Güncel veri setinin entropisini hesapla.

3. FOR veri setindeki her bir özellik
 - 3.a. Güncel veri setindeki özelliklerden bir tanesini seç.
 - 3.b. Seçilen özellik için bilgi değerini hesapla.
 - 3.c. Seçilen özellik için bilgi kazanımını hesapla.
 - 3.d. IF bilgi kazanımı > MaxBilgi then
 - 3.d.1. MaxBilgi değişkenine bilgi kazanımı değerini ata.
4. END FOR
5. MaxBilgi değerine sahip özelliği ağaca ekle.
6. MaxBilgi değerine sahip özelliği veri setinden sil.
7. Until veri setindeki özellik sayısı = 0
8. Bitir

olarak sıralanmaktadır (Demirbulut ve diğ., 2017).

3.6. Lojistik Regresyon

Lojistik Regresyon, ikili (binary) 0 veya 1 olarak kodlanmış verileri içeren, bir veya birden çok bağımlı ve bağımsız değişkenlerin aralarındaki ilişkiyi inceleyen istatistik yöntemidir. Lojistik Regresyon'da temelde bir regresyon analizi olarak tanımlanabilir ancak yapısal olarak farklılık göstermektedir. Doğrusal Regresyon'da bağımlı değişkenin değeri tahmin edilirken, Lojistik Regresyon'da analize cevap değişkeninin alacağı değerlerden birinin gerçekleşme olasılığı tahmin edilmektedir.

Bağımlı değişkenin kategorisinin belirlenmesi için, eğer değişken iki kategoriye sahipse ikili Lojistik Regresyon, ikiden fazla kategoriye sahipse çoklu Lojistik Regresyon kullanılmaktadır.

3 kategoriye sahip lojistik regresyon modeli denklem (3.10) ve denklem (3.11)'de verilmektedir.

$$g_1(A) = \log \left(\frac{P\left(B = \frac{1}{A}\right)}{P\left(B = \frac{0}{A}\right)} \right) = \beta_{10} + \beta_{11}A_1 + \dots + \beta_{1p}A_p \quad (3.10)$$

$$g_2(A) = \log \left(\frac{P\left(B = \frac{2}{A}\right)}{P\left(B = \frac{0}{A}\right)} \right) = \beta_{20} + \beta_{21}A_1 + \dots + \beta_{2p}A_p \quad (3.11)$$

3.7. Naive Bayes Sınıflandırma

Veri madenciliği ve örüntü tanıma gibi alanlarda yaygın olarak kullanılan sınıflandırma yöntemlerinden biri olan Naive Bayes, koşullu olasılıklar arasında bağıntı kuran Bayes teoremine dayanmaktadır (Hand ve diğ., 2001).

Veri setindeki her bir örnek $X = \{x_1, x_2, \dots, x_n\}$ değerlerinden oluştuğunda toplam n tane sınıf oluşursa sınıfı belirlemek için (3.12) olasılık denklemi kullanılır (Ren ve diğ., 2009).

$$P(C_i|X) = \frac{P(C_i|X)P(C_i)}{P(X)} \quad (3.12)$$

X: sınıflandırılacak veri seti

C: sınıf sayısı

P: olasılık değeri

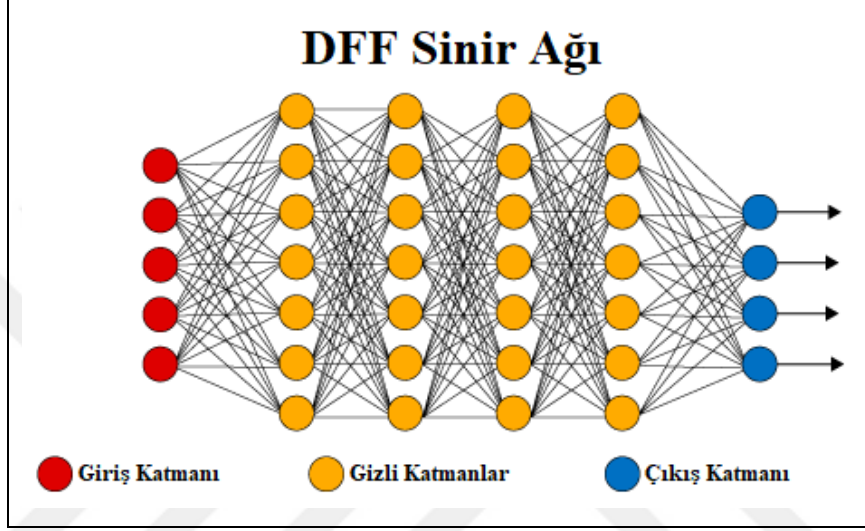
Hesaplamadaki X_i değerleri birbirinden bağımsız olarak alınır ve payda değerlerinin eşit olduğu bilindiğinden, $P(C_i|X)$ içinde pay değerleri karşılaştırılır. En büyük pay değeri seçilerek bilinmeyen hangi sınıfa ait olduğu belirlenir (Yıldız, 2014). – Doktora tezi

3.8. Derin İleri Beslemeli Sinir Ağı

Derin ileri beslemeli sinir ağı, bir ileri beslemeli yapay sinir ağı sınıfıdır. DFF, en az üç düğüm katmanından oluşur (Şekil 3.5.). Giriş düğümleri haricinde, her düğüm doğrusal olmayan bir etkinleştirme işlevi kullanan bir nörondur. DFF, eğitim için geri yayılım (backpropagation) olarak adlandırılan denetimli bir öğrenme tekniğini kullanır. Çok tabakalı ve lineer olmayan aktivasyon, DFF'yi doğrusal bir algılayıcıdan ayırır. Doğrusal olarak ayrılabilir olmayan verileri ayırt edebilir (Dutta S. ve ark., 2018).

DFF' de sinir ağına ait veriler aşağıdaki adımlarla hesaplanmaktadır (URL-2);

1. Giriş değerleri daha önce belirlenmiş ağırlık değerleriyle (w) çarpılır.
2. Adım 1'de elde edilen değer ile bias (b) değeri ile toplanır. w ve b parametreleri çıktı sonucunu en iyi verecek şekilde her eğitim adımında (epoch) değiştirilmektedir.
3. Çıkış fonksiyonunun doğrusal fonksiyon gibi davranmaması için aktivasyon fonksiyonuna tabi tutulur. Buradaki amaç ise sinir ağının öğrenme gücünü arttırmaktadır.



Şekil 3.5. DFF Sinir ağı yapısı

Çalışmada modellenen DFF sinir ağına ait parametreler Tablo 1'de verilmiştir.

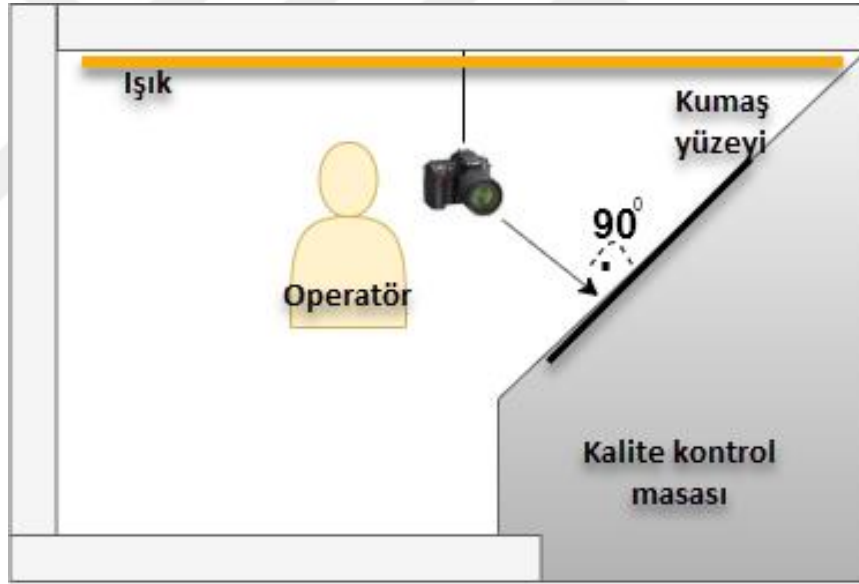
Tablo 3.1. DFF Sinir ağı parametreleri

Giriş katmanı hücre sayısı	6
Gizli katman sayısı	3
Gizli katman hücre sayıları	10, 8, 12
Gizli katmanda kullanılan aktivasyon fonksiyonları	ReLU, ReLU, Sigmoid
Çıkış katmanı hücre sayısı	1
Optimizer	Adamax
Batch Size	8
Test Size	0.10

4. BULGULAR VE TARTIŞMA

4.1. Görüntülerin Elde Edilmesi

Bu çalışmada kullanılmak üzere farklı renk ve aynı örgü tipinde 52 adet hatalı, 25 adet temiz olmak üzere 77 adet denim kumaş görüntüsü elde edilmiştir. Her bir denim kumaş görüntüsü kalite kontrol tezgahlarında akan kumaşa operatörlerce tespit edilen hatalarda tezgah durdurularak Şekil 4.1’ de sabitlenmiş durumdaki NIKON D80 fotoğraf makinesi ile 90 derecelik açı ile çekilmiştir. Elde edilen her görüntü 3872×2592 çözünürlükte ve JPEG formatında kaydedilmiş ve görüntü işleme algoritmalarına girdi olarak verilmiştir.

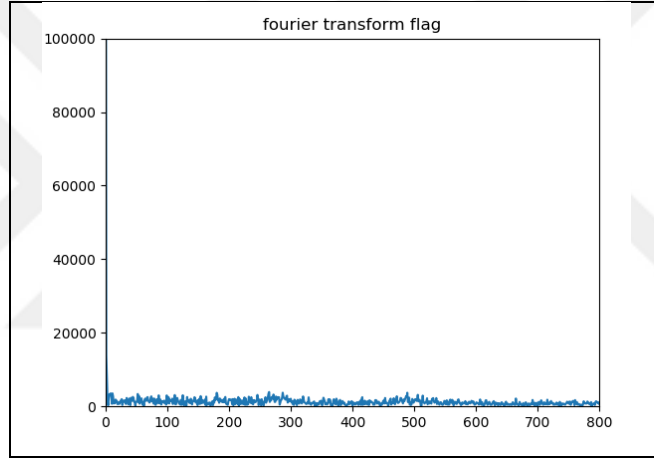


Şekil 4.1. Hatalı kumaş fotoğraflarının elde edilmesi


77 adet hatalı kumaş görüntüsünde 20 farklı çeşitte hata bulunmaktadır. Elde edilen tüm hatalı görüntüler ayıklanarak iplik, ihzar, dokuma ve terbiye süreçlerinde oluşan hata tiplerinden en az birer örnek alınacak şekilde oluşturulmuştur. Alınan her bir hata grubuna ait görüntü farklı denim kumaş tipindedir. Böylece bu çalışmada denim kumaşlardaki tüm hata grupları için görüntü işleme ve özellik çıkarım yöntemleri denenmiştir.

4.2. Görüntü İşleme Yöntemlerinin Uygulanması

Hatalı ve hatasız kumaşlardan elde edilen görüntü kümesine Python'da kodlanan ağırlık toplama yöntemi ile griye çevirme işlemi uygulanmıştır. İki seviyeli görüntülerde kumaş yüzeyinde örgü düzenini bozan hataların daha da netleştirilmesi için histogram eşitleme kullanılmıştır. Histogram eşitleme sonucunda Hızlı Fourier Dönüşümü kullanılarak elde edilen frekans spektrumları hem temiz hem de hatalı kumaşlar için incelenmiş ve spektrum geçişlerindeki farklar tespit edilmiştir. Hatalı görüntüden elde edilen Hızlı Fourier Dönüşümü spektrumları Şekil 4.2'de, hatasız görüntüden elde edilen Hızlı Fourier Dönüşümü spektrumları Şekil 4.3'de gösterilmiştir.

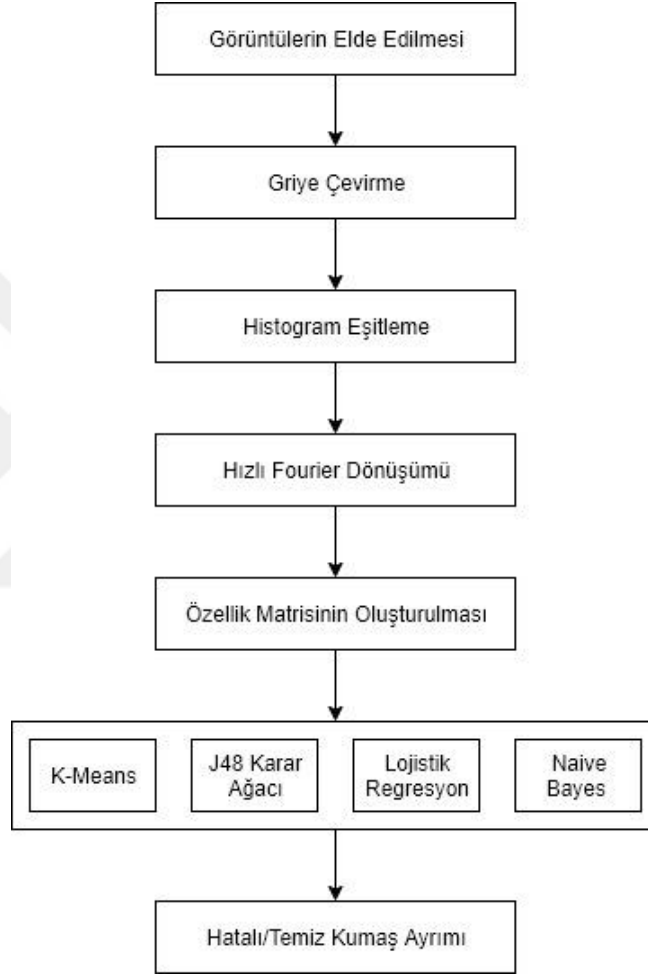


Şekil 4.2. Temiz kumaş görüntüsü Hızlı Fourier Dönüşümü sinyal grafiği



Şekil 4.3. Hatalı kumaş görüntüsü Hızlı Fourier Dönüşümü sinyal grafiği

Kumaşlardan alınan spektrum grafiklerinde belirli bir tekrarlı yapı kurulması ve matematiksel modellenmesi için özellik çıkarımı yöntemleri araştırılmış ve denenmiştir. Sınıflandırma ve kümeleme algoritmalarına girdi olarak verilebilmesi için spektrum grafikleri en uygun şekilde anlamlandırılarak sayısal verilere dönüştürülmüştür. Bütün çalışma ve kullanılan işlemlerin genel iş akışı Şekil 4.4'de verilmiştir.



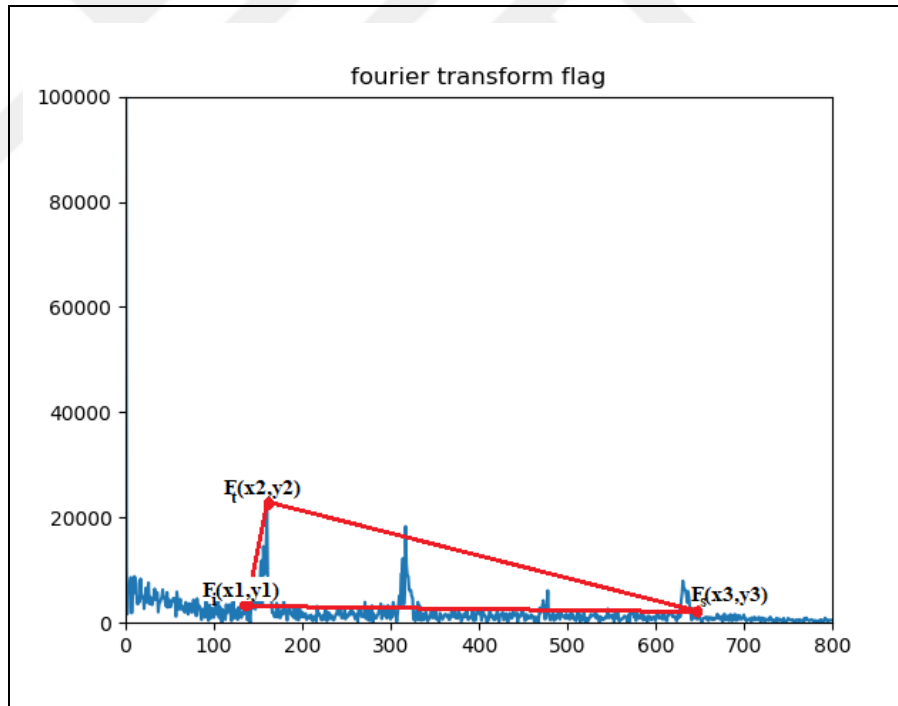
Şekil 4.4. Genel iş akışı

4.3. Özellik Matrisinin Elde Edilmesi

Gri seviyedeki görüntüyü büyüklük ve faza dönüştürmek için Hızlı Fourier dönüşümü kullanılmaktadır (Norislina ve diğ., 2011). Görüntünün Fourier spektrumu kumaşın örgü tekniğinden etkilenmez iken dokusundaki farklılıklarda kıvrım yapmaktadır (Hanbay ve diğ., 2014). Kumaş dokumada kullanılan çeşitli örgü teknikleri bulunur; bezayağı, jakarlı, saten ve dimi örgü çeşitleri bunlardan

bazılarıdır. Denim kumaşlarda ise en çok dimi örgü tekniği kullanılmaktadır. Bu sayede kumaş daha yumuşak dokuya sahip olacaktır.

Bu çalışmada kullanılan 77 adet farklı örgü düzeninde dokunmuş kumaş için renk veya leke hataları yerine kumaşın dokusundan kaynaklanan hatalar üzerinde inceleme yapılmıştır. Belirli bir düzeni tekrar eden kumaş dokusunun bozulmaya uğradığı her noktadaki frekans değeri kumaş hatasını ifade etmektedir. Şekil 4.2’de gösterildiği gibi hatalı ve temiz kumaş dokusunun Fourier spektrumu gözle görülür şekilde farklıdır. Literatürde kullanılan özellik çıkarımı yöntemlerine benzer olarak, spektrumdaki frekans değerleri hata noktaları için hesaplanarak sayısallaştırılmıştır. Hatalı görüntülerin Fourier spektrumu kumaş doku bozukluğuna bağlı olarak iki veya daha fazla kıvrımlar yaparken, hatasız kumaş görüntülerinde spektrum tek tepe değerli veya hiç kıvrım yapmamaktadır. Şekil 4.5’de ara hatasının Fourier spektrumu için çalışmada kullanılan hesaplamalar aşağıdaki gibidir;



Şekil 4.5. Ara hatası için Fourier spektrumu

$F_i(x_1, y_1)$: hata başlangıç değeri

$F_t(x_2, y_2)$: hata tepe noktası

$F_s(x_3, y_3)$: hata bitiş değeri olarak ele alınmıştır.

Bu deęerlere gre her bir grntnn frekans spektrumlarından 6 farklı istatistiksel nicelik denklem (4.1)-denklem (4.6)'da metrik olarak hesaplanmıřtır.

$$p_1 = |F_t F_t| \quad (4.1)$$

$$p_2 = |F_t F_s| \quad (4.2)$$

$$p_3 = |F_t F_s| \quad (4.3)$$

$$p_4 = \frac{p_1}{p_2} \quad (4.4)$$



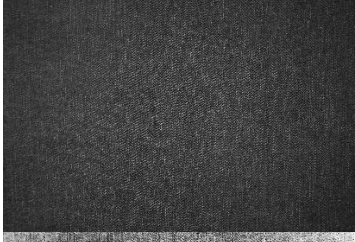

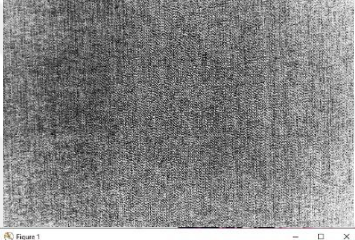

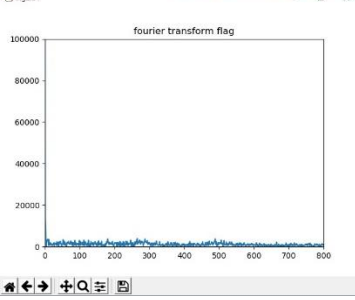
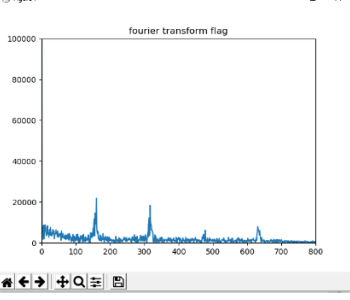
$$p_5 = \frac{p_2}{p_3} \quad (4.5)$$

$$p_6 = \frac{p_1}{p_3} \quad (4.6)$$

Buna gre p_1, p_2 zellikleri hata bařlangıç ve bitif frekans deęerlerine gre kumařın y eksenini doęrultusundaki yani hatanın noktasal veya sreksel oluřuna gre byklęnn vermektedir. p_3 zellięi ise hatanın x eksenini doęrultusunda yani kumař eni boyunca devamlılıęını vermektedir. p_3, p_4, p_5 zellikleri hesaplanan deęerlerin oranlarını vermektedir.

Elde edilen her grntye ait sınıf etiketi kmeleme algoritmalarında kullanılmak zere hatalı kumařlar iin 'H' ve temiz kumař grntleri iin 'T' olarak verilmiřtir. Bylece $M = (p_1, p_2, p_3, p_4, p_5, p_6, H)$ veya $M = (p_1, p_2, p_3, p_4, p_5, p_6, T)$ olacak řekilde 1×7 boyutunda zellik vektrleri oluřturulmuřtur. 77 adet zellik vektr ile denklem (4.7)'de 77×7 boyutundaki ana matris oluřturularak kmeleme ve sınıflandırma algoritmaları zerinde hatalı ve temiz kumařların ayrımı iin denemeler yapılmıřtır. Buna gre bir grntnn iřleme ařamaları Tablo 4.1' de gsterilmiřtir.

Tablo 4.1. Kumaş görüntü işleme aşamaları

Yöntem	Hatasız Görüntü	Hatalı Görüntü
Orijinal		
Gri Seviye		
Histogram Eşitleme		
Fourier Analiz		

4.4. Sınıflandırma ve Kümeleme İşlemleri

Özellik değerleri elde edildikten sonra her görüntüye ait altı özellik kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Lojistik Regresyon, Navie Bayes, DFF Neural Network ve J48 yöntemlerinde 10 katlı çapraz doğrulama kullanılarak sonuçlar hesaplanmıştır. K Means yönteminde ise sınıf etiketleri kullanılarak kümelerin değerlendirilmesi gerçekleştirilmiştir. Sınıflandırma işlemine ait elde edilen sonuçlar Tablo 4.2'de gösterilmiştir. Tablo 4.2'de yer alan sonuçlar doğrultusunda en düşük hata değerinin J48 yöntemiyle elde edildiği tespit edilmiştir.

Tablo 4.2. Sınıflandırma yöntemlerine ait hata oranları

Yöntem	RMSE	Doğruluk Yüzdesi
Lojistik Regresyon	0,3266	87,013 %
Naive Bayes	0,4032	83,12 %
DFF Neural Network	0,3646	85,71 %
J48	0,3448	87,01 %

Sınıflandırma ve kümeleme işlemleri farklı teknikler olduğundan yöntemlerin değerlendirme kriterleri de farklılık göstermektedir. K-Means kümeleme algoritması hatalı kumaşların tespiti için yapılan işlemler sonucunda elde edilen hata değerleri Tablo 4.3'te gösterilmiştir. Doğruluk yüzdeleri bakımından sınıflandırma ve K Means kümeleme yöntemi karşılaştırıldığında denim kumaş hatalarının tespitinde sınıflandırma yöntemlerinin daha başarılı olduğu görülmüştür.

Tablo 4.3. Kümeleme yöntemine ait hata oranları

Yöntem	Doğruluk Yüzdesi	Küme İçi Hata Karelerinin Toplamı
K-Means	62,338 %	3,742

Hem kümeleme hem de sınıflandırma yöntemleri genel olarak karşılaştırıldığında yine J48 ve Lojistik Regresyon algoritmaları en doğru sonuçları üretmiştir. Tablo 4.4'te J48 algoritmasına ait karmaşıklık matrisi verilmiştir. Yöntemin yüzde 87 doğruluk oranı ile hataları tespit ettiği görülmektedir.

Tablo 4.4. J48 yöntemine ait doğruluk değerleri

		Karmaşıklık Matrisi					
		Gerçek Değer					
Tahmin		H	T	Precision	Recall	F-Measure	Sınıf
	H	46	4	0,920	0,885	0,902	H
	T	6	21	0,778	0,840	0,808	T

Aynı şekilde Tablo 4.5'te Lojistik Regresyon modelinin karmaşıklık matrisi ve doğruluk değerleri verilmiştir.

Tablo 4.5. Lojistik Regresyon yöntemine ait doğruluk değerleri

		Karmaşıklık Matrisi					
		Gerçek Değer					
Tahmin		H	T	Precision	Recall	F-Measure	Sınıf
	H	46	6	0,920	0,885	0,902	H
	T	4	21	0,778	0,840	0,808	T

J48 ve Lojistik Regresyon yöntemlerinden sonra en başarılı sonuçları veren yöntem DFF Neural Network yöntemi olmuştur. DFF Neural Network yöntemine ait elde edilen karmaşıklık matrisi Tablo 4.6' da gösterilmiştir.

Tablo 4.6. DFF Neural Network yöntemine ait doğruluk değerleri

		Karmaşıklık Matrisi					
		Gerçek Değer					
Tahmin		H	T	Precision	Recall	F-Measure	Sınıf
	H	47	6	0,887	0,904	0,895	H
	T	5	19	0,792	0,76	0,776	T

Karmaşıklık matrisi Şekil 4.6.' de gösterildiği gibi, algoritmanın doğru ve yanlış tahminleri ile gerçekte olması gereken değerlerin karşılaştırılması için oluşturulmaktadır. Çıktının birden fazla durumlarda makine öğrenmesi problemlerinin karşılaştırılması için kullanılmaktadır.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Şekil 4.6.Karmaşıklık matrisi

Burada TP, FP, FN, TN değerleri;

True Positive (Doğru Pozitif): Görüntünün hatalı tahmin edildiği ve gerçekten hatalı olduğu durum.

True Negative (Doğru Negatif): Görüntünün temiz tahmin edildiği ve gerçekten temiz olduğu durum.

False Positive (Yanlış Olumlu): Görüntünün hatalı tahmin edildiği ama gerçekte temiz olduğu durum.

False Negative (Yanlış Olumsuz): Görüntünün temiz tahmin edildiği ama gerçekte hatalı olduğu durum.

Karmaşıklık matrisi ile denklem (4.7) ve (4.9)'a göre Recall, Precision, F-Measure değerleri hesaplanmıştır;

Recall: tüm pozitif sınıflardan ne kadar doğru tahmin edildiği,

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4.7)$$

Precision: tüm sınıflardan ne kadar doğru tahmin edildiği,

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4.8)$$

F-Measure: düşük hassasiyet veya yüksek geri çağırma değerlerinin aynı anda ölçülmesini sağlar. Recall ve Precision değerlerinin harmonik ortalamasıdır.

$$F\text{-Measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (4.9)$$

DFE Neural Network bir derin öğrenme yöntemidir ve genel olarak klasik sınıflandırma / yapay sinir ağları tekniklerine göre daha başarılıdır. Ancak çalışmamızda kullanılan veri seti üzerinde J48 ve Lojistik Regresyon yöntemleri DFE Neural Network Yönteminden daha başarılı sonuçlar üretmiştir. DFE Neural Network yönteminin daha başarısız olmasında en temel etken veri setinin sınırlı sayıda veri içermesidir. Derin öğrenme yöntemlerinde veri sayısının başarı üzerindeki etkisi daha önceki çalışmalarda da (Gündüz ve Cedimoğlu., 2019) gösterilmiştir. Veri sayısının sınırlı olması nedeniyle öğrenme tam olarak gerçekleştirilememiştir.

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, denim kumaşlardaki hataların tespiti ve sınıflandırılması için görüntü işleme yöntemleri kullanılarak yetmiş altı denim kumaşa ait altı farklı özellik çıkarılmıştır. Elde edilen özellikler kullanılarak sınıflandırma ve kümeleme yöntemleri üzerinden veri seti içerisindeki hatalı kumaşların tespiti sağlanmıştır.

Çalışma sonunda denim kumaşlardaki hata tespiti için sınıflandırma yöntemlerinin kümeleme yöntemlerinden daha doğru sonuçlar ürettiği tespit edilmiştir. Aynı zamanda sınıflandırma yöntemleri kendi içerisinde karşılaştırıldığında J48 ve Lojistik Regresyon algoritmalarının DFF Neural Network, Navie Bayes yöntemlerine göre denim kumaşlarda hata tespiti için daha uygun olduğu tespit edilmiştir.

KAYNAKLAR

Ala D.M., İkiz Y., Dokuma Üretimi Süresince Oluşan Dokuma Hatalarının Belirlenmesine Yönelik İstatistiksel Bir Araştırma, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 2015, **21**(7), 282-287.

Buluklu H.M., Dokuma İşletmelerinde Proses ve Kalite Kontrol, Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana, 2006, 183744.

Büyükkabasakal K., Kumaş Dokuma Hatalarının Tespiti ve Sınıflandırılması, Yüksek Lisans Tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2010, 256063.

Campbell, J. G., Fraley, C., Stanford, D., Murtagh, F., Raftery, A. E., Model-Based Methods for Textile Fault Detection, *International Journal of Imaging Systems and Technology*, 1999, **9**, 339–346.

Chan C. H., Pang, G. K., Fabric Defect Detection By Fourier Analysis. *IEEE Transactions on Industry Applications*, **36**(5): 1267-1276.

Coşkun M., Yünlü Kumaşlarda Neps Hatalarının Görüntü İşleme Teknikleri İle Belirlenmesi, Yüksek Lisans Tezi, Gaziantep Üniversitesi, Fen Bilimleri Enstitüsü, Gaziantep, 2015, 398909.

Coşkun C., Veri Madenciliği Algoritmaları Karşılaştırılması, Yüksek Lisans Tezi, Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Diyarbakır, 2010, 275428.

Çakır N., Kot Pantolon Üretiminde Bitim İşlemlerinin ve Farklı Denim Kumaşların Fit Üzerine Etkileri, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Tekstil Mühendisliği Anabilim Dalı, Denizli, 2010, 260021.

Çelik H. İ., Dülger C., Topalbekiroğlu M., Denim Kumaşın Hata Denetimi İçin Bir Algoritma Geliştirilmesi: Gabor Filtre Yöntemi, *Tekstil ve Konfeksiyon Dergisi*, 2013, **23**(2), 255-260.

Davidson I., Understanding K-Means Non-hierarchical Clustering, *SUNY Albany Technical Report*, 2002, **2**, 2-14.

Demirbulut Y. E., Aktaş M. S., Kalıpsız O., Bayracı S., İstatistiksel ve Makine Öğrenimi Yöntemleriyle Kredi Skorlama, *Turkish National Software Engineering Symposium*, 2017, 273-284.

Demirer M., Kumaşlarda Dikiş Büzülmelerinin Optoelektronik Yöntemle Algılanması, Doktora Tezi, Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa, 2010, 340052.

Dorrity L., Vachtsevanos G., Jasper W., Real-Time Fabric Defect Defection &Control in Weaving Processes, *National Textile Center*, 1995, **94**(2), 143-152.

Dutta S., Jha S., Sankaranarayanan S., Tiwari, A., Output Range Analysis for Deep Feedforward Neural Networks, *In NASA Formal Methods Symposium*, 2018, 121-138, Springer, Cham.

Gonzalez R.C., Woods R.E., *Digital Image Processing*, 1. Baskı, Palme Yayıncılık, 2014.

Güler H., GPU ile Kumaş Hata Tespiti ve Sınıflandırılması, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş, 2012, 325732.

Gündüz G., Cedimoğlu İ. H., Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini, *Sakarya University Journal Of Computer And Information Sciences*, 2019, **2**(1), 9-17.

Gürarda A., Konfeksiyon İşlemleri ile Kumaş Özellikleri Arasındaki İlişkinin İncelenmesi, *Tekstil ve Mühendis Dergisi*, 2015, **22**(99), 41-50.

Hanbay K., Yuvarlak Örgü Makineleri İçin Görüntü İşleme Tabanlı Kumaş Hatası Tespit Sistemi, Doktora Tezi, İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya, 2016, 444269.

Hanbay K., Talu M., Kumaş Hatalarının Online/Offline Tespit Sistemleri ve Yöntemleri, *Sakarya Üniversitesi Fen Bilimleri Dergisi*, 2014, **18**, 49-69.

Hand D. J., Keming Y., Idiot's Bayes—Not so Stupid After All?, *International Statistical Review*, 2001, **69**(3), 385-398.

Ismail, Norislina, Fabric Authenticity Method Using Fast Fourier Transformation Detection, *International Conference on Electrical, Control and Computer Engineering IEEE*, 2011, 233-237.

Jianxia W., Guang Z., Hongxia M., Min, Q., Feature Extraction of the Fabric Defects Image, *8th International Conference on Electronic Measurement and Instruments*, DOI:10.1109/icemi, 2007, 4350781.

Karataş İ., Soyaslan D., Tekstil Endüstrisinde Yapay Görme ile Hata Tespit Uygulamaları, *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi Özel Sayı*, **1**, 51-57.

Kanan C., Cottrell G. W., Color-To-Grayscale: Does The Method Matter in Image Recognition?, *PLoS ONE*, 2012, **7**, 842-846.

Kaur G., Chhabra A., Improved J48 Classification Algorithm for the Prediction of Diabetes, *International Journal of Computer Applications*, 2014, **98**(22),13-17.

Kısaçoğlu Ö., Fabric Quality Control Systems, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 2006, **12**(2), 233-241.

Köksal F., Denim Yıkamada Renk Varyasyonlarının Nedenlerinin İncelenmesi, Yüksek Lisans Tezi, Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Tekirdağ, 2015, 48905.

Kumar A., Pang G., Defect Detection in Textured Materials Using Gabor Filters, *IEEE Transactions on Industry Applications*, 2002, **38**(2), 425-440.

Liu M., Sun J., Fan Z., Zhang S., Automatic Location and Extraction of Woven Fabric Blocks Based on Gaussian Blur and Maximization Thought, *International Conference on Mechatronics and Control*, Jinzhou, 3-5 Temmuz.

Liu G. S., Qu P. G., Inspection of Fabric Defects Based on Wavelet Analysis and BP Neural Network, *Proceedings of the 2008 International Conference on Wavelet Analysis and Pattern Recognition*, 2008, 232-236, 10.1109/ICWAPR.2008.4635782.

Mahajan P. M., Kolhe S. R., Pati P.M. 2009. A Review of Automatic Fabric Defect Detection Techniques, *Advances in Computational Research*, **1**(2):18-29.

Pena J. M., Lozano J. A., Larranaga P., An Empirical Comparison of Four Initialization Methods for the K-means Algorithm, *Pattern Recognition Letters*, 1999, **20**(10),1027-1040.

Priya S., Kumar Ashok T., Varghese P., A Novel Approach to Fabric Defect Detection Using Digital Image Processing, *International Conference on Signal Processing, Communication, Computing and Networking Technologies*, 2011, 228-232.

Rebhi A., Abid S., Fnaiech F., Fabric Defect Detection Using Local Homogeneity and Morphological Image Processing, Scientific Research Laboratory in Signal, Image Processing and Energy Mastery (SIME) University of Tunis, 2016.

Ren J., Lee S. D., Chen X., Kao B., Cheng R., Cheung D., Naive Bayes Classification of Uncertain Data, *Data Mining*, 2009, 944-949.

Saklı F., Zitouni B., Jmali M., Fabric Defects Detecting Using Image Processing And Neural Networks, *IEEE*, 2014, 10.1109/ICTIA.2014.7883765.

Titrek N. G., Fabric Defect Detection In Frequency Domain Using Fourier Analysis, Yüksek Lisans Tezi, Işık Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2016, 436576.

Turan B., Görüntü İşleme Algortimalarının Eş Zamanlı Süreçlere Ayrılarak Kablosuz Ağ Üzerinden Gerçeklenmesi ve Performans Analizleri, Yüksek Lisans Tezi, Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2017, 486690.

Türkiye Denim Sektörü Dış Ticaret Raporu, *Uludağ İhracatçı Birlikleri Genel Sekreterliği (UTİB)*, Arge Şubesi, Mayıs 2019.

URL-1: <https://www.derstekstil.name.tr/tekstilde-kalite-kontrolun-onemi-ve-ozellikleri.html>, (Ziyaret Tarihi: 19 Ağustos 2019).

URL-2: <https://builtin.com/data-science/feedforward-neural-network-intro> (Ziyaret Tarihi: 23 Kasım 2019)

Vladimir G., Evgen I., Aung, N. L., Automatic Detection and Classification of Weaving Fabric Defects Based on Digital Image Processing. *2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering*, DOI:10.1109/eiconrus.2019.8657318.

Yıldız K., Kumaş Hatalarının Isıl Görüntüleme ve Görüntü İşleme Teknikleri ile Tespit Edilmesi, Doktora Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2014, 377205.

Yıldız K., Çamurcu Y., Doğan B., Veri Madenciliğinde Temel Bileşenler Analizi ve Negatifsiz Matris Çarpanlarına Ayırma Tekniklerinin Karşılaştırmalı Analizi, *Akademik Bilişim '10*, 2010, 248.

Zhang J., Li L., A New Algorithm for Fabric Defect Detection Based on Image Distance Difference, *2009 Third International Symposium on Intelligent Information Technology Application*, DOI:10.1109/iita.2009.192.

KİŞİSEL YAYIN VE ESERLER

Pınar Z., Gülağız Kaya F., Altuncu M. A., Şahin S., Denim Kumaşlarda Görüntü İşleme İle Hata Tespiti, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, Bitlis, 2019.



ÖZGEÇMİŞ

21.09.1993 tarihinde Bursa’da doğan Zeynep PINAR, 2011 yılında Mudanya Sami Evkuran Anadolu Lisesi mezunu oldu ve 2011 yılında Kocaeli Üniversitesi Fen Edebiyat Fakültesi, Matematik Bölümünde lisans öğrenimine başladı. Dört yıllık lisans eğitimin ardından 2015 yılında mezun oldu. 2016 yılında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği bölümünde yüksek lisans eğitimine başladı. 2018 Nisan ayından itibaren Bursa’da Güncel Yazılım firmasında çalışma hayatına devam etmektedir.

