

T.C.
AYDIN ADNAN MENDERES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI
YÜKSEK LİSANS PROGRAMI
2024-YL-82

DERİN ÖĞRENME VE GÖRÜNTÜ İŞLEME
KULLANILARAK KUMAŞ HATALARININ TESPİT
EDİLMESİ VE SINIFLANDIRILMASI

Uğur Can TOPÇU
YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Coşkun DENİZ

Bu tez Aydın Adnan Menderes Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından MF24001 proje numarası ile desteklenmiştir.

AYDIN – 2024



TEŞEKKÜR

Yüksek lisans eğitimim süresince ve bu tez çalışmasında yoğun bir emek ve özveri ile her konuda yanımda olan, desteklerini ve bilgisini benden esirgemeyen, aklın ve bilimin ışığında yol gösterici olarak gördüğüm değerli danışman hocam Sayın Doç. Dr. Coşkun DENİZ'e; bu çalışmanın prototip olarak hazırlanmasında katkısı olan ve işletmesinde bana ekipman desteği sağlayan EVSA Tekstil firmasının sahibi Ali Erdem AYAZ'a; benim bu bilgileri öğrenmemde emeği geçen tüm lisans ve yüksek lisans hocalarıma; hayatımın her anında sürekli yanımda olan, fikirleri ve farklı bakış açıları ile karşıma çıkan problemleri kolay bir biçimde çözmemi sağlayan sevgili hayat arkadaşım Eda ERDEN'e ve son olarak en zorlu şartlarda bile yılmadan sürekli yanımda olan beni bu günlere getiren maddi manevi her konuda daima destekçim olan canım aileme can-ı gönülden teşekkürlerimi sunarım.

Uğur Can TOPÇU



BİLİMSEL ETİK BEYANI

“Derin Öğrenme ve Görüntü İşleme Kullanılarak Kumaş Hatalarının Tespit Edilmesi ve Sınıflandırılması” başlıklı Yüksek Lisans tezindeki bütün bilgileri etik davranış ve akademik kurallar çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırlanan bu çalışmada, bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yaptığımı bildiririm. İfade ettiklerimin aksi ortaya çıktığında ise her türlü yasal sonucu kabul ettiğimi beyan ederim.



Uğur Can TOPÇU



İÇİNDEKİLER

KABUL VE ONAY	i
TEŞEKKÜR	iii
BİLİMSEL ETİK BEYANI.....	v
İÇİNDEKİLER.....	vii
SİMGELER DİZİNİ	ix
KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
ÇİZELGE DİZİNİ	xvii
ÖZET	xix
ABSTRACT	xxi
1. GİRİŞ	1
1.1. Tezin Amacı	2
1.2. Tezin Organizasyonu.....	2
2. KAYNAK ÖZETLERİ.....	5
2.1. Kumaş Dokuma Tezgahları	5
2.2. Kumaş Kalite Kontrol Tezgahları	7
2.3. Kalite Kontrolde Dokuma Kumaş Hata Katalogları.....	8
2.4. Literatürde Yer Alan Hata Tespit Çalışmaları.....	9
3. MATERYAL VE YÖNTEM.....	19
3.1. Dokuma Kumaş Hata Tipleri.....	19
3.2. Kumaş Hatalarının Tespitinde Uygulanan Yöntemler	24
3.2.1. Spektral Yöntemler.....	24
3.2.2. Model Tabanlı Yöntemler	25
3.2.3. İstatistiksel Yöntemler.....	25
3.2.4. Makine Öğrenmesi Yöntemleri	25

3.3. Kumaş Hataları Tespitinde Kullanılan Görüntü İşleme Yöntemleri	26
3.3.1. Rgb Renk Uzayı	26
3.3.2. Gri Tonlamalı Görüntü	29
3.3.3. Histogram Eşitleme	29
3.3.4. Difference of Offset Gaussian (DOOG).....	33
3.3.5. Morfolojik İşlemler	34
3.4. Yapay Sinir Ağları.....	36
3.5. Evrişimli Sinir Ağları	38
4. BULGULAR	43
4.1. Veri Setinin Oluşturulması	43
4.1.1. Kamera Seçimlerinin Yapılması.....	47
4.1.2. Aydınlatma Cihazlarının Ayarlanması	48
4.1.3. Metre Sayacı ve Okuyucu Cihazlarının Entegrasyonu.....	49
4.1.4. Kumaş Kalite Kontrol Makinesi Üzerine Mekanik Aksamın Entegrasyonu	50
4.1.5. Bilgisayar ve Haberleşme Kablolarının Entegrasyonu.....	50
4.2. Kumaş Hata Tespiti ve Sınıflandırılmasının İş Akış Diyagramı	51
4.3. Kumaş Hata Tespiti ve Sınıflandırılmasının Yazılımı	52
5. TARTIŞMA.....	55
5.1. Gerçek Zamanlı Kumaş Hata Görüntülerinin Tespiti.....	55
5.2. Tasarlanan Sistemin Arayüzü	58
5.3. Kumaş Görüntülerinin Hatalarına Göre Sınıflandırılma Başarımı	61
6. SONUÇ VE ÖNERİLER.....	79
KAYNAKLAR.....	81
EKLER	85
ÖZ GEÇMİŞ.....	87

SİMGELER DİZİNİ

R_k	Renk yoğunluk değerleri.
$p_r(r)$	Olasılık yoğunluk fonksiyonu.
A	Genlik değeri.
σ	Standart sapma.



KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay Zeka)
BA	: Bayes Ağları
BMP	: Bitmap
C++	: C Plus Plus
CCD	: Charge Coupled Device (Yük Bağlı Cihaz)
CDF	: Cumulative Distribution Function (Kümülatif Dağılım Fonksiyonu)
CMOS	: Complementary Metal Oxide Semiconductor (Tamamlayıcı Metal Oksit Yarı İletken)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağları)
COHOG	: Co-occurrence Histograms of Oriented Gradients (Yönlendirilmiş Gradyanların Eş Oluşum Histogramları)
CPU	: Central Process Unit (Merkezi İşlem Birimi)
DOOG	: Difference of Offset Gaussian (Ofset Gaus Farkı)
FCM	: Fuzzy Clustering Mean (Bulanık Kümeleme Anlamı)
FPS	: Frame Per Second
GPU	: Graphics Process Unit (Grafik İşlemci Birimi)
ISO	: International Organization for Standardization (Uluslararası Standardizasyon Teşkilatı)
KA	: Karar Ağacı
KEYK	: K En Yakın Komşuluk
M.Ö.	: Milattan Önce
MATLAB	: Matrix Laboratory
MDP	: Markov Decision Process (Markov Karar Süreci)
MP	: Megapixel

OPENCV	: Open Source Computer Vision (Açık Kaynak Bilgisayarlı Görü)
PDF	: Probability Density Function (Olasılık Yoğunluk Fonksiyonu)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
RMSE	: Root Mean Square Error (Ortalama Hata Kareleri Kökü)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
USB	: Universal Serial Bus (Evrensel Seri Veriyolu)
WDR	: Wide Dynamic Range (Geniş Dinamik Aralık)
YSA	: Yapay Sinir Ağları



ŞEKİLLER DİZİNİ

Şekil 2.1. Çin’lilerde ipekli el dokuma tezgahı	6
Şekil 2.2. Mekiğin elle atıldığı, ağızlık açma ve atkı sıkıştırma işlemlerinin pedallar ve tarak ile yapıldığı el dokuma tezgahında çalışmanın sembolik resmi.	6
Şekil 2.3. Kalite kontrol makinesi (Altinel makine).	7
Şekil 2.4. Kumaş Kalite Kontrol Panosu ve Uyarlanan Sistem, Ala (2008).	10
Şekil 2.5. Sistem görseli (Yıldız vd., 2016).	11
Şekil 2.6. Tasarlanan sistemin prosedürünü izah için, kamera ile elde edilen görüntü Gri seviyeye dönüştürülmüş.....	12
Şekil 2.7. Örgü Sistemi ve gerçek zamanlı hata tespit sisteminin genel yapısı (Hanbay vd., 2017).	13
Şekil 2.8. Fotoğraf çekmenin sağ ve sol ortamı (Şeker ve Yüksek, 2017).	14
Şekil 2.9. Gizli katmanda 100 düğümlü otomatik kodlayıcının temel modeli. (Şeker ve Yüksek, 2017).	15
Şekil 2.10. a) Orijinal görüntü b) Hata tespit yapılmış görüntü (Bağkur, 2013).	16
Şekil 2.11. Hata denetim raporu (Taşçı, 2015).	17
Şekil 3.1. Atkı keşiği hatası.	20
Şekil 3.2. Ayak kaçığı hatası.	20
Şekil 3.3. Tahar hatası.	21
Şekil 3.4. Yağ lekesi hatası.	21
Şekil 3.5. Yabancı elyaf hatası.	22
Şekil 3.6. Yırtık – delik hatası.	23
Şekil 3.7. Çözgü kopuğu hatası.	24
Şekil 3.8. 3 bant görseli (Ükte, 2023).	26
Şekil 3.9. RGB bantlarının gri tonlamalı görüntüleri (Ükte, 2023).	27
Şekil 3.10. Yapay renkli görüntülerin kombinasyon görselleri (Ükte, 2023).	28
Şekil 3.11. Üç Izgaranın Birleşimi (Ükte, 2023).	29
Şekil 3.12. $T(r)$ koşullara göre grafikleri	31

Şekil 3.13. Çalışılan kumaş hatalarından birine ilişkin orijinal görüntü (Sol üst), aşındırılmış görüntü (sol orta), genişletilmiş görüntü (sol alt), orijinal görüntü histogramı (sağ üst), aşındırılmış görüntü histogramı (sağ orta) ve genişletilmiş görüntü histogramı (sağ alt).....	35
Şekil 3.14. Orijinal görüntü (sol) - dilate (yayma - genişletme) işlemi sonucunda oluşan görsel (sağ).	36
Şekil 3.15. Yapay Sinir Ağı Mimarileri (Van Veen, 2019).	38
Şekil 3.16. Havuzlama İşlemi (Gürbüz, 2023).	39
Şekil 3.17. Cnn aşamaları (Gürbüz, 2023).	40
Şekil 4.1. Kalite kontrol bölümünde kontrolü gerçekleştirilecek olan kumaşlar.	44
Şekil 4.2. İşletme görseli.	44
Şekil 4.3. Kalite kontrol makinesi görseli ön kısım.	45
Şekil 4.4. Kalite kontrol makinesi görseli arka kısım.	46
Şekil 4.5. Firma kalite kontrol uzman operatörü.	46
Şekil 4.6. Kalite kontrol makinesi sol kısım.	47
Şekil 4.7. Sahnenin genişlik ve yükseklik değerlerine göre seçilen kamera geometrisi.	48
Şekil 4.8. Üst ışık etkisindeki kalite kontrol makinesi.	49
Şekil 4.9. Sigma profillerin kalite kontrol makinesi üzerindeki montajı (yan profilden görünüş ve tezgaha montaj edilmesi).	50
Şekil 4.10. İş akış diyagramı (İşlem adımı numara karşılıkları aşağıda sözdekod'da verilmiştir BKZ Şekil 5.10).	51
Şekil 5.1. Görüntü işleme hata tespit sözde kodu.	56
Şekil 5.2. Tespit edilen hata türünün sınıflandırılması için tasarlanan CNN mimarisi sözde kodu (Tasarlanan CNN mimarisi Şekil 6.3'de verilmiştir).	57
Şekil 5.3. Tasarlanan CNN mimarisine ait model özeti.	58
Şekil 5.4. Kullanıcı arayüz ekranı görseli.	59
Şekil 5.5. Kullanıcı arayüz ekranı sözde kodu.	60
Şekil 5.6. Operatör hata kayıt rapor örneği.	61
Şekil 5.7. Tasarlanan sistemin bulduğu hatayı operatörün fark edip beze yaklaşması.	62
Şekil 5.8. Operatörün tasarlanan sistemin hatalı bulduğu bölgeye hata etiketi yapıştırması.	63
Şekil 5.9. Hata etiketli doğrulanmış örnek hata görseli.	63

Şekil 5.10. Sistemin yakaladığı pamuk hatası örneği (<i>BKZ: Yukarıda Pseudo Code, Yani; Yeşil Dikdörtgen: Alan Filtresi, Kırmızı Dikdörtgen: Eşik Değeri Sonucu – bütün şekillerde geçerlidir</i>).	64
Şekil 5.11. Sistemin yakaladığı kırış hatası örnekleri.	65
Şekil 5.12. Sistemin yakaladığı atkı hatası ve kırış örnekleri (<i>Atkı Hatasında Uzunluk Büyük Olduğundan Sistemi Yormamak İçin Küçük Dikdörtgenler Konulmuştur.</i>).	65
Şekil 5.13. Sistemin yakaladığı yabancı iplik hatası örneği.	66
Şekil 5.14. Sistemin yakaladığı kırış hatası örneği.	66
Şekil 5.15. Sistemin yakaladığı leke hatası örneği.	67
Şekil 5.16. Sistemin yakaladığı tahar hatası örneği.	67
Şekil 5.17. Sistemin yakaladığı kırış hatası örneği.	68
Şekil 5.18. Sistemin DOOG filtre sonucunda yakaladığı atkı hatası örneği.	68
Şekil 5.19. Sistemin yakaladığı yabancı iplik hatası örneği.	69
Şekil 5.20. Sistemin yakaladığı yapışkan etiket hatası örneği.	69
Şekil 5.21. Sistemin yakaladığı yabancı iplik örnekleri.	70
Şekil 5.22. Kenar püskülü hatası.	72
Şekil 5.23. Farklı tipteki kumaş hatası.	73
Şekil 5.24. Yeşil renkteki kumaşta oluşan hata.	74
Şekil 5.25. Yeşil renkteki kumaşta oluşan hatalar.	75
Şekil 5.26. Kırış hatasına ait tasarlanan CNN test skor sonucu.	76
Şekil 5.27. Atkı hatasına ait tasarlanan CNN test skoru sonucu.	76
Şekil 5.28. Kırış hatasına ait tasarlanan CNN test skoru sonucu.	76
Şekil 5.29. Farklı tipteki hataların yer aldığı kumaş görüntüsü (<i>Üst taraf atkı hatası, orta taraf kırış hatası, alt taraf yabancı iplik hatası</i>).	77
Şekil 5.30. 10 döngü değerine ilişkin kayıp, doğruluk ve validasyon doğruluğu değerleri.	78



ÇİZELGELER DİZİNİ

Çizelge 2.1 Olası hata tipleri ve yüzdeleri.	8
Çizelge 2.2 Matlab ve C++/Opencv ortamlarının hatasız kumaş kontrolünde CoHOG yöntemi ile elde ettikleri önemli metrik sonuçlar. (Hanbay vd., 2017). ..	14
Çizelge 3.1 Parlaklık değerleri çizelgesi (Ükte, 2023).....	28
Çizelge 3.2 Makine öğrenmesi – Derin Öğrenme Çizelgesi.	37
Çizelge 4.1 Seçilen kamera özellikleri.	48
Çizelge 5.1 Sadece üst ışık etkisindeki beyaz renkli ham bez kumaşın başarımı.	71
Çizelge 5.2 Beyaz renkli ham bez kumaşın karmaşıklık matrisleri.	71
Çizelge 5.3 Sadece alt ışık etkisindeki beyaz renkli ham bez kumaşın başarımı.....	72
Çizelge 5.4 Siyah renkli kumaştaki hataların sınıflandırma başarımı <i>(tek ışık yetmediğinden iki ışık kullanılmıştır)</i>	73
Çizelge 5.5 Operatör – Tasarlanan sistem hata tespit ve sınıflandırma başarımı (%)....	75



ÖZET

DERİN ÖĞRENME VE GÖRÜNTÜ İŞLEME KULLANILARAK KUMAŞ HATALARININ TESPİT EDİLMESİ VE SINIFLANDIRILMASI

**Topçu, U. Aydın Adnan Menderes Üniversitesi, Fen Bilimleri Enstitüsü,
Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Danışman:
Doç. Dr. Coşkun DENİZ, Aydın, 2024.**

Kumaş hatalarının tespit edilmesi ve bu hataların doğru bir biçimde sınıflandırılabilmesi tekstil sektörü için son yıllarda önemli hale gelmiştir. Firmaların kar marjının geçmiş yıllara göre düşmesi ve işçi maliyetlerinin artması sebebiyle sektörde yeni arayışlar ortaya çıkmıştır. Teknolojik çözümler, zaman, maliyet ve kalite bakımından sektördeki firmaların ihtiyacı haline gelmektedir. Tez çalışmasının hedefi tekstil sektörünün zorlandığı bu dönemlerde yenilikçi firmaların teknolojiyle birlikte rakiplerine karşı daha güçlü bir konuma gelmelerini sağlamaktır. Pakistan, Hindistan ve benzeri ülkelerin iş gücü maliyeti ülkemizden daha düşük olduğu için sektördeki firmaların kaliteden ödün vermeden doğru bir analizle müşterilerine ürün tedarik etmesi kaçınılmaz bir durum oluşturmaktadır. Tez çalışması, dokuma kumaş hatalarının doğru bir biçimde tespit edilip bu hataların sınıflandırılmasına yönelik bir çerçeve içerisinde oluşturulmuştur.

İki aşamadan oluşan bu sistemde ilk aşama dokuma kumaş hatalarının tespit edilmesidir. Görüntü işleme tekniklerinden renk dönüşümleri, histogram analizi ve morfolojik işlemler kullanılmıştır. Renkli görüntü öncelikle tek bant gri tonlamalı görüntüye çevrilmiş sonra görüntü kırpma işlemleri ile histogram çıkarımı yapılmıştır. Morfolojik işlemler sonrasında eşikleme işlemi yapılmış ve hatalı görüntüler elde edilmiştir. İkinci aşama olan sınıflandırma kısmında derin öğrenme algoritmalarından evrimsel sinir ağları CNN (Convolutional Neural Network) kullanılmıştır. Farklı renkteki ve farklı aydınlatma sahnelerindeki kumaşların hata tespit ve sınıflandırma başarımları belirlenmiştir. Prototip sistem hazırlanmış ve Denizli ilinde yer alan EVSA

Tekstil işletmesinde başarılı bir biçimde kullanıma hazır hale getirilmiştir. Elde edilen çıktılar yorumlanarak bu alandaki diğer araştırmacılara ve okuyuculara fikir vermesi amaçlanmıştır.

Anahtar Kelimeler: Derin öğrenme, CNN, Görüntü işleme, Histogram, Kumaş hata tespit, Sınıflandırma



ABSTRACT

DETECTION AND CLASSIFICATION OF FABRIC DEFECTS USING DEEP LEARNING AND IMAGE PROCESSING

**Topçu, U. Aydın Adnan Menderes University, Institute of Science and
Technology, Department of Electrical and Electronics Engineering, Master's
Thesis, Supervisor: Assoc. Dr. Coşkun DENİZ, Aydın, 2024.**

Detecting fabric defects and classifying these defects correctly has become important for the textile industry in recent years. Due to the decrease in the profit margin of the companies compared to the past years and the increase in labor costs, new searches have emerged in the sector. Technological solutions are becoming a need for companies in the sector in terms of time, cost and quality. The aim of this thesis is to enable innovative companies to become stronger against their competitors with technology in these periods when the textile sector is struggling. Since the labor cost of Pakistan, India and similar countries is lower than our country, it is inevitable for companies in the sector to supply products to their customers with an accurate analysis without sacrificing quality. The thesis study was created within a framework for the accurate detection of woven fabric defects and classification of these defects.

In this system, which consists of two stages, the first stage is the detection of woven fabric defects. Image processing techniques such as color transformations, histogram analysis and morphological operations were used. The color image was first converted to a single band grayscale image and then histograms were extracted by image cropping. After morphological operations, thresholding was performed and erroneous images were obtained. In the second stage, classification, CNN convolutional neural networks, one of the deep learning algorithms, were used. The error detection and classification achievements of fabrics in different colors and different lighting scenes were determined. The prototype system was prepared and successfully put into use in EVSA Textile

enterprise located in Denizli province. The outputs obtained are interpreted and it is aimed to give ideas to other researchers and readers in this field.

Keywords: Deep learning, CNN, Image processing, Histogram, Fabric defect detection, Classification



1. GİRİŞ

Tekstil sektöründe kumaş üreticisi olan firmaların müşterilerine hatasız kumaş tedariki sağlaması son derece önem arz etmektedir. Bu önem çerçevesinde üretici firmalar her ne kadar kalite kontrol operatörleri ile kumaşlarını “hatalı” veya “hatasız” şeklinde kategorize etse de bu süreçten istenilen verim alınamamaktadır. İnsan, doğası gereği bedensel ve mental anlamda yorgunluk belirtileri gösterebilmektedir. Çalışma koşulları, stres, psikolojik etmenler vb. sebeplerden dolayı insanlar gerekli çalışma performansını her zaman yeteri düzeyde sağlayamayabilirler. Bu yüzden her zaman istenilen performansı gösteremezler. İşletmelerde bu durum sıkça yaşanmaktadır. Örneğin 50m/dk hızla ilerleyen kalite kontrol makinası üzerindeki kumaşa, meydana gelebilecek hataların tespiti normalde insan gözüyle yapılmaktadır ve bu hata tespiti neticesinde yaklaşık %40 başarı elde edilmektedir (Kısaoglu, 2006). Entegre tesislerde bu durum bir sonraki prosese geçiş aşamasında bile büyük bir önem taşımakta iken son ürünün hata oranı yüksek bir biçimde kullanıcılara teslim edilmesi kabul edilemez bir durumdur. Bu ve benzeri sebeplerden ötürü kumaş hatalarının tespit etme işi otomasyonel bir biçimde insan kontrolünden olabildiğince bağımsız daha hassas cihazlar ve sistemler ile olmalıdır.

Yapay zeka ve dijitalleşmenin önemini her geçen gün daha iyi kavradığımız dünyamızda teknolojik gelişmelere ayak uydurabilmek gerekmektedir. Firmalar arasındaki rekabet ortamında teknolojik gelişmelere yatırım yapılması ihtiyacı en az maliyet ile en çok kazanç sağlama noktasında gereklilik göstermektedir. Kumaş hatalarının istenilen tolerans aralıklarında tespit edilebilmesi ve bu hataların isimlerinin neler olduğunun saptanabilmesi, yazılım ve donanımın iç içe kullanılması ile yüksek verimlerde gerçekleştirilebilmektedir. Günümüzde gelişmiş ülkelerdeki birçok tekstil firmaları otomasyonel kalite kontrol makineleri kullanmaktadır. Bu firmalar, kalite kontrol makineleri üzerinde kumaş hatalarını tespit edebilmek için çeşitli yazılım firmalarından gelişmiş sistemler satın almaktadırlar. Dünya tekstil pazarında rekabet gücünün artmasına duyulan ihtiyaç ve bu ihtiyacı karşılayabilmek için teknolojik yeniliklerin arayışında olan vizyoner yöneticilerin artması ile bu yenilikçi teknoloji, ülkemizdeki uygulama sahalarında giderek artan bir ivmeyle talep görmeye başlamıştır. Yazılım ve otomasyon işi yapan firmalar da bu talebe karşılıksız kalamayıp teknolojik yatırımlarını ve araştırma geliştirme çalışmalarını bu alanda yoğunlaştırmışlardır. Böylece yapılan bu tez çalışmasının ana fikri ortaya çıkmıştır.

1.1. Tezin Amacı

Bu tez çalışmasının temel amacı tekstil sektöründe en sık karşılaşılan dokuma kumaş hatalarının doğru bir biçimde tespit edilebilmesi ve tespit edilen hataların doğru bir biçimde sınıflandırılmasını sağlamaktır. Tekstil firmasında sürekli çalışan kumaş kalite kontrol makinesi üzerine sistemin montajının yapılması ve gerçek zamanlı hata tespitinin sağlanması, bu tez çalışmasını öne çıkaran önemli bir faktördür. Hata tespiti yapılmış olan kumaşın hata tipi ne ise o hata tipine göre sınıflandırılması da tasarlanan sistem içerisinde yer almaktadır. Çalışma sonunda ortaya çıkan tasarımla, firmaların bu sistemden yararlanmasına yönelik bilimsel katkı beklenmektedir. Bu sayede, kumaş hatalarının tespit ve sınıflandırılmasına yönelik gerçek zamanlı çalışan bir sistem tasarlayıp literatüre katkı sağlanması hedeflenmiştir.

1.2. Tezin Organizasyonu

Bölüm 2’de kaynak özetleri başlığı altında tekstil süreci içerisinde yer alan kumaş dokuma tezgahlarının çalışma prensibinden ve dokuma tezgahlarının tiplerinden bahsedilmiştir. Kalite kontrol tezgahlarından ve dokuma kumaşta meydana gelen hataların bilgilerinin yer aldığı hata kataloglarından bilgiler aktarılmıştır. Bunun yanında literatürde yer alan hata tespit çalışmalarından bahsedilmiştir.

Bölüm 3’te materyal ve yöntem başlığı altında bazı dokuma kumaş hata tiplerinin neler oldukları açıklanmıştır. Bu hata tipleri görsellerle desteklenmiştir. Kumaş hatası tespitine yönelik literatürde yer alan yöntemlere değinilmiştir. Bunun yanında tasarımın “*kumaş hatalarının tespit edilmesi*” kısmında kullanılan temel kavramlar (RGB) renk uzayı, gri tonlama dönüşümü, histogram analizi ve morfolojik işlemler *görüntü işleme* alt başlığı altında açıklanmıştır. Tasarımın, “*tespit edilen kumaş hatalarının sınıflandırılması*” kısmında kullanılan evrişimsel sinir ağları (CNN) ve yapay sinir ağları (YSA) alt başlığında incelenmiştir.

Bölüm 4’te bulgular başlığı altında tasarlanan sisteme ait çalışmalara değinilmiştir. Bunlar veri setinin hazırlanması, kumaş hata tespit ve sınıflandırılmasına ait matematiksel alt yapının oluşturulması ve bu sisteme yönelik yazılımın yapılmasıdır. Veri setinin oluşturulması alt başlığı altında kameraların seçimlerinin yapılması, aydınlatma cihazlarının seçimi, metre sayacı ve okuyucu ekipmanların entegrasyonunun sağlanması, sistemin kalite kontrol makinesi üzerine entegrasyonunun gerçekleştirilmesi ve bilgisayara bağlı olan haberleşme kablolarının sistem ile entegrasyonundan bahsedilmiştir. Bunun yanında kumaş hata tespit ve sınıflandırılmasına ait iş akış diyagramı ve yazılımından bahsedilmiştir.

Bölüm 5’de tartışma başlığı altında gerçek zamanlı kumaş hata tespit sisteminin kurulum, montaj ve devreye alma aşamaları anlatılmıştır. Sistemin tasarlanan arayüzü görsellerle anlatılmıştır. Tespit edilen kumaş hatalarının sınıflandırma işlemi, yapay sinir ağları (YSA) ve evrimsel sinir ağları (CNN) kullanılarak gerçekleştirilmiştir. Tasarlanan sistemin dokuma kumaş üzerinde başarı yüzdeleri çizelgeler halinde verilmiştir.

Bölüm 6’da sonuç ve öneriler başlığı altında gerçek zamanlı kumaş hata tespit ve sınıflandırma sisteminin getirdiği yeniliklerden, sistemin kullanım kolaylığından ve başarımından bahsedilmiştir. Yapılacak olan sonraki çalışmalar için önerilerde bulunulmuştur.






2. KAYNAK ÖZETLERİ

Kalite standartlarını değerlendirirken genelde ISO 9000 serisi standartlar baz alınmaktadır. Dokuma kumaşlarda yapılan incelemeler genel kalite tanımı baz alınarak daha anlaşılır olmaktadır. Genel anlamda kalite kavramı bir hizmetin veya üretilen bir malın, kullanım amaçları doğrultusunda önceden belirlenen isteklere göre yapılması veya üretilmesidir. Bu tasarımda söz konusu kullanım amaçları, maliyet, güvenlik, çevre, bakım kolaylığı, elde edilebilirlik gibi etmenleri de içinde bulundurur. Bu bakımdan kalite terimi ürün veya hizmetin yukarıdaki faktörlerine bağlı olarak değişiklik gösteren ve belli sınıflara ayrılan bir kavramdır. Bu bölümde kumaş dokuma sürecine yönelik ön bilgi vermek üzere kalite kavramını, kumaş dokuma işlemini, dokuma hata tiplerini okuyucuya genel bilgi anlamında sunmak, hata tespit ve sınıflandırmada sözü edilen kavramların daha net bir biçimde anlaşılmasını sağlayacaktır.


2.1. Kumaş Dokuma Tezgahları

Dokumacılık, dünyada bilinen en eski tekstil yüzeyi oluşturma yöntemidir. Arkeolojik kazılarda elde edilen bazı bulgular M.Ö. 7000-7500 yıllarındaki medeniyetlerde ilkel olarak iki iplik sisteminin birbirlerine dik olarak bağlantı oluşturmasıyla dokuma kumaş üretildiğini ortaya koymaktadır. Eski bir tarihe sahip olmasına rağmen dokumacılık uzun yıllar önemli bir gelişme göstermemiştir. İlk olarak 12. yüzyılda tamamen ağaçtan yapılan, genel anlamda bugünkü dokuma makineleri ile aynı prensibe sahip olan, fakat bütün işlemlerin insan gücüyle yapıldığı el dokuma tezgahları geliştirilmiştir (Yakartepe, 1998). Bu tezgahlara ait görseller Şekil 2.1 ve Şekil 2.2’de verilmiştir.



Şekil 2.1. Çin’lilerde ipekli el dokuma tezgahı

a) Çerçeveler, b) Çözü, c) Pedal, d) Tarak, e) Çapraz Çubukları, f) Atkı Bobini (Yakartepe, 1998).



Şekil 2.2. Mekiğin elle atıldığı, ağızlık açma ve atkı sıkıştırma işlemlerinin pedallar ve tarak ile yapıldığı el dokuma tezgahında çalışmanın sembolik resmi.

a) Çözü levendi, b) Çözüyü frenleyen ağırlıklar, c) Çözüyü salma ve sarma kolu, d) Çözü iplikleri, e) Çerçeveler ve gücü telleri, f) Çerçevelere hareket ileten pedallar, g) Tarak, h) Tefe vazifesi gören taşıyıcılar, i) mekiğin elle ağızlığa atılması, j) Kumaş levendi, k) Kumaş sarma kolu (Yakartepe, 1998).

2.2. Kumaş Kalite Kontrol Tezgahları

Kumaş kalite kontrol işlemi, dokuma süreci tamamlandıktan sonra kumaşların, eğer varsa dokuma tezgahı üzerinde yer alan aydınlatma ekipmanlarından faydalanarak normalde operatörler tarafından gözle ya da bu çalışmada olduğu gibi geliştirilmiş yenilikçi teknolojik yöntemlerle kontrolünün sağlanmasıdır. Bu suretle, dokuma tezgahı üzerinde dokuma işlemi yapılan kumaşın müşteriye raporlanarak teslimi veya bir sonraki üretim sürecine geçilmesi sağlanmış olmaktadır Otomasyonel tipteki bazı kalite kontrol tezgahlarında kumaş hatalarının insan gözüyle tespitini kolaylaştıran seçenekler yer almaktadır. Piyasada birçok firmanın farklı özelliklerde kalite kontrol makinesi bulunmaktadır. Genel tipteki bir kalite kontrol makinası Şekil 2.3'te verilmiştir.



Şekil 2.3. Kalite kontrol makinesi (Altinel makine).

Makine üzerinde her türlü ham ve mamul kumaşların kalite kontrol işlemi gerçekleştirilebilmektedir. Hızı 0-60 m/dk aralığındadır. İleri – geri çalışma yönüne sahiptir. Kumaşın sertlik ayarı yapılabilmektedir ve kumaşa alttan ve üstten aydınlatma imkanı sağlanmaktadır.

2.3. Kalite Kontrolde Dokuma Kumaş Hata Katalogları

Kalite kontrol sürecinde dokuma kumaş üzerinde meydana gelen birçok hata mevcuttur. Bu hatalardan bazıları bölüm 3'te anlatılmaktadır. Bu hataların çerçevesinde oluşan katalog bilgilerine *hata katalogları* adı verilmektedir. Kumaş hata kataloglarına ait belirli standartlar mevcuttur (Barış ve Özek, 2019). Bu standartlar uluslararası normlara sahiptir ve ilgili araştırmacı ve okuyucuların kullanımına açıktır. En sık karşılaşılan kumaş hata tiplerinden bazıları: *atkı kesigi*, *ayak kaçığı*, *tahar hatası*, *yağ lekesi*, *yabancı elyaf*, *yırtık-delik*, *çözgü kopuğu* hatalarıdır. Kullanıcılar uygulamalarına özel bir biçimde hangi kumaş hata tipleri ile ilgileneceklerini keyfi olarak seçebilirler. Hata katalog verisi genel anlamda bir periyot içerisindeki sürede örneğin senelik veya aylık olacak şekilde hata tiplerini ve toplamda yer alan yüzdeleri içermektedir. (Standart, 1996). Üretilen bir kumaşa ilişkin fabrika hata katalog verisi örneği aşağıda Çizelge 2.1'de gösterilmiştir.

Çizelge 2.1 Olası hata tipleri ve yüzdeleri.

Hata Tipi	Yüzdesi (%)
Atkı Kesigi	15
Ayak Kaçığı	7
Tahar Hatası	4
Yağ Lekesi	16
Yabancı Elyaf	3
Yırtık Delik	20
Çözgü Kopuğu	35

Çizelge 2.1'de yer alan olası hata tipleri Bölüm 3'de açıklanacaktır.

Kumaş hatalarının tespit edilmesi ve tespit edilen bu hataların sınıflandırılabilmesine yönelik çalışmalar genellikle görüntü işleme ve yapay zeka yöntemleri kullanılarak gerçekleştirilir. Bunun sebebi görüntü işleme yöntemlerinin tekstil sektöründe yer alan kumaşlardaki küçük ayrıntıları iyi bir şekilde yakalayabilmesindendir. Ortaya çıkarılan hatalar gerekli durumlarda hedeflenir böylece hatanın insan gözüyle görülebilmesi sağlanır. Sonraki aşamada amaçlanan ise kumaş üzerinde belli bir lokasyonda mevcudiyeti tespit edilmiş olan kumaş hatasının önceki bölümde incelenen kumaş hatası tiplerine göre kategorize edilmesi yani sınıflandırılmasıdır. Burada ilk aşama "*kumaş hatalarının tespit edilmesi*", ikinci aşama ise, "*tespit edilen kumaş hatalarının sınıflandırılması*" olarak karşımıza çıkmaktadır. Yapay zeka yöntemleri ile etkili ve verimli bir sınıflandırma başarımı yakalamak mümkün olmaktadır. Bu

bölümde, kumaş hatalarının tespit ve sınıflandırılmasına ilişkin literatürde yer alan temel görüntü işleme ve yapay zeka yöntemleri ele alınmıştır.

2.4. Literatürde Yer Alan Hata Tespit Çalışmaları

Tekstil sektöründe yapılan kumaş hatalarının tespit etme ve sınıflandırmaya yönelik çalışmalar ile ilgili yeni bakış açıları gün geçtikçe artmaktadır. Bu çalışmanın amacı kumaş hatalarının gerçek zamanlı tespit edilebilmesi ve sınıflandırılmasıdır. Geçmişten günümüze birçok araştırmacı bu konuda çalışmalar yapmıştır. Bu çalışmalardan bazıları aşağıda verilmiştir:

Ala (2008) yaptığı çalışmada CCD (charged coupled device) (yük bağlaşımlı cihaz) çizgisel kamera ile kaydedilen dokuma kumaş görüntülerindeki dokuma hatalarını tespit ederek, hata tanımlarının sayısallaştırılmasını sağlamıştır. Bu tez çalışmasında %100 pamuklu, dokuma ham bez kumaşlar kullanılmıştır. Kumaşlar kalite kontrol panosundan dakikada 3 metre hızla sarılarak geçirilmiş ve CCD çizgisel kamera ile 2048*4096 piksel boyutlarında, BMP formatında görüntüler alınmıştır. Hatalı kumaş görüntüleri seçilerek, dokuma kumaş hatalarına göre sınıflandırılmış ve photoshop CS3 programı ile görüntülerin gri renk değerleri ve hata boyutları incelenmiştir. Kumaşın hatalı kısmı ile hatasız kısmının sayısal değerleri çıkarılarak Çizelgeler halinde verilmiştir. Farklı hataların sayısal değerleri bulunmuştur.

CCD kamera modelleri mükemmel WDR'ye wide dynamic range (geniş dinamik aralık) sahiptir, bu nedenle bu tip görüntü sensörlerine sahip kameralar düşük ışık koşullarında yüksek performans gösterir. CCD kameralar CMOS kameralar ile karşılaştırıldığında genellikle titreşim sorunlarından daha az etkilenir. CCD güvenlik kameraları, “global obtüratör” kullanır, yani tüm sensörü anında gösterir ve titreşime daha az duyarlıdır. Kumaş hatalarının tespitinde CCD kamera kullanılan söz konusu çalışmanın görseli Şekil 2.4'te verilmiştir.



Şekil 2.4. Kumaş Kalite Kontrol Panosu ve Uyarlanan Sistem, Ala (2008).

Hanbay ve Talu (2014) kumaş hatalarının online ve offline tespit sistemleri ve yöntemleri çalışmalarında güncel hata tespit metotlarının matematiksel formülasyonlarını, özelliklerini ve güçlü ve zayıf yönlerini incelemişlerdir. Metotları yedi ayrı sınıfa ayırarak karşılaştırma çalışması yapmışlardır. Her metot için ayrı ayrı gürültü hassasiyeti, güvenilirlik, döndürme/ölçekleme bağımsızlığı ve başarı oranı sonuçları ile bir kalite analizi sunmuşlardır.

Yıldız vd. (2016) kumaş hata denetimi ile ilgili iki farklı çalışma gerçekleştirmiştir. İlk çalışma hatalı kumaş görüntülerine görüntü işleme algoritmaları uygulamaktır. Hatalı alanın tespitinden sonra şekilsel ve histogram özellikleri çıkartılmıştır. Bu özellikler kullanılarak Fuzzy C-Means (FCM) algoritması ile kümeleme işlemi gerçekleştirilmiştir. Ayrıca tespit edilen hatanın kumaş üzerindeki dikey ve yatay koordinatlarının belirlenmesi de gerçekleştirilmiştir. İkinci çalışmada ise kaydedilen video üzerinde hatalı görüntünün tespiti yapılmıştır. Hata, K En Yakın Komşu (KEYK), Bayes Ağları (BA) ve Karar Ağaçları (KA) algoritmaları kullanılarak anlık olarak sınıflandırılmıştır. Ayrıca hatanın yeri, cinsi ve kumaşın hangi metresinde yer aldığı belirlenmiştir. İlk çalışmada hatalı görüntüler üzerinde Fourier Analizi, Gabor Filtreler ve Dalgacık Dönüşümü yöntemleri ile uygulamalar yapılmıştır. Geliştirilen Fourier Tabanlı görüntü işleme yönteminin diğer algoritmalarından daha iyi sonuç verdiği gözlenmiştir. Poplin kumaş üzerinde delik, yırtık, yabancı iplik, makine yağı, nope, çözgü kaçığı ve atkı kaçığı hataları belirtilen görüntü işleme yöntemleri ile tespit edilmiştir.


Aynı çalışmada denim ve kaşe kumaş üzerinde- çözgü ve atkı kaçığı hatalarının tespitinde ise geliştirilen algoritmalar etkisiz kalmıştır. Farklı türdeki kumaş ve hatalar üzerinde şekilsel ve histogram özellikleri kullanılarak FCM ile yapılan uygulamada ortalama %87 kümeleme başarısı elde edilmiştir. Gruplandırılan hata sayısının az veya fazla olması kümeleme

performansını etkilemektedir. Yapılan ikinci çalışmada ise 3 farklı kumaş türü üzerinde farklı hatalara sahip olan video üzerinde anlık hata tespiti, sınıflandırma ve yer tespiti gerçekleştirilmiştir. Hata sınıflandırma işlemi için anlık olarak kaydedilen video üzerinde gri seviye eş oluşum matrisi kullanılarak özellik çıkarımı yapılmıştır. Elde edilen özellikler KEYK, BA ve KA kullanılarak sınıflandırılmıştır. Sınıflandırma işlemi için her bir hata türüne ait 6 adet görüntü, eğitim verisi olarak kullanılmıştır. KEYK algoritması ile yapılan uygulamada ortalama olarak %90'lık bir başarı elde edilmiştir. KEYK ile yapılan uygulamalarda diğer yöntemlere göre daha iyi sonuçlar elde edilmiştir. Çalışma görseli Şekil 2.5'te verilmiştir.



Şekil 2.5. Sistem görseli (Yıldız vd., 2016).


Tağluk (2017) çalışmasında tekstil fabrikasında gerçek zamanlı elde edilmiş kumaş imgelerin uzaysal iki boyutlu spektrumları alınmış ve bu problem için tasarlanan özel bir kernel ile filtrelenmiştir. Filtreleme sonucunda elde edilen spektral güç değerleri kullanılarak hatalı ve sağlam kumaş imgeleri yaklaşık olarak %99.19 oranında birbirinden ayrıştırılmıştır. Bu başarı oranı geliştirilen yöntemin başarılı olduğunu göstermektedir. Ayrıca bu sistemin gerçek zamanlı uygulamalar için yeterince hızlı olduğu tespit edilmiştir. Bu çalışmanın tasarım prensibine ilişkin bazı görseller Şekil 2.6'da verilmiştir.



Şekil 2.6. Tasarlanan sistemin prosedürünü izah için, kamera ile elde edilen görüntü Gri seviyeye dönüştürülmüş

(a), İki boyutlu spektrumu elde edilmiş (b), Spektrumun yakınlaştırılmış hali (c), Spektrumun Yüksek geçiren filtrelenmiş hali (d) ve spektrumun tasarlanan özel kernel ile filtrelenmiş hali (e) (Tağluk, 2017).

Hanbay vd. (2017) çalışmasında gerçek zamanlı kumaş hatası tespit sistemi geliştirilmiş ve yuvarlak örgü makinesi üzerinde test edilmiştir. Kumaş görüntüsünün dokusal özellikleri Fourier dönüşümü temelinde çıkarılmıştır. Bu dokusal özellikler 7 tane olup kumaş görüntüsünün Fourier frekans spektrumunun yatay ve dikey yönlerinden hesaplanmıştır. Önerilen metodunun performansı ilk olarak kapsamlı veri tabanı temel alınarak gerçek zamanlı olmayan çalışmalar yolu ile değerlendirilmiştir. Önerilen metot gerçek zamanlı kontrolde de başarı sağlayabilecek üstün bir performans elde etmiştir. İkinci olarak, endüstriyel şartlarda etkin bir kumaş hatası kontrolü için gerçek zamanlı makine görmesi sistemi tasarlanmıştır. Gerçek zamanlı hata tespit sistemi çizgi kamera tarafından elde edilen kumaş görüntüleri analiz edilerek test edilmiştir. Deneysel sonuçlar önerilen hata tespit modelinin yaygın örgü kumaş hatalarını başarılı bir şekilde tespit edebildiğini göstermiştir. Örgü sistemi ve genel yapısı Şekil 2.7’de verilmiştir.



Şekil 2.7. Örgü Sistemi ve gerçek zamanlı hata tespit sisteminin genel yapısı (Hanbay vd., 2017).

Hanbay ve Golgiyaz (2017) çalışmasında Matlab ve C++ programlama dillerinin zaman performanslarını karşılaştıran gerçek zamanlı bir hata tespit yaklaşımı sunulmuştur. Önerilen metotta, kumaş görüntülerinin önemli doku özellikleri CoHOG metodu ile çıkarılmıştır. Kumaş hatalarını sınıflandırmak için yapay sinir ağları kullanılmıştır. Geliştirilen metot yuvarlak örgü makinesi üzerindeki örgü kumaş hatalarını tespit etmek için uygulanmıştır. Matlab ve C++ uygulamaları için genel hata tespit başarı oranı %93 olarak elde edilmiştir. Hata tespiti alanındaki araştırmacılara fikir vermek için Matlab ve C++ kodlarının gerçek zamanlı işlem hızları incelenmiştir. Özellikle 1 saniyede işlenebilen görüntü sayısı belirlenmiştir. Matlab temelli kodlama 1 saniyede 3 görüntü işleyebilirken, C++/Opencv temelli kodlama 1 saniyede 55 görüntü işleyebilmektedir. Önceki çalışmalar nadiren yazılım ortamlarının karşılaştırmalı değerlendirmelerini içermektedir. Bu yüzden endüstriyel uygulama sonuçlarının bu alandaki gelecek çalışmalar için değerli bir kaynak olacağı düşünülmüştür. Çalışma sonuçları Çizelge 2.2’de verilmiştir.


Çizelge 2.2 Matlab ve C++/Opencv ortamlarının hatasız kumaş kontrolünde CoHOG yöntemi ile elde ettikleri önemli metrik sonuçlar. (Hanbay vd., 2017).

	Matlab	C++/Opencv (Debug mod)	C++/Opencv (Release mod)
1 saniyede analiz edilen görüntü sayısı	3	40	55
İncelenen toplam görüntü sayısı	900	900	900
Hatasız Olarak Tespit Edilen Görüntü Sayısı	837	828	828
Sağlamaları Tespit Başarısı (~)	%93	%92	%92

Şeker ve Yüksek (2017) çalışmalarında giriş verisini sıkıştırma ya da genişletme ile temsil eden yığınlı oto-kodlayıcılar kullanmışlardır. Kumaş hatası tespitinde oto kodlayıcının hiper parametreleri değiştirilerek öznitelik çıkarım başarısı artırılıp, veri setleriyle %96'lık bir başarı elde etmişlerdir. Çalışmaya ilişkin bazı görseller Şekil 2.8 ve Şekil 2.9'da verilmiştir.




Şekil 2.8. Fotoğraf çekmenin sağ ve sol ortamı (Şeker ve Yüksek, 2017).



Şekil 2.9. Gizli katmanda 100 düğümlü otomatik kodlayıcının temel modeli. (Şeker ve Yüksek, 2017).

Güler (2013) çalışmasında görüntü tanıma yöntemini kullanarak otomatik olarak kumaş hatalarını tespit etmiş ve sınıflandırmıştır. Görüntü işleme yöntemi olarak ayırık dalgacık dönüşümü kullanmış ve sınıflandırma için de ileri beslemeli ve çok katmanlı (Yapay Sinir Ağları) YSA kullanmıştır. CPU ve GPU’da çalıştırmak üzere aynı algoritmalara sahip iki adet uygulama geliştirmiştir ve uygulamaların hız bakımından performanslarını incelemiştir.

Bağkur (2013) çalışmasında DOOG filtrelerini kullanarak kumaşlardaki hatalı alanları tespit etmiş ve histogram analizi yardımıyla hatalı alanları daha belirgin hale getirmiştir. Sonuçlarda kumaş hatalarının tümünün doğru olarak tanımlanabildiğini göstermiştir. Bu çalışmaya ait görsel Şekil 2.10’da verilmiştir.



a)

b)

Şekil 2.10. a) Orijinal görüntü b) Hata tespit yapılmış görüntü (Bağkur, 2013).

Şekil 4.7’de sol kısımda yer alan görüntü orijinal görüntüdür. Sağ kısımdaki görüntü ise hata tespiti yapılmış görüntüyü temsil etmektedir.

Taşçı (2015) çalışmasında yonga levha üretim sistemlerinde görüntü işleme tabanlı hata denetim sistemi gerçekleştirmiştir. Görüntüler kameralar ile bilgisayara aktarılmış ve hata denetimi ve sınıflandırma işlemleri gerçekleştirilmiştir. Hata denetimi sonuçları ekranda anlık olarak gösterilmiş ve ayrıntılı rapor hazırlanmıştır. Bu çalışmaya ait görsel Şekil 2.11’de verilmiştir.

1 of 1 100% Find | Next

HATA DENETİM RAPORU

Ürün Numarası : 15

Ürün Sınıf No : 2

Ürün Görüntüsü



Ürün Özellik Bilgileri

Boyut X:	549
Boyut Y:	397
Ortalama R:	171
Ortalama G:	0
Ortalama B:	0
max-min R:	224 123
max-min G:	180 66
max-min B:	141 47
max-min Gray:	189 82

Şekil 2.11. Hata denetim raporu (Taşçı, 2015).

Nawaf (2019) çalışmasında kumaş hatalarının tespit ve sınıflandırılması ile ilgili görüntü işleme ve derin öğrenme yöntemlerine dayalı bir uygulama oluşturmuştur. Hata tespitinde ayrık Fourier dönüşümü ve Gabor filtreleri, sınıflandırma aşamasında ise Fast R-CNN kullanmıştır. RMSE ortalama kare hataları tespit ve sınıflandırma hatalarını hesaplamak için kullanılmıştır.

Shakir (2019) çalışmasında Fourier dönüşümüne dayalı denetimsiz bir yaklaşım sunmuştur. Yöntem kumaşla alakalı bir ön bilgiye ihtiyaç duymamaktadır. 10 farklı kumaş türünden 26 adet hata sınıfı içeren bir veri kümesi hazırlanmış ve bu alandaki çalışmacıların kullanımına sunulmuştur.

Bağırhan (2019) çalışmasında Shearlet dönüşümü kullanarak öznelik çıkarma metoduyla dokuma kumaşlarda çözgü kaçığı, atkı kaçığı, delik, yırtık ve leke hatalarını gerçek zamanlı olarak tespit eden bir sistem geliştirmiştir.

Çıklaçandır vd. (2020) çalışmalarında kumaş görüntüsünü eşit bloklara ayırarak bloklara özellik çıkarma yöntemi uygulayıp K means kümeleme algoritmasına sokmuşlardır. Özellik çıkarımı için iki farklı yöntem gri seviye eş oluşum matrisi ve ortanca farkı uygulamışlardır.

Gri seviye eş oluřum matrisi ile %97.99, ortanca farkı ile %86.91 hata bulma başarısı yakalamıřlardır ve atkı yönündeki hataların çözgü yönündeki hatalara göre daha kolay tespit edilebildiđini vurgulamıřlardır.

Karatař ve Soyaslan (2016) alıřmasında yapay görme sistemlerinin tekstil sektöründeki ihtiyalarına deđinmektedir. Bu alıřmada insan faktörü yerine otomasyonel sistemlerin ihtiya duyulduđu uygulama alanları belirlenmiřtir.

Kaur vd. (2022) alıřmalarında temel makine öğrenmesi araçlarını kullanarak pandemi dönemine dikkat çekerek insanın yüzünde maske olup olmadığına dair bir alıřma gerekleřtirmiřlerdir. Durađan veya hareket halindeki kiřinin maske takıp takmadıđını başarıyla tespit etmiřlerdir. Bu alıřma, kumař hatalarının tespitine yönelik olmasa da, görüntüdeki belli bir desenin (maske) tespitine yönelik yaygın alıřılan makine öğrenmesi metotlarını ieren bir alıřma olarak göze arpmaktadır.

Shahrabadi vd. (2022) alıřmalarında hazır veri seti kullanıp bilgisayarlı hata analizi gerekleřtirip bilindik mimarilere dayanan CNN algoritmaları ile %98'in üzerinde bir dođrulukta kumař hatası tespit etmiřlerdir.


3. MATERYAL VE YÖNTEM

Kumaş hatalarının tespit ve sınıflandırılması, dünya tekstil piyasasında rekabet gücü açısından günümüzde elzem duruma gelmiştir. Bunun sebeplerinden biri müşterilerin firmalardan siparişlerine yönelik sürdürülebilirlik ve dijitalleşme adımları istemesidir. Örneğin konfeksiyon firması bir müşteri tekstil dokuma kumaşı üreten bir firmadan nevesim takımı veya buna benzer bir ürün üretmek için dokuma kumaşı satın almak istediğinde, sipariş vermiş olacaktır ki bu sipariş belirli özelliklerde olmalıdır. Bu özellikler genellikle siparişin ağırlık, metre, renk, boyut vb. bilgilerini içermektedir. Gelişen teknolojiyle birlikte firmalar müşterilere dijital ortamda veya elden teslim edilmek üzere hazırladıkları ürüne ilişkin hata raporlarını da vermeye başlamışlardır. Sürecin her aşamasının titiz ve dikkatli bir biçimde gerçekleştiğini beyan etmek amacıyla firmalar, dokuma sürecinde veya kalite kontrol sürecinde ürünlerine ilişkin hata raporlarını müşterilerine sunarak dünya tekstil piyasasında rekabet gücünü koruyabilmektedirler. Bu davranışın amacı, müşteriye ürünlerinin hazırlık aşamasında büyük bir özenle ve kalite standartlarına uygun bir biçimde gerçekleştirildiğinin göstergesi olabilmektedir. Bu bölümde dokuma kumaş hata tiplerinden ve kumaş hatalarının tespitinde uygulanan yöntemlerden bahsedilmektedir.

3.1. Dokuma Kumaş Hata Tipleri


Bölüm 2’de Çizelge 2.1’de verilen bazı dokuma kumaş hata tipleri bu bölümde anlatılmaktadır. Literatürde 295 adetten fazla hata tipi mevcuttur. İşletmelerin farklı adlandırmaları yüzünden hata tiplerinin isimleri değişkenlik gösterebilmektedir. Bu karışıklığın önüne geçebilmek ve okuyucuya doğru bilgi verebilmek amacıyla bu çalışmada sınıflandırmada kullanılan kumaş hata tiplerini içeren en yaygın temel kumaş hata tipleri, bu bölümde ilgili görsellerle desteklenerek incelenmiştir.

En çok görülen hata tiplerinden ilki *atkı kesiği*’dir. Atkı kesiği hatası, ağırlık içindeki atkı ipliğinin kopması veya bitmesi neticesinde kumaş eninin bir kısmında atkı ipliğinin bulunup, bir kısmında bulunmamasıdır. Atkı kesiği hatası içeren örnek bir kumaş görüntüsü Şekil 3.1’de verilmiştir.




Şekil 3.1. Atkı kesiği hatası.

Ayak kaçığı hatası bir diğer tekstil hata tipi olup dokuda bir veya birkaç ipliğin eksikliğinden kaynaklanmaktadır. İki ayaktan çok dokularda yanlış ağızlığa atılan atkının oluşturduğu atkı hatasına da aynı ad verilmektedir. Ayak kaçığı hatası içeren örnek bir kumaş görüntüsü Şekil 3.2’de verilmiştir.




Şekil 3.2. Ayak kaçığı hatası.

Bahsedilmesi gerekli olan üçüncü hata tipi *tahar* hatasıdır. Tahar hatası çözgü ipliği hareketinin, sırasına uygunsuzluğunu gösteren bezdeki boyuna örgü hatasıdır. Tahar hatası içeren örnek bir kumaş görüntüsü Şekil 3.3'te verilmiştir.




Şekil 3.3. Tahar hatası.

Bir diğer hata olan *yağ lekesi* hatası kumaşın atkısı veya çözgüsü yönünde yağ şeklinde meydana gelmektedir. Yağ lekesi hatası içeren örnek bir kumaş görüntüsü Şekil 3.4'te verilmiştir.



Şekil 3.4. Yağ lekesi hatası.

Yabancı elyaf veya *yabancı iplik* hatası, kumaşın atkı veya çözgü yönünde farklı renkte elyaf bulunmasından kaynaklanmaktadır. Yabancı elyaf hatası içeren örnek bir kumaş görüntüsü Şekil 3.5’te verilmiştir.




Şekil 3.5. Yabancı elyaf hatası.

Yırtık-delik hatası kumaşın dikkatsizlik sonucu dokuma esnasında veya taşıma indirme bindirme esnasında meydana gelen hata tipidir. Yırtık delik hatası içeren örnek bir kumaş görüntüsü Şekil 3.6’da verilmiştir.



Şekil 3.6. Yırtık – delik hatası.

Çözü kopuğu hatası dokuma sürecinde meydana gelen en sık karşılaşılan hata tiplerinden biridir. *Çözü kopuğu* hatası dokuma esnasında *çözgü* ipliğinin kopması anında tezgahın durmamasından veya geç durmasından doğan ve *çözgü* yönünde örgünün kopuk iplik boyunca bozulmasından meydana gelen çizgi şeklindeki hata tipidir. *Çözü kopuğu* hatası içeren örnek bir kumaş görüntüsü Şekil 3.7’de verilmiştir.



Şekil 3.7. Çözü kopuğu hatası.

3.2. Kumaş Hatalarının Tespitinde Uygulanan Yöntemler

Kumaş hatalarının tespit edilmesinde uygulanan farklı yöntemler mevcuttur. Bu yöntemlerden en etkili olanları bu bölüm içerisinde alt başlıklar halinde verilmektedir. Bunlar sırasıyla *spektral yöntemler*, *model tabanlı yöntemler*, *istatistiksel yöntemler* ve *makine öğrenmesi* yöntemleri'dir. Bu yöntemlerin temel özellikleri bu bölümde incelenmiş olup, kumaş hatalarının tespitine yönelik uygulamalar, ilgili literatür ışığında bir sonraki bölümde detaylandırılarak incelenmiştir.

3.2.1. Spektral Yöntemler

Spektral yöntemler kumaş hata tespitinde son yıllarda kullanımı en yaygın olan yöntemlerdendir. Burada dikkat edilmesi gereken en önemli husus eğer spektral yöntemler kullanılarak kumaş hataları tespit edilmek istenecekse kumaş veya desenin periyodik olması gereklidir. Aksi halde yani periyodik olmayan kumaş ve desen üzerinde spektral tabanlı bir çalışma yapılması durumunda istenilen sonuçlar elde edilemeyebilmektedir. En yaygın spektral yöntemler *Fourier dönüşümü*, *Gabor dönüşümü*, *Dalgacık dönüşümü*'dür.

Fourier dönüşümü, temel matematik ve mühendislik ders kitaplarında mevcuttur. Dennis Gabor'un adını alan Gabor dönüşümü, Fourier dönüşümünün kısa zamanlı olanının bir başka

versiyonudur. Sinüzoidal frekansı bulmak için kullanılan dönüşüm yerel anlamda faz içeriği bilgisini de verir. Bir $x(t)$ sinyalinin gabor dönüşümü denklem 1'deki gibidir.

$$G_x(\tau, \omega) = \int_{-\infty}^{\infty} x(t) e^{-\pi(t-\tau)^2} e^{-j\omega t} dt \quad (1)$$

3.2.2. Model Tabanlı Yöntemler

Doku genellikle karmaşık yapıda bir örüntü dizisi olarak kabul edilir ve olasılıksal (stochastic) veya olasılıksal olmayan (deterministic) bir model tarafından tanımlanabilir. Kumaş görüntüleri gibi gerçek dokular olasılıksal bir işlem olarak modellenenebilir. Dolayısıyla görüntü uzayı üzerinde elde edilen parametrik olasılık dağılımları ile başka bir doku bölgesi izlenip değerlendirilebilir. Böylece modellenen doku ile eşleşen ve eşleşmeyen dokular elde edilir (Hanbay, 2016).

3.2.3. İstatistiksel Yöntemler

İstatistiksel yaklaşımlar piksel değerlerinin uzamsal dağılımlarını ölçen yöntemlerdir. İstatistiksel yöntemler kumaş yüzeyinde farklı istatistiksel sonuçlar üreten bölgeleri tespit ederek bu bölgelerin hatalı olup olmadığını tespit etmeyi amaçlar. Bu yaklaşımlar bölgesel özellikleri tanımlayan piksel sayıları temel alınarak birinci, ikinci ve daha yüksek mertebeden istatistiksel yöntemler olarak sınıflandırılmıştır. Bu yaklaşıma ait en çok kullanılan yöntemler histogram temelli, eş oluşum matrisi, oto korelasyon fonksiyonu ve matematiksel morfoloji olarak dört başlık altında incelenebilir (Hanbay, 2016).

3.2.4. Makine Öğrenmesi Yöntemleri

Makine öğrenmesi yöntemleri son yıllarda popülerliğini arttıran yöntemlerden biri haline gelmiştir. *Denetimli öğrenme*, *denetimsiz öğrenme*, *yarı denetimli öğrenme* ve *takviyeli öğrenme* olarak dört gruba ayrılan makine öğrenmesi yöntemleri genel olarak kumaş yüzeyinde meydana gelen hataları tespit etmek amacıyla kullanılmaktadır. Denetimsiz öğrenmede bir denetmene ihtiyaç duyulmaksızın etiketsiz veriler incelenirken denetimli öğrenmede ise belirli etiketlere sahip veriler tercih edilmektedir. Yarı denetimli öğrenmede bazı veriler etiketli bazı


veriler ise etiketsiz olabilmektedir. SVM (Support Vector Machine) (Destek Vektör Makinaları) ve self-training yöntemleri örnek olarak verilebilir. Takviyeli öğrenmede ise önceden tanımlanmış bir veriye ihtiyaç duyulmaz. Çevre ile etkileşim sağlayarak takviyeli öğrenme gerçekleştirilebilmektedir. Takviyeli öğrenmede, davranışsal öğrenme süreci kullanılmaktadır. MDP (Markov Decision Process) (Markov Karar Süreci) ve Deep Mind örnek olarak verilebilmektedir (Deniz, 2023).

3.3. Kumaş Hataları Tespitinde Kullanılan Görüntü İşleme Yöntemleri

Tez çalışmasının yazılım aşamasında görüntü işleme, yapay zeka ve derin öğrenme yöntemlerinden bazıları kullanılmıştır. Buna göre görüntülerin istediğimiz formatta dönüşüm işlemlerinin hesap karmaşıklığını aza indirmek amacıyla tercih edilebileceği öngörülmektedir. Bu sebeple öncelikle görüntü kavramını iyi anlamak gereklidir.

3.3.1. Rgb Renk Uzayı

Aynı nesnenin **R** (kırmızı), **G** (Yeşil), **B** (Mavi) olarak kodlanmış üç gri ton görüntüsünün üst üste iletilmesiyle renkli bir görüntü oluşturulur (Ükte, 2023). Bu prensibi açıklayan bir Görsel Şekil 3.8’de verilmiştir.



Şekil 3.8. 3 bant görseli (Ükte, 2023).


Renkli görüntü kavramı şu şekilde de açıklanabilir: 1. bant kırmızı filtrelidir, yani orijinal görüntüdeki gri değerler kırmızının tonları olarak ifade edilmektedir. Benzer şekilde 2. ve 3. bantlar yeşil ve mavinin tonları olarak ifade edilir. Bu üç bant üst üste bindirilir ve oluşan renk karışımından doğal renkler elde edilir (Ükte, 2023). Doğal renkli bir görüntü ve bu görüntünün RGB bantlarının gri tonlamalı görüntüleri Şekil 3.9’da gösterilmiştir.



Şekil 3.9. RGB bantlarının gri tonlamalı görüntüleri (Ükte, 2023).

RGB anlamında doğal renklerden oluşan renkli bir görüntü için doğru bant kombinasyonu 1-2-3 şeklindedir. RGB gösteriminde bant kombinasyonları değiştirilirse renkler de değişir. Bu şekilde oluşturulan görüntülere yapay renkli görüntüler denir (Ükte, 2023). Yapay renkli görüntülerin bant kombinasyonlarına göre oluşturulan görseli Şekil 3.10'da verilmiştir.






Şekil 3.10. Yapay renkli görüntülerin kombinasyon görselleri (Ükte, 2023).

Bit derinliği (m) her bir gri-ton rengin kodlanacağı bit miktarını belirtmektedir. Bit derinliğinin 8 bit olması durumunda, renkli görüntülerin her bir pikseli bilgisayar ekranlarında 24 bit veri olarak görüntülenir. Her bir renk $m = 8$ bit ile kodlanacağı için üç renk $RGB = 3 \times 8 = 24$ bit ile kodlanacaktır. Bu durumda RGB görüntülerin her pikseli $G = 2^{24} = 16777216$ (yaklaşık 17 milyon) farklı renk değerine sahip olabilir. Bu üç rengin kombinasyonu için değer aralığı $RGB = (0,0,0), \dots, (255,255,255)$ biçiminde gösterilir (Ükte, 2023). Kırmızı yeşil ve mavi renklerin tam parlaklık değerleri Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Parlaklık değerleri çizelgesi (Ükte, 2023).

Parlaklık değerleri				Görünüm
	R	G	B	
Red	255	0	0	
Green	0	255	0	
Blue	0	0	255	

RGB gösteriminde $(0,0,0)$ siyahı, $(255,0,0)$ kırmızıyı, $(0,255,0)$ yeşili, $(0,0,255)$ maviyi ve $(255,255,255)$ beyazı temsil eder. Beyaz tüm renkleri içerir (Ükte, 2023). Matris olarak ele alındığında doğal renkli bir RGB görüntüsü, aşağıda Şekil 11’de gösterildiği gibi her biri $(M \times N)$ boyutlu üç matrisin (ızgaranın) birleşimidir. Matris gösteriminde $\{ I(i, j, k) \mid i = 1, 2, \dots, M; j = 1, 2, \dots, N; k = 1, 2, 3 \}$. Genel olarak bu matrislerin her biri pikselleri 256 gri seviyeden birine sahip gri tonlamalı bir görüntüyü temsil eder (Ükte, 2023). Üç ızgaranın görseli Şekil 3.11’de verilmiştir.



Şekil 3.11. Üç Izgaranın Birleşimi (Ükte, 2023).

3.3.2. Gri Tonlamalı Görüntü

Renkli sayısal bir görüntüyü gri tonlamalı bir görüntüye dönüştürme işlemi esas olarak RGB renk modelinde belirtilen her bir renk bandına karşılık gelen gri tonlamalı görüntülerin ağırlıklı ortalamasından başka bir şey değildir. Bu bağlamda, renkli görüntünün parlaklık değerleri korunarak gerçekleştirilen ölçekleme işlemi Denklem 2’de şu şekilde elde edilmektedir (Ükte, 2023).

$$I_{grayscale}(i, j) = 0.299I_{color}(i, j, 1) + 0.587I_{color}(i, j, 2) + 0.144I_{color}(i, j, 3) \quad (2)$$

3.3.3. Histogram Eşitleme

Histogram analizi genel anlamda histogram işleme görüntü işlemenin alt dallarından biridir. Bu çalışmada hataların tespiti noktasında kullanılacağı için aşağıdaki şekilde değinilmektedir.

R_k , $k = 0, 1, 2, \dots, L - 1$ için L seviyeli sayısal görüntü $f(x, y)$ ’nin piksel renk yoğunluk değerlerini gösterebilir. Burada f ’nin normalize edilmemiş histogramı aşağıdaki denklem 3’de tanımlanır.

$$H(R_k) = n_k ; k = 0, 1, 2, \dots, L - 1 \quad (3)$$

Burada n_k f görüntüsündeki R_k renk yoğunluğu değerlerine sahip piksel adedidir. Renk yoğunluk skalasındaki alt bölümlere histogram bölmeleri (histogram bins) denmektedir. f 'nin normalize edilmiş histogramı ise aşağıdaki denklem 4'de tanımlanır.

$$p(R_k) = \frac{H(R_k)}{MN} = \frac{n_k}{MN} \quad (4)$$

M ve N sırasıyla görüntüdeki satır ve sütun sayılarını belirtmektedir. Denklemden yer alan k 'nin tüm değerleri için $p(R_k)$ 'nin toplamı her zaman 1'dir. $p(R_k)$ fonksiyonunun değerleri, görüntüdeki renk yoğunluk değerlerine ait olasılıklar olarak düşünülebilir. Histogram manipülasyonu, görüntü işlemede sıklıkla kullanılan temel bir araçtır. Histogramların hesaplanması kolaydır ve hızlı donanım gerçekleştirmeleri için de uygundur. Bu sebeple histogram tabanlı teknikler, gerçek zamanlı görüntü işleme için popüler birer araç haline gelmiştir (Ükte, 2023). Kontrast germe işlemi uygulanmış bir görüntüde gri renk seviyelerinin dağılımı yeterli olmayabilir. Başka bir deyişle, görüntüdeki her bir gri seviyenin dinamik aralığa niceliksel dağılımı düzgün (uniform) olmayabilir. Bu dağılımın iyi dengelenmediği durumlarda görüntü genelinde kontrast düşük olur veya istenen bilgi görüntünün karanlık kısmında kalabilir. Bu sorunu çözmek için idealde her bir gri seviye değerine sahip piksel sayısı eşitlenmeye çalışılır. Böylece, gri seviyelerin piksellere dağılımı daha düzgün hale gelir. Birazdan yapılacak olan matematiksel çıkarımlara uygunluk açısından şimdilik görüntüdeki renk yoğunluk değerlerini belirten r değişkeninin ayrık değil sürekli olduğunu varsayalım. Bu durumda r 'nin $[0, L - 1]$ aralığında sürekli değerler aldığı ve $r = 0$ 'ın siyahı, $r = L - 1$ 'in ise beyazı temsil ettiği varsayılmıştır. Yukarıdaki koşulları sağlayan r değerleri için, giriş görüntüsündeki belirli bir r renk yoğunluğu değerine karşı gelen çıkış görüntüsü renk yoğunluğu değeri s 'yi üreten aşağıdaki yapıda dönüşümler (renk yoğunluğu eşlemeleri) denklem 5'de tanımlanmıştır.

$$s = T(r) ; 0 \leq r \leq L - 1 \quad (5)$$

$T(r)$ için aşağıdaki iki varsayım geçerlidir:

- a) $T(r)$, $0 \leq r \leq L - 1$ aralığında tekdüze artan bir fonksiyondur.
- b) $0 \leq r \leq L - 1$ için $0 \leq T(r) \leq L - 1$.


Bazı uygulamalarda aşağıda denklem 6'da tanımlanan ters dönüşüm kullanılabilir.

$$r = T^{-1}(s); 0 \leq s \leq L - 1 \quad (6)$$

Bu durumda a) varsayımının aşağıdaki şekilde güncellenmesi gerekir.

a) $T(r)$, $0 \leq r \leq L - 1$ aralığında kesin artan bir fonksiyondur.

a)'daki $T(r)$ 'nin tekdüze olarak artması koşulu, çıkış görüntüsündeki renk yoğunluğu değerlerinin, karşılık gelen giriş görüntüsündeki renk yoğunluğu değerlerinden asla daha az olamayacağını garanti eder ve böylece renk yoğunluğundaki azalmadan kaynaklanabilecek yapaylıklar önlenmiş olur. Ayrıca b) koşulu, çıkış ve giriş görüntülerindeki renk yoğunluğu aralıklarının aynı olmasını garanti eder. Son olarak a) koşulu, s 'den tekrar r 'ye geçiş durumundaki eşlemelerin bire bir olmasını garanti ederek renk yoğunluğu değerlerindeki olası belirsizlikleri önler. Koşullara göre gösterim Şekil 3.12'de verilmiştir.



Şekil 3.12. $T(r)$ koşullara göre grafikleri

- a) Birden fazla değer tek bir değerle nasıl eşleşebileceğini gösteren monoton artan fonksiyon
- b) Kesinlikle monoton artan fonksiyon bu her iki yönde de bire bir eşlemedir (Gonzales ve Woods, 2018).

Piksel gri seviye yoğunluk değeri, $[0, L - 1]$ aralığında değerler alabilen rastgele bir değişken olarak düşünülebilir. $p_r(r)$ ve $p_s(s)$, iki farklı görüntüdeki renk yoğunluk değerleri r ve s 'ye ait olasılık yoğunluk fonksiyonları (PDF)'ler olarak tanımlansın. Olasılık teorisinin temel bir sonucu olarak eğer giriş görüntüsüne ait renk yoğunluğu PDF'i $p_r(r)$ ve r 'den s 'ye dönüşüm fonksiyonu $T(r)$ biliniyorsa ve $T(r)$ fonksiyonu sürekliyse ve ilgilenilen değer aralığında türevlenebilirse, dönüştürülmüş (eşlenmiş) renk yoğunluğu s 'nin PDF'i aşağıdaki gibi denklem 7'de elde edilebilir.

$$p_s(s) = p_r(r) \left| \frac{dr}{ds} \right| \quad (7)$$

Bu durumda çıkış görüntüsüne ait renk yoğunluğu değişkeni s 'nin PDF'i giriş görüntüsüne ait renk yoğunluğu değişkeni r 'nin PDF'i dönüşüm fonksiyonu kullanılarak belirlenmektedir. Hatırlatma anlamında belirtmek gerekirse r ve s birbirine $T(r)$ fonksiyonu ile bağlıdır. Görüntü işleme için özel bir öneme sahip dönüşüm fonksiyonu aşağıda denklem 8'de tanımlanmıştır.

$$s = T(r) = (L - 1) \int_0^r p_r(w) dw \quad (8)$$

Eşitliğin sağ tarafındaki integral r rastgele değişkeninin kümülatif dağılım fonksiyonudur (CDF). PDF'ler her zaman pozitif değerler alan fonksiyonlar olduğu için ve bir fonksiyonun integrali fonksiyon altında kalan alan olarak tanımlandığı için, (8) eşitliğindeki dönüşüm fonksiyonu a) koşulunu sağlar. Bunun nedeni r değeri arttıkça fonksiyon altında kalan alan miktarının azalamayacağı gerçeğidir. Eşitlikteki integralin üst sınırı $r = L - 1$ olduğunda integral bire eşit olacaktır. Çünkü PDF en fazla 1 olabilir. Sonuç olarak s 'nin en yüksek değeri $L - 1$ 'dir ve bu durumda b) koşulu da sağlanmış olur. Denklem 7'deki $\frac{dr}{ds}$ teriminde s yerine denklem 8'deki $s = T(r)$ eşitliği yazıldığında ortaya çıkan eşitlik denklem 9'da verilmiştir.

$$\begin{aligned} \frac{ds}{dr} &= \frac{dT(r)}{dr} \\ &= (L - 1) \frac{d}{dr} \left[\int_0^r p_r(w) dw \right] \\ &= (L - 1) p_r(r) \end{aligned} \quad (9)$$

$\frac{dr}{ds}$ değeri denklem (7) da yerine konulduğunda oluşan eşitlik denklem 10'da verilmiştir.

$$\begin{aligned} p_s(s) &= p_r(r) \left| \frac{dr}{ds} \right| \\ &= p_r(r) \left| \frac{1}{(L-1)p_r(r)} \right| \\ &= \frac{1}{L-1} \quad 0 \leq s \leq L - 1 \end{aligned} \quad (10)$$

Görüldüğü gibi $p_s(s)$ olasılık yoğunluk fonksiyonu düzgün dağılımlıdır. Yani (7) eşitliğindeki renk yoğunluğu dönüşüm fonksiyonunun uygulanması sonrasında, düzgün dağılımlı PDF'e sahip bir s rastgele değişkeni elde edilmiştir. Burada önemli olan nokta, $p_s(s)$ 'nin, $p_r(r)$ 'nin dağılım yapısından bağımsız bir şekilde her zaman düzgün dağılıma sahip olmasıdır. Bilindiği gibi ayrık rastgele değişkenlerde olasılık yoğunluk fonksiyonu yerine olasılık dağılım fonksiyonu vardır. Ayrıca sürekli değişkenlerdeki integral operatörü yerine ayrık değişkenlerde toplam operatörü vardır. (8) eşitliğindeki dönüşümün ayrık karşılığı aşağıda denklem 11'de verilmiştir.

$$s_k = T(r_k) = (L - 1) \sum_{j=0}^k p_r(r_j) ; k = 0, 1, 2, \dots, L - 1 \quad (11)$$

Burada L daha önce olduğu gibi görüntüdeki olası tüm renk yoğunluğu seviyelerinin sayısını belirtmektedir. Örneğin 8 bit görüntü için bu sayı 256'dır. Sonuç olarak, giriş görüntüsündeki r_k yoğunluk değerine sahip her piksel, eşitlik (10) kullanılarak, çıkış görüntüsündeki s_k yoğunluk değerine sahip karşı gelen piksele eşlenerek işlenmiş çıkış görüntüsü elde edilir. Bu işleme histogram eşitleme veya histogram doğrusallaştırma dönüşümü adı verilmektedir (Ükte, 2023).

3.3.4. Difference of Offset Gaussian (DOOG)

DOOG kenar algılama tekniklerinden biri olup iki farklı standart sapması olan Gauss filtresinin farkından oluşmaktadır. Buradaki kullanım amacı görüntüde yer alan kenar ve köşelerin daha belirgin bir biçimde tespit edilmesidir (Lindeberg, 1998). DOOG fonksiyonu, denklem 12'de verildiği gibi, farklı standart sapmalardan oluşan iki Gauss fonksiyonunun farkı olacak biçimde verilir.

$$DOOG(x, y) = G(x, y, \sigma_1) - G(x, y, \sigma_2) \quad (12)$$

Burada $G(x, y, \sigma)$ standart sapması σ olan Gauss fonksiyonunu temsil eder. x ve y görüntünün yatay ve dikey koordinatlarıdır. σ_1 ve σ_2 Gauss fonksiyonlarının standart sapmalarıdır. İki boyutlu bir Gauss fonksiyonunun örneği denklem 13'te verilmiştir.

$$G(x, y, \sigma) = Ae^{-\left[\frac{(x-x_0)^2}{2\sigma_x^2} + \frac{(y-y_0)^2}{2\sigma_y^2}\right]} \quad (13)$$

Burada A genlik değerini temsil eder. x_0 ve y_0 merkezdir. σ_x ve σ_y yatay ve dikey yayılmalardır.

3.3.5. Morfolojik İşlemler


A ve $B \subseteq Z^d$, $d > 0$ içinde kümeler olsun. B_x , B 'nin x 'e göre ötelenmesini ve $\hat{B}$, B 'nin orijine göre yansımısını gösterebilir. A 'nın B tarafından aşındırılması (İng.: erode işlemi) $A \ominus B$ şöyle tanımlanmaktadır (Rodriguez ve Ayala, 2001).

$$A \ominus B = \{x | (B_x \subseteq A)\} \quad (14)$$

Başka bir deyişle A 'nın B tarafından aşındırılması, x tarafından ötelenen B 'nin A 'da içerildiği tüm x noktalarının kümesidir. A 'nın B tarafından genişletilmesi (İng.: dilate işlemi) $A \oplus B$, şöyle tanımlanmaktadır (Rodriguez ve Ayala, 2001).

$$A \oplus B = \{x | (\hat{B})_x \cap A \neq \emptyset\} \quad (15)$$


Böylece A 'nın B tarafından genişletilmesi, $\hat{B}$ ve A 'nın sıfır olmayan en az bir elemanı örtüştüğü şekilde $\hat{B}$ 'nin orijininin tüm x yer değiştirmelerinin kümesidir. B kümesi genellikle erozyon, dilatasyon ve diğer morfolojik işlemlerde yapılandırma elemanı olarak adlandırılır (Rodriguez ve Ayala, 2001). Morfolojik işlemler görüntü işleme yöntemlerinde en sık kullanılan operatörlerden biridir. Bu çalışmada erozyon işlemi, tanımlı bir alan üzerindeki gürültüyü azaltmak ve detayı ortaya çıkarmak için kullanılmıştır. Morfolojik yöntemlerin bu çalışmadaki filtrelenmiş gri ölçekli bir kumaş hatası görüntüsü üzerindeki sonuçları Şekil 3.13'te verilmiştir.



Şekil 3.13. Çalışılan kumaş hatalarından birine ilişkin orijinal görüntü (Sol üst), aşındırılmış görüntü (sol orta), genişletilmiş görüntü (sol alt), orijinal görüntü histogramı (sağ üst), aşındırılmış görüntü histogramı (sağ orta) ve genişletilmiş görüntü histogramı (sağ alt).

Gözle görüleceği üzere giriş görüntüsü kullanıcı isteğine göre parametrelerin ayarlanması sonucunda daha işlevsel bir hale gelmektedir. Dilation (yayma) operatörü giriş görüntüsü üzerinde verilen alan için sınırları genişletmeye yaramaktadır. Yapısal element olarak kullanıcı isteğine göre ayarlanan parametrelere göre yayma işleminin sınırları değişkenlik

gösterebilmektedir. Yine Şekil 3.13'deki çalışılan kumaş hatasına ilişkin dilate işlemi sonucu Şekil 3.14'te verilmiştir.



Şekil 3.14. Orijinal görüntü (sol) - dilate (yayma - genişletme) işlemi sonucunda oluşan görsel (sağ).


3.4. Yapay Sinir Ağları

Yapay zeka (AI) bilgisayarların insan zekasını taklit etmesini sağlayan bir tekniktir. Makine öğrenmesi içerir. Makine öğrenmesi ve derin öğrenme teknikleri kullanılarak genellikle insan zekasıyla ilişkili görevleri yerine getiren bilgisayar sistemleri ve uygulamalar oluşturulabilir. Bu görevlerden bazıları görüntü tanıma, konuşma tanıma ve dil çevirisini içerir. Çizelge 3.2'de iki teknik ayrıntılı olarak karşılaştırılmıştır.

Çizelge 3.2 Makine öğrenmesi – Derin Öğrenme Çizelgesi.

	Makine Öğrenmesi	Derin Öğrenme
Veri Noktası Sayısı	Tahminde bulunmak için az miktarda veri kullanılabilir.	Tahminde bulunmak için büyük miktarda eğitim verisinin kullanılması gerekir.
Donanım Bağımlılıkları	Düşük özellikli makinelerde çalışabilir. Çok fazla hesaplama gücüne ihtiyaç yoktur.	Yüksek özellikli makinelere bağlıdır. Hesap karmaşıklığı fazladır. GPU bu işlemleri verimli bir şekilde iyileştirebilir. Hesap karmaşıklığını azaltabilir.
Özellik Geliştirme İşlemi	Özelliklerin kullanıcılar tarafından doğru bir biçimde tanımlanması ve oluşturulması gereklidir.	Verilen üst düzey özellikleri öğrenir ve tek başına yeni özellikler oluşturur.
Öğrenme Yaklaşımı	Öğrenme sürecini daha küçük adımlara ayırır. Ardından her adımdaki sonuçları tek bir çıkışta birleştirir.	Sorunu uçtan uca çözerek öğrenme sürecinde ilerler.
Yürütme Süresi	Kısa eğitim süresi	Uzun eğitim süresi
Çıkış	Çıkış genellikle puan veya sınıflandırma gibidir fakat sayısal bir değerdir.	Çıkışın metin, puan, ses veya görüntü gibi birden çok biçimi olabilir. Bu derin öğrenme tekniği ile oluşturulan sonuç üretken yapay zeka modellerinin bir özelliğidir.

Derin öğrenme, yapay sinir ağları ve insan beyninin işlevlerini taklit eden hesaplama sistemleri kavramına dayanır. Derin öğrenmenin tarihi, Warren McCulloch ve Walter Pitts'in 1943 yılında düşünce sürecini taklit etmek için matematiğe ve sinir mantığı olarak adlandırılan algoritmalara dayalı sinir ağları için bir hesaplama modeli oluşturmalarına uzanmaktadır. Derin öğrenme bir makine öğrenmesi türüdür. Ayrıca yapay sinir ağlarındaki mimariler Şekil 3.15'de gösterilmektedir.



Şekil 3.15. Yapay Sinir Ağı Mimarileri (Van Veen, 2019).


Şekil 3.15’de farklı özelliklere sahip yapay sinir ağı mimarileri yer almaktadır. Sarı renkli hücreler giriş katmanlarını, yeşil renkteki hücreler gizli katmanları, kırmızı renkteki hücreler çıkış katmanlarını ve mor renkteki hücreler de konvolüsyon veya havuzlama katmanlarını göstermektedir.

3.5. Evrişimli Sinir Ağları

Bu tez çalışması kapsamında derin öğrenme yöntemlerinden evrişimsel sinir ağı (CNN) (Convolutional Neural Network) yönteminin kullanılması tercih edilmiştir. Görüntüdeki çeşitli obje veya nesneleri birbirinden ayırtırmamıza yardımcı olan derin öğrenme algoritmasıdır.

İleri yönlü bir sinir ağı olan CNN, hayvanların görme merkezinden esinlenilerek ortaya çıkmıştır. Evrişimsel işlemler, bir nöronun kendi uyarı alanından uyarılara verdiği cevap olarak düşünülebilir (Dettmers, 2015). Basit olarak ifade etmemiz gerekirse evrişim olayı matematik, fizik veya mühendislik uygulamalarında karmaşık işlemleri basitleştirmek için kullanılan matematiksel işlemlerdir. Çalışmaların başında görüntü ve ses işleme, doğal dil işleme ve biyomedikal gibi alanlarda kullanılmıştır fakat en iyi sonuçları görüntü işleme alanında vermiştir.

Evrişimsel Sinir Ağları, bir veya daha fazla konvolüsyonel katmanlardan, altörnekleme katmanından ve standart çok katmanlı bir sinir ağı gibi bir veya daha fazla bağlı katmanlardan oluşur. CNN'lerin avantajı, aynı miktarda gizli birimle tamamen bağlı ağlardan daha az sayıda eğitime ve daha az parametreye gerek duymalarıdır. Konuyu daha iyi kavramak amacıyla bir konvolüsyonel katmanındaki girdi olarak, $a \times b \times c$ 'lik bir resim düşünülebilir. Burada a ve b değerleri sırasıyla görüntünün yüksekliği ve genişliği, c ise kanalların sayısıdır. Konvolüsyonel katmanı ise $d \times e \times f$ boyutlarında x adet filtreden oluşur. Filtre için görüntünün boyutundan daha küçük olan d ve e , ve c (kanal) değeriyle genellikle aynı seçilen f değeri seçilir. Bu filtreler ile, her biri $a - d + 1$, $b - e + 1$ boyutunda k adet birbirine yerel olarak bağlı özellik haritaları üretir. Sonrasında her harita için, Şekil 3.16'da verilen örnek gibi, maksimum veya ortalama havuzlama ile $y \times y$ 'lik altörnekleme işlemi uygulanır (Gürbüz, 2023).




Şekil 3.16. Havuzlama İşlemi (Gürbüz, 2023).

İki boyutlu olan evrişimlerde birden fazla aşama vardır. Bu aşamalar şu şekilde sıralanır;

➔ Kenar Bulma (Edge Finding)

- ➔ Piksel Ekleme (Padding)
- ➔ Kaydırma (Stride)
- ➔ Havuzlama (Pooling)

Şekil 3.17’de bu aşamaların bulunduğu görsel verilmiştir.



Şekil 3.17. Cnn aşamaları (Gürbüz, 2023).

Şimdi CNN yapısını daha iyi anlayabilmek için Şekil 3.17’de yer alan konvolüsyon katmanı ile başlayalım. Anlatımı basitleştirmek adına tek kanallı bir sistem ele alınmıştır ($c = f = 1$). Giriş olarak örnek bir $(a \times b) = (4 \times 4)$ ’lük bir A matrisi ele alındığında $(d \times e) = 2 \times 2$ ’lik örnek bir B filtresinden geçirilirse yukarıdaki bilgilerden de anlaşılacağı üzere $(a - d + 1 \times b - e + 1) = (3 \times 3)$ boyutlarında öznitelik veya özellik matrisi veya özellik haritası C oluşacaktır. Örnek bir öznitelik matrisi oluşumu denklem 14’te verilmiştir.

$$A = \begin{bmatrix} 1 & 3 & 2 & 0 \\ 2 & 1 & 2 & 4 \\ 5 & 3 & 7 & 1 \\ 4 & 2 & 6 & 1 \end{bmatrix}, \quad B = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \quad A * B = C, \quad C = \begin{pmatrix} C_{11} & C_{12} & C_{13} \\ C_{21} & C_{22} & C_{23} \\ C_{31} & C_{32} & C_{33} \end{pmatrix} \quad (14a)$$

$$\begin{aligned} C_{11} &= (1 \times 1) + (3 \times 0) + (2 \times 0) + (1 \times 1) = 2 \\ C_{12} &= (3 \times 1) + (2 \times 0) + (1 \times 0) + (2 \times 1) = 5 \\ C_{13} &= (2 \times 1) + (0 \times 0) + (2 \times 0) + (4 \times 1) = 6 \\ C_{21} &= (2 \times 1) + (1 \times 0) + (5 \times 0) + (3 \times 1) = 5 \\ C_{22} &= (1 \times 1) + (2 \times 0) + (3 \times 0) + (7 \times 1) = 8 \\ C_{23} &= (2 \times 1) + (4 \times 0) + (7 \times 0) + (1 \times 1) = 3 \\ C_{31} &= (5 \times 1) + (3 \times 0) + (4 \times 0) + (2 \times 1) = 7 \\ C_{32} &= (3 \times 1) + (7 \times 0) + (2 \times 0) + (6 \times 1) = 9 \end{aligned} \quad (14b)$$

$$C_{33} = (7 \times 1) + (1 \times 0) + (6 \times 0) + (1 \times 1) = 8$$

$$C = \begin{pmatrix} C_{11} & C_{12} & C_{13} \\ C_{21} & C_{22} & C_{23} \\ C_{31} & C_{32} & C_{33} \end{pmatrix} = \begin{pmatrix} 2 & 5 & 6 \\ 5 & 8 & 3 \\ 7 & 9 & 8 \end{pmatrix} \quad (14c)$$

C matrisi öznitelik matrisi olup bu örnek için tek bantta 3×3 boyutlarında elde edilmiştir. Bu aşamadan sonra genellikle doğrusal olmayan katman gelmektedir. Aktivasyon katmanı olarak da adlandırılan bu katmanda geçmişte sigmoid ve tanh gibi doğrusal olmayan fonksiyonlar kullanılırdı fakat sinir ağı eğitmekte hız parametresi göz önüne alındığında en iyi sonucu verdiği için ReLu fonksiyonu daha çok tercih edilmeye başlamıştır. (Lin ve Shen, 2018). ReLu eşitliği denklem 15'te verilmiştir.

$$f(x) = \max(0, x) \quad (15)$$

Gelen giriş değeri 0'dan büyükse geldiği gibi aynı değeriyle çıkış olarak verilir. Eğer giriş değeri 0'dan küçük eşit ise direkt 0 olarak çıkar. Bir diğer aktivasyon fonksiyonu olan softmax fonksiyonu genellikle çoklu sınıflandırma problemlerinde tercih edilir ve denklem 16'da verilmiştir.

$$\sigma_i(\vec{z}) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (16)$$

Burada z , z_i , $i = 1, \dots, K$ gerçekte değerlerine sahip keyfi bir vektördür. K CNN'nin boyutudur (Kouretas ve Paliouras, 2019). Çıktı vektörü $\sigma_i(\vec{z})$ her bir sınıfın olasılık değerini tutar. Bütün değerlerin toplamı 1'dir. Örneğin 0'dan 9'a kadar olan sayıların resimlerini giriş olarak YSA modeli için verirken çıkışta 1×10 boyutunda bir vektör elde ederiz ve bu çıkış vektörünün kendi içindeki elemanları toplamı 1'e eşittir. Şekil 4.18'deki bir sonraki aşama ise flatten aşamasıdır. Konvolüsyon katmanı ve havuzlama katmanından sonra gelen flatten yani düzleştirme katmanı adından da anlaşılacağı üzere matrisi sütun vektörüne dönüştürme işlemi uygular. Örnek bir C matrisinin flatten işlemi sonrasındaki durumu denklem 17'de verilmiştir.

$$C = \begin{pmatrix} 2 & 5 & 6 \\ 5 & 8 & 3 \\ 7 & 9 & 8 \end{pmatrix} \xrightarrow{flatten} \begin{bmatrix} 2 \\ 5 \\ 6 \\ 5 \\ 8 \\ 3 \\ 7 \\ 9 \\ 8 \end{bmatrix} \quad (17)$$

Bu aşamadan sonra artık tam bağlantı katmanının girişleri hazır hale gelmektedir. Kullanıcının isteğine göre konvolüsyon katmanları, aktivasyon katmanları ve havuzlama katmanları arttırılıp azaltılabilmektedir. Bu tez çalışmasında kullanılan aktivasyon fonksiyonları Relu ve softmax'dir. Tez çalışmasında kullanılan CNN mimarisi sözdekod (pseudocode) biçiminde Bölüm 5'de verilmiştir.

Yeni ve gündemde olan generative AI (üretken yapay zeka) son yıllarda popülerliğini artıran bir yapay zeka yöntemidir. Bu sebeple kullanıcılar tarafından tercih edilmektedir. Bu tez çalışmasında kullanılmamıştır.

4. BULGULAR

Tez çalışması özelinde bulgular bölümünde tasarlanan sistemde kumaş kalite kontrol makinesi, sigma profiller, bilgisayar, kameralar, kamera lensleri, haberleşme ekipmanları ve aydınlatma ekipmanı bulunmaktadır. Buradaki temel amaç tez çalışmasının başarıya ulaşması için teknik hesaplamalar ile oluşturulan prototip sistemin kumaş hatalarını yüksek doğrulukta tespit etme ve sınıflandırması işlemlerini yüksek başarımlı değerleriyle gerçekleştirebilmesidir.

4.1. Veri Setinin Oluşturulması

Denizli ili organize sanayi bölgesi içinde yer alan EVSA tekstil işletmesinde tez çalışması için kurulan prototip sistem üzerinden veri seti oluşturulmaktadır. Kalite kontrol makinesi üzerine sabitlenen sigma profillerin altına üç boyutlu yazıcı kullanılarak basılan kamera kapakları virgül somun civata bağlantısı ile montajlanmıştır. Kamera kapaklarının içinde belirli ölçümler ve hesaplamalar neticesinde önceden karar verilmiş olan kameralar (2 adet) yerleştirilmiştir. Kalite kontrol makinesi besleme hattına tez çalışmasında kullanılmak üzere ham bez yerleştirilmiştir. Kameralar bez üzerinde gerçek zamanlı görüntü alarak çalışmanın veri setinin hazırlanması işlemini gerçekleştirmektedir. İşletmenin kalite kontrol bölümüne ait görseller Şekil 4.1’de verilmiştir.



Şekil 4.1. Kalite kontrol bölümünde kontrolü gerçekleştirilecek olan kumaşlar.

İlgili firma işletme görseli Şekil 4.2’de verilmiştir.



Şekil 4.2. İşletme görseli.

Kalite kontrol makinesi ön kısmı Şekil 4.3’de verilmiştir.



Şekil 4.3. Kalite kontrol makinesi görseli ön kısım.

Kırmızı daireler içinde yer alan ekipmanlar tez çalışmasının ekipmanlarıdır ve şunları içermektedir: Sigma profiller üzerine montajı gerçekleştirilen 2 adet alan tarama kamerası, kumaş inceleme bölgesi üzerindeki tekerlekli enkoder, sol tarafta masa üzerinde yer alan dizüstü bilgisayar, kamera kabloları, kamera lensleri ve diğer mekanik malzemeler. Kalite kontrol makinesi arka kısmı, firma kalite kontrol operatörünün makine üzerinde çalışırken çekilen görseli ve kalite kontrol makinesi sol kısmı Şekil 4.4 ve Şekil 4.5 ve Şekil 4.6 da verilmiştir.



Şekil 4.4. Kalite kontrol makinesi görseli arka kısım.




Şekil 4.5. Firma kalite kontrol uzman operatörü.



Şekil 4.6. Kalite kontrol makinesi sol kısım.

4.1.1. Kamera Seçimlerinin Yapılması

Kumaş üzerinde yer alan ayrıntıları tespit etmenin en önemli yollarından biri de iyi bir kamera seçimi gerçekleştirmektir. Sonuçta bu hataları tespit edebilmek için düzenli çalışacak ve işletme koşullarında sorun çıkarmayacak kamera gruplarına ihtiyaç duyulmaktadır. O halde işletmenin belirli parametrelerinden etkilenmeyecek ve gereken hassasiyetle çalışabilecek kameralara gereksinim oluşmaktadır. Kamera seçimlerinin sağlıklı bir biçimde yapılmasını sağlayan hususlardan biri de kullanıcıların ne kadarlık bir çalışma alanında hangi açıyla çalışacaklarına karar vermeleri gereksinimidir. Bu çalışma kapsamında 2 adet kamera kullanmamızın sebebi görmek istediğimiz sahnedeki en boy değerlerinin maksimum çözünürlükte görüntülenebilmesini sağlama ihtiyacından kaynaklanmaktadır. Sahne seçimi için kamera tedarikinden önce yapılan ölçümler ve açı değerleri Şekil 4.7’de verilmiştir.



Şekil 4.7. Sahnenin genişlik ve yükseklik değerlerine göre seçilen kamera geometrisi.

Piyasada farklı özelliklerde kullanıma açık birçok kamera mevcuttur. Burada çalışmacı kendi çalışmasına uygun bir biçimde ne istediğini bilerek bu seçimi gerçekleştirmelidir. Aksi halde çalışmanın ilerleyen bölümlerinde malzemenin yanlış seçilmesi durumu telafisi çok zor olacak sonuçlar doğurmaktadır. Herhangi bir sıkıntıyla karşılaşmamak ve çalışmanın her aşamasında iyi sonuçlar elde etmek için bu tez çalışmasında seçimi gerçekleştirilen kamera ve özellikleri Çizelge 4.1’de verilmiştir.


Çizelge 4.1 Seçilen kamera özellikleri.

Kamera Adı / Modeli:	Basler 107821 a2A1920
Kamera Çözünürlüğü: (Resolution):	2.3 MP
Kamera FPS Değeri:	160 fps
Kamera Renkli / Renksiz: (Mono/Color):	Color
Kamera Haberleşme Tipi:	USB 3.0
Kamera Rolling/Global Shutter:	Global Shutter
Kamera Sensör Tipi:	CMOS
Kamera Tarama Tipi: (Area Scan / Line Scan):	Area Scan

4.1.2. Aydınlatma Cihazlarının Ayarlanması

Tasarlanan prototip sistem üzerinde yer alan kumaş kalite kontrol makinesi içindeki aydınlatma ekipmanlarının düzenli ışık vermesi, çekim yapacak olan kameraların aynı ışık miktarı altında pozlama yapmasını sağlamaktadır. Işık miktarı değişken olursa pozlama süresi sabit olsa bile kameralar değişken ışıktan dolayı oluşan gürültüden etkilenirler ve iyi bir kare

yakalayamazlar. Çalışmanın hata tespit safhasında kumaş hatalarının net ve sıkıntısız bir biçimde tespit edilebilmesi için aydınlatma koşullarının önceden ayarlanmış ve sabit olması gerekmektedir. Bu yüzden alt ışık dediğimiz led ışık, kumaş kalite kontrol makinesi içine monte edilmiştir. Düzenli gelen ışık, ortamdaki diğer ışıklardan gelen bozucu etkileri en aza indirmektedir. Belirli bir alana odaklanan kameralar bu alandaki görüntülerle ilgilenmekte ve diğer bozulması muhtemel alanlara yani gürültülü alanlara odaklanmamaktadır. Böylece aydınlatma kaynaklı bozulmaların önüne geçilmiş olmaktadır. Sadece üst ışığın yer aldığı kumaş kalite kontrol makinesi Şekil 4.8’de verilmiştir.



Şekil 4.8. Üst ışık etkisindeki kalite kontrol makinesi.

4.1.3. Metre Sayacı ve Okuyucu Cihazlarının Entegrasyonu

EMKO marka endüstriyel metre sayaç cihazı, tekerlekli enkoderden gelen verileri display ekranında göstermek ve gelen metre verilerini RS 232-USB bağlantısı ile bilgisayara bağlanarak okumak için bu çalışmada kullanılmıştır.

4.1.4. Kumaş Kalite Kontrol Makinesi Üzerine Mekanik Aksamın Entegrasyonu

Kumaş kalite kontrol makinesi yalın haliyle değerlendirildiğinde üzerinde yer alan havlu, bez vb. ürünlerin operatör tarafından göz ile muayenesine tabi tutulmaktadır. Bu kontrol işlemi hemen hemen her tekstil işletmesinde yapılmaktadır. Otomatik tespit ve sınıflandırma işlemlerinin gerçekleştirilmesi için kamera, bilgisayar gibi ekipmanlara ihtiyaç duyulacağından özellikle kameraların kalite kontrol makinesi üzerine belirli açılarda ve belirli uzaklıklarda konumlandırılması gerekmektedir. İşte bu konumlandırmayı yapabilmek adına bu tez çalışmasında kumaş kalite kontrol makinesi üzerine sigma profillerin montajı gerçekleştirilmiştir. Kullanılacak olan kumaş kalite kontrol makinesinin ölçüleri alınıp o ölçülere uygun biçimde sigma profiller temin edilmiş ve somun-civata bağlantısı ile kalite kontrol makinesi üzerine monte edilmiştir. Sistemin montajlı halinin yan profilden görüntüsü Şekil 4.9’da verilmiştir.



Şekil 4.9. Sigma profillerin kalite kontrol makinesi üzerindeki montajı (yan profilden görünüş ve tezgaha montaj edilmesi).


4.1.5. Bilgisayar ve Haberleşme Kablolarının Entegrasyonu

Çalışmada kullanılan bilgisayar, Monster marka diz üstü bilgisayardır. Windows 11 işletim sistemine sahiptir. Intel Core i5-11400H işlemcisine sahiptir. 16 GB RAM bellek

mevcuttur. 500 GB SSD disk vardır. Bu çalışmada işlemci olarak bu bilgisayar kullanılmıştır. Kameradan gelen USB 3.0 haberleşme kabloları bilgisayarın mevcuttaki bağlantı noktalarına erişerek bilgisayar – kamera iletişimi sağlanmıştır. 5 metre uzunluğunda haberleşme kabloları kullanılmıştır.

4.2. Kumaş Hata Tespiti ve Sınıflandırılmasının İş Akış Diyagramı

Dokuma kumaşlarda oluşan hataların tespit edilmesi ve sınıflandırılması için bu tez çalışmasında öncelikle aşağıdaki şekilde bir iş akış diyagramı hazırlanmıştır. Bu akış diyagramında yer alan her adım yazılımsal olarak kodlanmıştır. İlgili diyagram Şekil 4.10'da verilmiştir.



Şekil 4.10. İş akış diyagramı (İşlem adımı numara karşılıkları aşağıda sözdekod'da verilmiştir BKZ Şekil 5.10).

Şekil 4.10'da verilen iş akış diyagramının ilk işlem adımı gerçek zamanlı görüntü yakalama adımıdır. Bu adımdan sonra gerçek zamanlı yakalanan üç banttaki görüntüler tek

banda gri ölçekli görüntülere dönüştürülür. İkinci işlem adımında elde edilen gri ölçekli görüntülere üçüncü işlem adımında DOOG filtresi uygulanır. DOOG filtresi uygulanan görüntüler istenilen genişlik ve yükseklikte dördüncü işlem adımında kırpılır. Kırpılan görüntülere histogram eşitleme işlemi beşinci işlem adımında uygulanır. Bu adımda ayrıca kullanıcı isteğine göre belirlenen değerde eşikleme işlemi uygulanır. Morfolojik işlemler eşikleme sonrasında altıncı işlem adımında uygulanır ve sonrasında hatalı alanlar yeşil ve kırmızı dikdörtgenler içine alınır. Böylece görüntü işleme kısmının işlem adımları tamamlanmış olur.

Hatalı kumaşlar tarih bilgisiyle bilgisayara kaydedilir ve derin öğrenme için zemin hazırlanmış olur. İstenilen hata sınıflarına göre hatalı kumaş fotoğrafları klasörlenir ve CNN algoritmasına sokulur. %70 oranında hatalı kumaşlar eğitim aşaması için seçilir. %15 oranında doğrulama aşaması için ve %15 oranında da test aşaması için seçilir. Eğitim performansı tamamlanmış olan CNN test verilerinin ilgili çıkışlara göre sınıflandırmasını tamamlar ve böylece derin öğrenme kısmının işlem adımları da tamamlanmış olur.

4.3. Kumaş Hata Tespiti ve Sınıflandırılmasının Yazılımı

Kumaş hata tespiti yazılımı için iki farklı yazılım dili ve iki farklı program kullanılmıştır. Bunlardan ilki Python, ikincisi ise C++ programıdır. Bir üst bölümde yer alan iş akış diyagramına göre kodlamalar gerçekleştirilmiştir. Python programında ilk olarak Spyder derleyicisinde *import* komutu ile programda gerekli olabilecek kütüphaneler eklenmiştir. Bunlar sırasıyla *sys*, *tkinter*, *pypylon*, *cv2* ve *numpy* kütüphaneleridir. Bir sonraki işlem adımı *tkinter* kütüphanesi ile arayüz oluşturmak ve bu arayüz içine kumaş hata tespit komutlarını yerleştirmektir. Burada, kullanılmak istenen arayüz ekranının başlığı, pencere boyutu, ölçüleri ve arkaplan rengi ayarlanmıştır. Detaylı bilgiler 5. Bölümde yer alan sistem arayüzü başlığı altında anlatılmaktadır. Arayüz konfigürasyonu bittikten sonra kumaş hata tespiti algoritmaları arayüz üzerindeki buton yardımıyla aktif hale getirilmiştir. Bu algoritmalar iş akış diyagramında da anlatıldığı gibi sırasıyla önce görüntüyü okumak veya yakalamak için sisteme bağlı kameraları aktif hale getirmektedir. Sonra yakalanan görüntüler gri tonlamalı tek bant görüntüye dönüştürülür. Sonra bu gri tonlamalı görüntü üzerine DOOG filtresi uygulanır. Bunun sebebi görüntü üzerindeki detayların daha belirgin hale getirilmek istenmesidir. Sonraki işlem adımı ise görüntüyü kırpmaktır. İstenen ölçülerde sol üst noktadan başlanıp görüntü kırpma işlemi uygulanır. Bir sonraki işlem adımı histogram işlemidir. Histogramı hesaplanan görüntü el ile değiştirilebilen eşik değeri ile hata tespiti için hazırlanır. Kullanıcının bu eşik

değerini görmek istediği sonuca göre belirlemesinden sonra, Bölüm 3.2’de incelenen *aşındırma ve yayma* (İng.: *Erode* ve *Dilate*) işlemlerine geçilir. Morfolojik operasyonlardan sonra görüntü üzerinde cv2 komutları kullanılarak hatalı bölgeler dikdörtgen içine alınmaktadır. Hatalı olan görüntüler bilgisayara o günün tarihi alınarak gün ay yıl biçiminde bir klasör içinde kaydedilir. Böylece hata tespit sisteminin ilk aşaması tamamlanmış olur.

Sistemin ikinci aşaması olan sınıflandırma için kaydedilmiş görüntüler evrişimli sinir ağları algoritmasına giriş olarak verilmektedir. Bu hatalı görüntüler istenilen çıkış sayısına göre önceden etiketlenmiş çıkış sınıflarına göre önce eğitim aşamasından geçmektedir. Daha sonra test aşamasında hata tiplerine göre örneğin atkı hatası, çözgü hatası, kırış hatası, yabancı iplik ve tahar hatası gibi etiketler ile görüntüler sınıflandırılmış olmaktadır. Böylece dokuma kumaşlarda tespit ve sınıflandırma işlemi gerçekleştirilmiş ve işlem adımları tamamlanmıştır.





5. TARTIŞMA

Bu bölümde gerçek zamanlı kumaş hata görüntülerinin tespiti, tasarlanan sistemin arayüzü ve kumaş hata sınıflandırma başarımları anlatılmaktadır. Şekil 4.10'da verildiği gibi, yapılan işlem iki bölümden oluşmaktadır:

1) Hata tespiti (yeşil ve kırmızı kutulara alma işlemi) görüntü alan filtresi, DOOG filtresi, histogram eşitleme sonucunda elde edilen görüntünün eşik değeri ve morfolojik işlemler içeren görüntü işleme yöntemleriyle belirlenen hatalı görüntüler veriseti olarak kaydedilir.

2) Tespit edilen bu hataların türü tasarlanan CNN ile sınıflandırılır.

Görüntü işleme ile kumaş hatası tespit kısmının sözde kodu Şekil 5.1'de verilmiştir. Kumaş hata türlerinin sınıflandırılmasına yönelik tasarlanan CNN sözde kodu Şekil 5.2'de verilmiştir. Kumaş hatalarının tespit edilmesi ve sınıflandırılması için tekstil firmasında sistemin montajı gerçekleştirilmiştir. Kumaş hataları tespit edilmiş daha sonra tespit edilen hatalara yönelik işletme çalışanı operatör ile doğrulama yapılmıştır.

5.1. Gerçek Zamanlı Kumaş Hata Görüntülerinin Tespiti

Kumaş hata tespit sistemi Evsa tekstil firmasında kurulmuştur. Sistem yazılımı içinde olan hata tespit sisteminin sözde kodu Şekil 5.1'de verilmiştir.

İşlem Adımı 1 (Kameraların ve görüntü yakalama sisteminin hazırlanması)

pylon.TlFactory sınıfından bir örnek oluştur #Kamera tanıtımı için.

1. tlFactory üzerinden bağlı cihazları listele.
2. Eğer cihaz listesi boşsa hata yazdır ("Kamera bulunamadı").
3. Boş bir kamera listesi oluştur.
4. Kullanılacak maksimum kamera sayısı kadar dön (#2 kamera).
5. tlFactory.CreateDevice() ile her kamera için bir
pylon.InstantCamera nesnesi oluştur ve kamera listesine ekle.
6. Kameranın model adını yazdır.
7. Kamerayı aç.
8. Pozlama süresini (exposureTime) değerine ayarla.
9. Tek bir kare yakalama stratejisiyle çekime başla.
10. Birinci kameranın çekim yapıp yapmadığını kontrol et.
11. Eğer birinci kamera çekim yapıyorsa döngüye devam et.
12. Kullanılacak maksimum kamera sayısı kadar dön (#2 kamera).
13. Her kamera için sonuç al.
14. Eğer görüntü yakalama başarılıysa;
15. Dönüştürücü (converter) kullanarak yakalanan görüntüyü OpenCV
uyumlu BGR formatına dönüştür.
16. Dönüştürülen görüntü (image) üzerinden veriye eriş.

İşlem Adımı 2 (RGB görüntüden gri tonlamaya geçiş)

Görüntüyü gri tonlamaya çevir.

İşlem Adımı 3 (DOOG filtresi uygula)

tantriggs fonksiyonuyla DOOG filtre görüntü işleme işlemi gerçekleştir.

İşlem Adımı 4 (Görüntüyü kırp)

İstenen bölgeyi kumaş uzunluğuna göre kırp.

İşlem Adımı 5 (Histogram eşitleme uygula ve eşikleme uygula)

Histogram analizi uygula.

Eşikleme uygula.

İşlem Adımı 6 (Hatalı alanları işaretle)

Kontur tespiti yap.

İlgi çeken nesneleri belirle ve yeşil olarak işaretle (alan filtresiyle).

Belirlenen nesneleri dikdörtgenlerle işaretle ve sonuçları bir listede topla ve kırmızı olarak işaretle.

Kameraları serbest bırak.

Görüntüleri birleştirerek ekrana yansıt.

Klavyeden 'q' tuşuna basılana kadar döngüye devam et.

Sonuç listesini temizle.

Tüm kameraları kapat ve kaynakları serbest bırak.

OpenCV pencerelerini kapat.

Döngü Sonu

Şekil 5.1. Görüntü işleme hata tespit sözde kodu.

Şekil 5.1’de verilen görüntü işleme kısmına ait sözde kod’da işlem adımları sırasıyla açıklanmıştır. İlk işlem adımında kamera tanıtımı ile başlayan komutlardan sonra kontrol komutları yer almaktadır. İkinci işlem adımında tek banta dönüştürülen görüntü elde edilmektedir. Üçüncü işlem adımında DOOG filtresi uygulanır. Dördüncü işlem adımında kumaş uzunluğu ve kullanıcı isteğine göre görüntü kırpma işlemi gerçekleştirilmektedir. Beşinci işlem adımında histogram eşitleme ve eşikleme işlemleri uygulanmaktadır. Altıncı

işlem adımımda hatalı alanlar kontur tespiti yapıлып yeşil ve kırmızı dikdörtgenler içine alınmaktadır.

Tez çalışmasının ilk kısmı olan hatanın tespit edilmesi aşaması yukarıda anlatılmıştır. Hata tespit edildikten sonraki kısım olan sınıflandırma aşaması sözdekodları Şekil 5.2’de verilmiştir.

İşlem Adımı 1 (CNN tasarımı) 1. Hatalı görüntülerin yer aldığı klasör yolunu tanıt. 2. Batch size (grup boyutu), görüntü genişlik ve yükseklik değerlerini gir. 3. Eğitim veri setini oluştur. %70 Eğitim 4. Doğrulama veri setini oluştur. %15 Doğrulama 5. Sınıf isimlerini eğitim veri setine göre oluştur (atkı, çözgü, kırış, yabancı iplik). 6. Normalizasyon katmanı oluştur (1 / 255). 7. Model sequential oluştur (CNN Modeli Tasarla) 8. Model compile oluştur (Derleyici) 9. Epochs değeri gir (10). (Kullanılan döngü değeri) 10. Accuracy değerlerini hesapla. (Doğruluk değeri) 11. Modeli kaydet. 12. Test aşamasında son kaydedilen modeli yükle %15 Test 13. Görüntü özelinde model predict oluştur. (Model Tahminleme) 14. Yüzde skor yazdırıp sınıf çıkışını tahminle. Döngü Sonu

Şekil 5.2. Tespit edilen hata türünün sınıflandırılması için tasarlanan CNN mimarisi sözde kodu (Tasarlanan CNN mimarisi Şekil 6.3’de verilmiştir).

Şekil 5.2’de yer alan sözde kod’da hatalı görüntülerin yer aldığı dosya yolu tanıtılmaktadır. Görüntünün genişlik, yükseklik ve grup boyutu değerleri girilmektedir. Eğitim ve doğrulama veri setleri oluşturulmaktadır. CNN modeli tasarlanmaktadır ve model kaydedilip test aşamasında kullanılmaktadır. Model tahminleme ile ekrana yüzdelik skor yazdırılıp sınıf çıkışı tahmin edilmektedir.

Tasarlanan CNN mimarisine ait model özeti Şekil 5.3’te verilmiştir.

Model: "sequential"

Layer (type)	Output Shape	Param #
rescaling_1 (Rescaling)	(None, 180, 180, 3)	0
conv2d (Conv2D)	(None, 180, 180, 16)	448
max_pooling2d (MaxPooling2D)	(None, 90, 90, 16)	0
conv2d_1 (Conv2D)	(None, 90, 90, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 45, 45, 32)	0
conv2d_2 (Conv2D)	(None, 45, 45, 64)	18496
max_pooling2d_2 (MaxPooling2D)	(None, 22, 22, 64)	0
flatten (Flatten)	(None, 3072)	0
dense (Dense)	(None, 128)	396800
dense_1 (Dense)	(None, 4)	516


=====
Total params: 3,989,156
Trainable params: 3,989,156
Non-trainable params: 0

Şekil 5.3. Tasarlanan CNN mimarisine ait model özeti.

Şekil 5.3'te CNN mimarisi model özeti verilmiştir. Model 3 adet konvolüsyon katmanı, 3 adet maksimum havuzlama katmanı, flatten katmanı ve tam bağlantı katmanından oluşmuştur.

5.2. Tasarlanan Sistemin Arayüzü

Tasarlanan sistemin arayüzü kullanıcıların rahat bir biçimde işlemleri gerçekleştirmesi adına anlaşılır ve kolay tasarlanmıştır. Tkinter programı ile hazırlanan arayüz giriş ekranı görseli Şekil 5.4'de verilmiştir.



Remote Fabric Defect Detection System

User name:

Password:

Enter

Hesabınız Yok mu? [Kayıt Ol](#)

Şekil 5.4. Kullanıcı arayüz ekranı görseli.

Şekil 5.4’te kullanıcı arayüz giriş ekranı verilmiştir. Sol üstte “Giriş Ekranı” yazısı yer almaktadır. User name ve Password kısımlarına tıklanıldığında kullanıcının giriş yapabileceği giriş kutuları yer almaktadır.

Bu ekranın hazırlanmasını sağlayan kodlar sözdekod biçiminde Şekil 5.5’te verilmiştir.

Tasarlanan Sistemin Arayüz Ekranı (Arayüz tasarımı)

1. Tkinter kütüphanesini kontrol et. Eğer yoksa tkinter modülünden gerekli sınıfları (Tk, messagebox) içe aktar.
2. Diğer gerekli kütüphaneleri içe aktar (pylon, cv2, numpy)
3. Ana pencere (root) bir başlık ve boyut ata. Pencerenin yeniden boyutlandırılmayacağını belirt.
4. signin isimli bir fonksiyon oluştur.
5. Kullanıcı adı (username) ve şifre (password) giriş alanlarından değerleri al.
6. Eğer girilen kullanıcı adı (username) ve şifre (password) "admin" ve "1234" ise:
7. Yeni bir pencere (screen) oluştur.
8. Yeni pencereye başlık ve boyut ata. Pencerenin yeniden boyutlandırılmayacağını belirt.
9. Yeni pencereye bir karşılama mesajı yazdır.
10. Yeni pencerede bir "Başla" butonu oluştur ve bu butona tıklandığında test fonksiyonunu çağır.
11. Eğer girilen kullanıcı adı (username) veya şifre (password) yanlışsa:
12. Bir hata mesajı görüntü kutusu oluşturarak kullanıcıyı bilgilendir (Hatalı giriş, geçersiz kullanıcı adı veya şifre).
13. login.png dosyasından bir resim (img) oku ve ana pencereye yerleştir.
14. Ana pencere içerisinde beyaz renkli bir çerçeve (frame) oluştur.
15. Çerçeve içerisine "Remote Fabric Defect Detection System" yazısı ekle.
16. user adında bir giriş alanı oluştur.
17. Giriş alanına varsayılan olarak "User name: " yazısı yerleştir.
18. Giriş alanına tıklandığında varsayılan yazının silinmesini ve kullanıcı adı girişi için hazırlanmasını sağla.
19. Giriş alanından çıkıldığında eğer kullanıcı adı girilmemişse tekrar varsayılan yazının ("User name: ") görünmesini sağla.
20. Giriş alanı altına siyah yatay bir çizgi yerleştir.
21. code adında bir şifre giriş alanı oluştur.
22. Giriş alanına varsayılan olarak "Password: " yazısı yerleştir.
23. Giriş alanına tıklandığında varsayılan yazının silinmesini ve şifre girişi için hazırlanmasını sağla.
24. Giriş alanından çıkıldığında eğer şifre girilmemişse tekrar varsayılan yazının ("Password: ") görünmesini sağla.
25. Şifre giriş alanı altına siyah yatay bir çizgi yerleştir.
26. "Enter" yazılı bir buton oluştur.
27. "Kayıt Ol" yazılı bir buton oluştur ve bu butona tıklandığında signin fonksiyonunu çağır.

Şekil 5.5. Kullanıcı arayüz ekranı sözde kodu.

5.3. Kumaş Görüntülerinin Hatalarına Göre Sınıflandırılma Başarımı

Gerçek zamanlı oluşturulan kumaş hata tespit sistemi başarımını ölçmek için firma çalışanı gözle kontrolü ile sistemin hata tespit çıktıları karşılaştırılmıştır. Metre okuyucu yardımıyla oluşturulan karşılaştırma Çizelgesunda firma çalışanın göz ile kontrolü esnasında kumaş hatası oluştuysa hangi metrede olduğu belirlenmiştir. Metre kaydedilmiştir. Operatörün tuttuğu hata kayıt raporlarından bir örnek Şekil 5.6’da verilmiştir.

[illegible]

Şekil 5.6. Operatör hata kayıt rapor örneği.


Şekil 5.6’da operatörün el yazısıyla hazırlamış olduğu örnek bir hata kalite kontrol formu yer almaktadır. Raporda hata isimleri, metre bilgileri, ağırlık bilgileri ve top bilgileri yer almaktadır.

Daha sonra tez çalışması için tasarlanan kumaş hata tespit sistemi çalıştırılmıştır. Aynı metrede ilgili hatanın bulunup bulunmadığı karşılaştırılmıştır. Çalışma esnasında oluşan hatanın operatör tarafından fark edilip müdahale edildiği görseller Şekil 5.7, Şekil 5.8 ve Şekil 5.9’da verilmiştir.



Şekil 5.7. Tasarlanan sistemin bulduğu hatayı operatörün fark edip beze yaklaşması.

Şekil 5.7’de operatör hatayı fark edip sisteme yaklaşmış ve gerçek zamanlı görüntü yakalama sisteminin içine girmiştir. O yüzden operatörün saç kısmı hata ile birlikte hedeflenip görsele yansımıştır.




Şekil 5.8. Operatörün tasarlanan sistemin hatalı bulduğu bölgeye hata etiketi yapıştırması.




Şekil 5.9. Hata etiketli doğrulanmış örnek hata görseli.

Firma kalite kontrol operatörünün bulduğu hataları sistem eksiksiz bir biçimde ve aynı metrede tespit etmiştir. Tespit edilen bazı hataların görselleri aşağıda Şekil 5.10, Şekil 5.11, Şekil 5.12, Şekil 5.13, Şekil 5.14, Şekil 5.15, Şekil 5.16, Şekil 5.17, Şekil 5.18, Şekil 5.19, Şekil 5.20 ve Şekil 5.21 'de verilmiştir. Not: Yukarıda Pseudo Code da açıklandığı gibi; bütün bu şekillerde, Yeşil Dikdörtgen: Alan Filtresi, Kırmızı Dikdörtgen: Eşik Değeri Sonucu şeklindedir.




Şekil 5.10. Sistemin yakaladığı pamuk hatası örneği (BKZ: Yukarıda Pseudo Code, Yani; Yeşil Dikdörtgen: Alan Filtresi, Kırmızı Dikdörtgen: Eşik Değeri Sonucu – bütün şekillerde geçerlidir).




Şekil 5.11. Sistemin yakaladığı kırış hatası örnekleri.




Şekil 5.12. Sistemin yakaladığı atkı hatası ve kırış örnekleri (Atkı Hatasında Uzunluk Büyük Olduğundan Sistemi Yormamak İçin Küçük Dikdörtgenler Konulmuştur.).



Şekil 5.13. Sistemin yakaladığı yabancı iplik hatası örneği.



Şekil 5.14. Sistemin yakaladığı kırış hatası örneği.




Şekil 5.15. Sistemin yakaladığı leke hatası örneği.



Şekil 5.16. Sistemin yakaladığı tahar hatası örneği.



Şekil 5.17. Sistemin yakaladığı kırış hatası örneği.




Şekil 5.18. Sistemin DOOG filtre sonucunda yakaladığı atkı hatası örneği.



Şekil 5.19. Sistemin yakaladığı yabancı iplik hatası örneği.



Şekil 5.20. Sistemin yakaladığı yapışkan etiket hatası örneği.



Şekil 5.21. Sistemin yakaladığı yabancı iplik örnekleri.

Kumaş hata tespiti ve sınıflandırılması farklı günlerde yapılmış olup farklı renklerdeki kumaşlar kullanılmıştır. Alt ışık, üst ışık ve bazı durumlarda alt ve üst ışık birlikte kullanılmıştır. Çalışmanın yapıldığı günlere ait hata görüntüleri bilgisayarın depolama aygıtında gün, ay, yıl isimli klasörde saklanmıştır. Yapılan çalışmalar neticesinde beyaz renkli ham bez için sadece üst ışık kullanıldığında genel anlamda yabancı iplik ve kırış hatalarını tasarlanan sistemin sorunsuz bir biçimde tespit ettiği gözlenmiştir. Sadece alt ışık kullanılması durumunda beyaz renkli ham bez için atkı hatalarının tespiti anlamında iyi sonuçlar alınmıştır. Siyah renkli kumaşta hata tespiti için hem alt hem de üst ışık birlikte kullanıldığında hata tespiti anlamında daha iyi sonuçlar alınmıştır. Yeşil renkli kumaşta ise sadece üst ışık kullanıldığında bile birçok hatayı sorunsuz bir biçimde tasarlanan sistem tespit etmiştir. Beyaz renkli ham bez için sadece üst ışık kullanıldığında verilerin Çizelgesi Çizelge 5.1’de verilmiştir.

Çizelge 5.1 Sadece üst ışık etkisindeki beyaz renkli ham bez kumaşın başarımı.

Tespit Gerçek	Atkı Hataları		Çözümlü Hataları		Yabancı İplik Hataları		Kırış Hataları	
	Operatör (insan gözü ile)	Tasarla nan CNN ile	Operatör (insan gözü ile)	Tasarlanan CNN ile	Operatör (insan gözü ile)	Tasarlan an CNN ile	Operatör (insan gözü ile)	Tasarlan an CNN ile
Atkı Hataları	18	16	0	0	0	0	0	0
Çözümlü Hataları	0	0	0	0	0	0	0	0
Yabancı İplik Hataları	0	0	0	0	2	2	0	0
Kırış Hataları	0	0	0	0	0	0	4	6

Çizelge 5.2 Beyaz renkli ham bez kumaşın karmaşıklık matrisleri.

Atkı Hataları	Toplam Nüfus=P+N = 18	Tasarlanan CNN ile	
		Pozitif (PP) 16	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 18	Gerçek Pozitif (TP) 16	Yanlış Negatif (FN) 0
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 2

Çözümlü Hataları	Toplam Nüfus=P+N = 0	Tasarlanan CNN ile	
		Pozitif (PP) 0	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 0	Gerçek Pozitif (TP) 0	Yanlış Negatif (FN) 0
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Yabancı İplik Hataları	Toplam Nüfus=P+N = 2	Tasarlanan CNN ile	
		Pozitif (PP) 2	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 2	Gerçek Pozitif (TP) 2	Yanlış Negatif (FN) 0
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Kırış Hataları	Toplam Nüfus=P+N = 6	Tasarlanan CNN ile	
		Pozitif (PP) 6	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 4	Gerçek Pozitif (TP) 4	Yanlış Negatif (FN) 0
	Olumsuz (N) 2	Yanlış Pozitif (FP) 2	Gerçek Negatif (TN) 0

Çizelge 5.2’de görüldüğü üzere sadece üst ışık etkisinde çalıştırılan sistemin bulması gereken atkı hatasının iki tanesini kırış hatası olarak sınıflandırması atkı hatalarının tespit ve sınıflandırma çalışmalarında alt ışığın daha iyi sonuçlar verdiğini bizlere düşündürmüştür ve sadece alt ışık varken tasarlanan sisteme beyaz renkli ham bez beslemesi yapılmıştır. Çıkan sonuçlar Çizelge 5.3’de verilmiştir.

Çizelge 5.3 Sadece alt ışık etkisindeki beyaz renkli ham bez kumaşın başarımı.

Atkı Hataları	Toplam Nüfus=P+N = 18	Tasarlanan CNN ile	
		Pozitif (PP) 18	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 18	Gerçek Pozitif (TP) 18	Yanlış Negatif (FN) 0
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Çözgü Hataları	Toplam Nüfus=P+N = 0	Tasarlanan CNN ile	
		Pozitif (PP) 0	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 0	Gerçek Pozitif (TP) 0	Yanlış Negatif (FN) 0
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Yabancı İplik Hataları	Toplam Nüfus=P+N = 2	Tasarlanan CNN ile	
		Pozitif (PP) 2	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 2	Gerçek Pozitif (TP) 2	Yanlış Negatif (FN) 0
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Kırış Hataları	Toplam Nüfus=P+N = 6	Tasarlanan CNN ile	
		Pozitif (PP) 6	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 4	Gerçek Pozitif (TP) 4	Yanlış Negatif (FN) 0
	Olumsuz (N) 2	Yanlış Pozitif (FP) 2	Gerçek Negatif (TN) 0

Siyah renkli kumaşta duruş izi hataları, tahar hataları gibi hatalar da bulunmuştur ancak biz sınıflandırma sistemini genel anlamda 4 başlık altında topladığımız için bu hata sınıfları çıkartılmamıştır. Farklı hata sınıflarına ait görseller Şekil 5.22 ve Şekil 5.23 'de verilmiştir:



Şekil 5.22. Kenar püskülü hatası.



Şekil 5.23. Farklı tipteki kumaş hatası.

Siyah renkli kumaştaki hataların tespit ve sınıflandırılmasında hem alt hem de üst ışık kullanılmıştır. Böylece kumaştaki ışık geçirgenliği artırılmış olup hatalar daha sağlıklı bir biçimde tespit edilmiştir. Siyah renkli kumaştaki hataların sınıflandırma başarımı Çizelge 5.4’de verilmiştir.

Çizelge 5.4 Siyah renkli kumaştaki hataların sınıflandırma başarımı *(tek ışık yetmediğinden iki ışık kullanılmıştır)*

Atkı Hataları	Toplam Nüfus=P+N = 14	Tasarlanan CNN ile	
		Pozitif (PP) 13	Negatif (PN) 1
Operatör (insan gözü ile)	Pozitif (P) 14	Gerçek Pozitif (TP) 13	Yanlış Negatif (FN) 1
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Çözümlü Hataları	Toplam Nüfus=P+N = 21	Tasarlanan CNN ile	
		Pozitif (PP) 19	Negatif (PN) 2
Operatör (insan gözü ile)	Pozitif (P) 21	Gerçek Pozitif (TP) 19	Yanlış Negatif (FN) 2
	Olumsuz (N) 0	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 0

Yabancı İplik Hataları	Toplam Nüfus=P+N = 10	Tasarlanan CNN ile	
		Pozitif (PP) 8	Negatif (PN) 2
Operatör (insan gözü ile)	Pozitif (P) 8	Gerçek Pozitif (TP) 8	Yanlış Negatif (FN) 0
	Olumsuz (N) 2	Yanlış Pozitif (FP) 0	Gerçek Negatif (TN) 2

Kırış Hataları	Toplam Nüfus=P+N = 46	Tasarlanan CNN ile	
		Pozitif (PP) 46	Negatif (PN) 0
Operatör (insan gözü ile)	Pozitif (P) 45	Gerçek Pozitif (TP) 45	Yanlış Negatif (FN) 0
	Olumsuz (N) 1	Yanlış Pozitif (FP) 1	Gerçek Negatif (TN) 0

Yeşil renkli kumaşa da siyah renkli kumaşa olduğu gibi hem alt hem de üst ışık kullanılmıştır ancak siyah renkli kumaşa göre yeşil renkli kumaş sadece üst ışık etkisinde iken daha iyi sonuçlar vermiştir. Yeşil kumaştaki bazı hatalar Şekil 5.24 ve 5.25’de verilmiştir.



Şekil 5.24. Yeşil renkteki kumaşa oluşan hata.



Şekil 5.25. Yeşil renkteki kumaşta oluşan hatalar.

Toplam hata tespit ve sınıflandırma başarıımı ile ilgili veriler Çizelge 5.5’de verilmiştir.

Çizelge 5.5 Operatör – Tasarlanan sistem hata tespit ve sınıflandırma başarıımı (%).

Gerçek Tahmin	Atkı Hataları		Çözümlü Hataları		Yabancı İplik Hataları		Kırış Hataları	
	Operatör (%)	Tasarlanan Sistem (%)	Operatör (%)	Tasarlanan Sistem (%)	Operatör (%)	Tasarlanan Sistem (%)	Operatör (%)	Tasarlanan Sistem (%)
Atkı Hataları	100	96	0	0	0	0	0	4
Çözümlü Hataları	0	0	100	94	0	6	0	0
Yabancı İplik Hataları	0	0	0	6	100	94	0	0
Kırış Hataları	0	4	0	0	0	0	100	96

Tasarlanan CNN mimarisine ilişkin test görsellerinin bazıları Şekil 5.26, Şekil 5.27 ve Şekil 5.28 de verilmiştir.

```
In [6]: runfile('D:/Deep Learning/cnn/untitled0.py', wdir='D:/Deep Learning/cnn')
1/1 [=====] - 0s 90ms/step
Image name most likely belongs to kiris with a 98.10 percent confidence.
```

Şekil 5.26. Kırış hatasına ait tasarlanan CNN test skor sonucu.


```
1/1 [=====] - 0s 86ms/step
Image name most likely belongs to atki with a 60.86 percent confidence.
```

Şekil 5.27. Atkı hatasına ait tasarlanan CNN test skoru sonucu.

```
1/1 [=====] - 0s 144ms/step
Image name most likely belongs to kiris with a 95.90 percent confidence.
```

Şekil 5.28. Kırış hatasına ait tasarlanan CNN test skoru sonucu.

Farklı kumaş hata görüntüleri için sınıflandırma yapan CNN algoritmasında çıkan farklı skorların sebebi kumaş hatalarının farklı bilgiler barındırmasından kaynaklanmaktadır. Örneğin Şekil 5.27’de yer alan %60’lık skor verilen sınıflandırılmış hatanın görseli Şekil 5.29 da verilmiştir.



Şekil 5.29. Farklı tipteki hataların yer aldığı kumaş görüntüsü (Üst taraf atkı hatası, orta taraf kırış hatası, alt taraf yabancı iplik hatası).

Aynı çekim içinde birden fazla hatanın yer aldığı durum çok nadir görülse de çalışma esnasında karşılaşılan bir olay haline gelmiştir. Bu gibi görüntülerde tasarlanan CNN algortimasının, görüntüde en fazla hangi sınıfa ilişkin hata varsa o sınıfa ait karar verici rol üstlendiği görülmektedir. Tasarlanan CNN modelin 10 döngüde ortaya çıkan eğitim doğruluk sonuçlarının yer aldığı görsel Şekil 5.30’da verilmiştir.

```
Epoch 1/10
7/7 [=====] - 7s 717ms/step - loss: 1.3887 - accuracy: 0.2670 -
val_loss: 1.3697 - val_accuracy: 0.3725
Epoch 2/10
7/7 [=====] - 2s 243ms/step - loss: 1.2577 - accuracy: 0.5971 -
val_loss: 1.4029 - val_accuracy: 0.3529
Epoch 3/10
7/7 [=====] - 2s 247ms/step - loss: 0.9678 - accuracy: 0.6456 -
val_loss: 0.8850 - val_accuracy: 0.6863
Epoch 4/10
7/7 [=====] - 2s 242ms/step - loss: 0.5702 - accuracy: 0.7573 -
val_loss: 0.5449 - val_accuracy: 0.7843
Epoch 5/10
7/7 [=====] - 2s 251ms/step - loss: 0.4228 - accuracy: 0.8398 -
val_loss: 0.5266 - val_accuracy: 0.8431
Epoch 6/10
7/7 [=====] - 2s 267ms/step - loss: 0.2971 - accuracy: 0.8835 -
val_loss: 0.5558 - val_accuracy: 0.8824
Epoch 7/10
7/7 [=====] - 2s 266ms/step - loss: 0.2922 - accuracy: 0.9126 -
val_loss: 0.5170 - val_accuracy: 0.8627
Epoch 8/10
7/7 [=====] - 2s 266ms/step - loss: 0.2189 - accuracy: 0.8981 -
val_loss: 0.5312 - val_accuracy: 0.8627
Epoch 9/10
7/7 [=====] - 2s 253ms/step - loss: 0.1781 - accuracy: 0.9175 -
val_loss: 0.5712 - val_accuracy: 0.8431
Epoch 10/10
7/7 [=====] - 2s 250ms/step - loss: 0.1431 - accuracy: 0.9272 -
val_loss: 0.6432 - val_accuracy: 0.8431
```

Şekil 5.30. 10 döngü değerine ilişkin kayıp, doğruluk ve validasyon doğruluğu değerleri.

Şekil 5.30’da 10 epoch yani döngüde ilk döngüden onuncu döngüye kadar gidildiğinde loss yani kayıp değerlerinin azaldığı ve accuracy yani doğruluk değerlerinin arttığı görülmektedir. Son döngüdeki kayıp değeri 0.1431 ve doğruluk değeri 0.9272 olarak belirlenmiştir.

6. SONUÇ VE ÖNERİLER

Kumaş hata tespit ve sınıflandırma sistemi prototipi Denizli ili içinde yer alan Evsa Tekstil işletmesinde kurulmuştur. Bu tez çalışması sonucunda elde edilen verilerden ilki sistemin ortalama başarımlar yüzdesidir. Literatürde birçok hata tipi mevcuttur. Bu hata tiplerinden en sık karşılaşılan hataların bazıları değerlendirmeye alınmıştır. Farklı ışık etkileri altında beyaz renkli kumaş, yeşil renkli kumaş ve siyah renkli kumaşta oluşan hatalar ve bu hataların sınıflandırma başarımları karşılaştırılmıştır. Daha sonra çalışılan bütün hatalı kumaşlar baz alınarak toplam atkı hataları, çözgü hataları, yabancı iplik hataları, kırış hataları operatör ve sistem karşılaştırılması yapılarak başarımlar yüzdesi hesaplanmıştır. Tez çalışmasının sonucunda ilgili hataların toplam tespit ve sınıflandırma başarımlar yüzdesi ortalaması %95 dir. Bu sonuç çalışmanın başarılı olduğunun bir göstergesidir.

Eğitim modelinin 0.9272 doğruluk değerine sahip olması ve kayıp değerinin 0.1431 olması bu çalışma kapsamında istenen bir sonuçtur. Modelin çok fazla ezberleyip hata yapmasının önüne geçilmiştir. Tez içerisinde ilgili bölümlerde tespit edilen bazı kumaş hatalarının görselleri verilmiştir. Bu görsellerde hatalar dikdörtgen içine alınıp hedeflenmiştir. Böylece okuyucuların hataları fark etmeleri kolaylaştırılmıştır.

Bu alanda çalışacak olan diğer araştırmacılar için faydalı bir tez çalışması hazırlandığı düşünülmektedir. Sistemin daha iyi performans göstermesi için birkaç öneri sunulmaktadır. Bu önerilerden ilki işletme şartlarını iyi bir biçimde tespit edip işletmede kurulacak olan sistemin ortam ışığından olabildiğince ayrıştırılması gerekliliğidir. Aksi halde gün ışığı ve ortam ışığına maruz kalan sistem bozucu etkiler gösterebilmektedir. Diğer bir öneri ise kamera ve kamera lenslerinin kumaşın dikey ve yatayda ne kadar alan üzerinde çalışılacaksa o odak mesafesinde seçilmesini gerekli kılmaktadır. Lenslerin doğru bir biçimde seçimi ve montaj yapılacak derinlik mesafesinin ölçülmesi başarımlar yüksek oranda arttıracaktır. Dokuma kumaş üzerinde meydana gelen hataların yorumlanmasına ilişkin önceden tekstil alanında bilgi ve deneyim sahibi olmak da hata tespiti açısından araştırmacıların işini kolaylaştıracak bir diğer etkidir.

Teknolojinin günden güne hızla gelişiminin ve tedarik sürecindeki yeniliklerin, sistemin kurulması için gerekli olan donanım maliyetlerini giderek düşürebileceği öngörülmektedir. Böylece alanda çalışacak olan araştırmacılar daha ucuz maliyetle donanım gereksinimlerini karşılayabilecek ve sistem üzerinde iyi sonuçlar elde edebileceklerdir. Dikkat edilmesi gereken

bir diğ er husus tekstil alanında faaliyet g osteren dokuma i letmelerinin ilerleyen s re te bu sistemlere ister istemez y onelm e gerekliliğidir. Esnek  alı ma bi imlerinin ve i  i maliyetlerinin arttığ ı g un m z d nyasında, bu alanda yapılacak olan  alı malar tekstil firmalarına ekonomik olarak katkı sağlayacak ve diğ er firmalara g ore rekabet ortamında  nde olmalarını m mk n kılacaktır.

 alı manın ger ek zamanlı olması hem akademik a ıdan hem de tekstil sekt r nde uygulama yapılmı  olması a ısından mevcut haliyle  nem arz etmektedir. Dokuma kuma  üzerinde yapılan bu tez  alı ması geli tirilip  rme ve diğ er kuma   e itleri  zerinde uygulanabilir.  alı ılan sistemin kuma  hatalarının tespit ve sınıflandırılmasında kameraların  artlandırılması, kuma   alı ma b lgesindeki ı ık  iddeti ve farklı desen ve kuma  tiplerindeki ba arım ili kisine y onelik nicel ara tırmaların yapılarak otomasyonun geli tirilmesinin, tekniğinin geli tirilerek s rd r lebilir bir  ekilde tekstil fabrikalarında kullanılabilirliğ i a ısından yararlı olacağı d   n lmektedir. Ayrıca, birbirine yakın hataların ayırt edilmesine y onelik g r nt  i leme ve CNN modellerinin geli tirilmesinin de bu bağlamda yararlı olacağı d   n lmektedir.

KAYNAKLAR

- Ala, D. M. (2008). *Dokuma kumaş hatalarının görüntü analiz yöntemiyle sayısallaştırılması*. [Yüksek Lisans Tezi, Pamukkale Üniversitesi], YÖK Ulusal Tez Merkezi, https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=wBmNpkQC9Nhi90NLW7E7-YKNFghm7_WJm69UEwDuj9amwt08IMowCRQ2w9AP9c5M.
- Bağırhan, M. (2019). *Shearlet dönüşümü kullanılarak gerçek zamanlı kumaş hatası tespiti*. [Yüksek Lisans Tezi, Maltepe Üniversitesi], YÖK Ulusal Tez Merkezi, https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=as2oTjW5jfr9IKSvmCdJYhCdAFBNq_HLcCRzaEsBmI-9TH6Xtck0xrU6hJ_fHd80.
- Bağkur, S. (2013). *Fabric defect detection using image processing techniques* [Master's thesis, Dokuz Eylül University], YÖK Ulusal Tez Merkezi, https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=rcbWnuqW6HxCZ_98ARapgjSsX0SMbGYUcLez2P6wZ7_cVoCuQ6nIYkqO6ltWYTjZ.
- Bariş, B. ve Özek, H. Z. (2019). Dokuma kumaş hatalarının sistematik sınıflandırılması üzerine bir çalışma. *Tekstil ve Mühendis*, 26(114), 156–167. <https://doi.org/10.7216/1300759920192611405>
- Çıklaçandır, F. G. Y., Utku, S. ve Özdemir, H. (2020). Kumaşlarda hatayı yerel olarak arayan denetimsiz bir sistem. *Tekstil ve Mühendis*, 27(120), 252-259. <https://doi.org/10.7216/1300759920202712005>
- Dettmers, T. (2015). *Deep learning in a nutshell: Core concepts*. NVIDIA Devblogs. <https://devblogs.nvidia.com/deep-learning-nutshell-core-concepts/>
- Deniz, C. (2023). Derin Öğrenme Ders Notları. Aydın Adnan Menderes Üniversitesi.
- Gonzalez, R. C. ve Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson Education
- Güler, H. (2013). *GPU ile Kumaş Hata Tespiti ve sınıflandırılması*. [Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi].
- Gürbüz, B. (2019, Aralık 28). Konvolüsyonel sinir ağları (evrişimli sinir ağları olarak da bilinir) convolutional neural networks (CNNs). Medium. <https://medium.com/@batincangurbuz/konvolüsyonel-sinir-ağları-evrişimli-sinir-ağları-olarak-da-bilinir-convolutional-neural-4ecd2c5ad842>

- Hanbay, K. (2016). *Yuvarlak örgü makineleri için görüntü işleme tabanlı kumaş hatası tespit sistemi*. [Doktora tezi, İnönü Üniversitesi], Yök Ulusal Tez Merkezi, https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=OykDDDeWBWTL9-Wm52sZBrMbTC6-CEz4-j_g15yAV3Eiyh3tzvjhfMwbWaODYsrhZ
- Hanbay, K., Talu, M. F. ve Özgüven, Ö. F (2017). *Fourier dönüşümü kullanılarak gerçek zamanlı kumaş hatası tespiti*. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(1).
- Hanbay, K., Golgiyaz, S. ve Talu, M. F. (2017). *Real time fabric defect detection system on Matlab and C++/Opencv platforms*. *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*. IEEE.
- Hanbay, K., ve Talu, M. F. (2014). *Kumaş hatalarının online/offline tespit sistemleri ve yöntemleri*. *Sakarya University Journal of Science*, 18, 49-69. <https://dergipark.org.tr/tr/pub/saufenbilder/issue/20678/220675>
- Karataş, İ. ve Soyaslan, D. D. (2016). *Tekstil Endüstrisinde Yapay Görme ile Hata Tespit Uygulamaları*. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(Özel (Special) 1), 51-57.
- Kaur, G., Sinha, R., Tiwari, P. K., Yadav, S. K., Pandey, P. Raj, R. ve Rakhra, M. (2022). *Face mask recognition system using CNN model*. *Neuroscience Informatics*, 2(3), 100035.
- Kısaoğlu, Ö. (2006). *Kumaş Kalite Kontrol Sistemleri*. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 233-241.
- Kouretas, I., ve Paliouras, V. (2019, May). *Simplified hardware implementation of the softmax activation function*. In *2019 8th international conference on modern circuits and systems technologies (MOCAST)* (pp. 1-4). IEEE.
- Lindeberg, T. (1998). *Edge detection using a scale-space method: The case of active edges*. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 20(10), 1072-1089.
- Lin, G., ve Shen, W. (2018). *Research on convolutional neural network based on improved Relu piecewise activation function*. *Procedia computer science*, 131, 977-984.
- Nawaf, A. M. (2019). *Development of a new software for fabric defect detection and classification using image processing and machine learning methods* [Master's thesis, Çukurova Üniversitesi], <https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=FgmKGchPKo23qQqBeqzVZg370GJAWO7LZvg8D2DLuxHgHyf0qpEXaqOIi4rZpdPI>

- Rodríguez, J. E., ve Ayala, D. (2001, November). *Erosion and Dilation on 2-D and 3-D Digital Images: A New Size-Independent Approach*. In VMV.
- Şeker, A., ve Yüksek, A. G. (2017). *Stacked autoencoder method for fabric defect detection*. *Cumhuriyet Üniversitesi Fen Edebiyat Fakültesi Fen Bilimleri Dergisi*, 38(2), 342-354.
- Shahrabadi, S., Solaimanian, M., ve Minaei, M. (2022). *Defect detection in the textile industry using image-based machine learning methods: a brief review*. *Journal of Physics: Conference Series*, 2224(1), 012015.
- Shakir, S. (2019). *Unsupervised fabric defect detection via clustering in spectral domain* [Master's thesis, Anadolu Üniversitesi], https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=vjszP7PzV0HebcjFEvDfwLE0qlRN_YETDfnP8lqc3NRf_6xQxwDA6tvXU8ZWz6uq
- Standard, A. S. T. M. (1999). *Standard terminology relating to fabric defects*. *ASTM International, Pennsylvania, USA*. ASTM D3990-99.
- Taşci, İ. (2015). *Yonga levha üretim sistemlerinde görüntü işleme tabanlı hata denetimi* [Master's thesis, Süleyman Demirel Üniversitesi], https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=WBc656i315e2eV6-EZV1ot7UZDd2XNgcTi9cPUlzIrVITLBH8Dok_MZ_vMC8bmjL
- Ükte, A. (2023). *Görüntü İşleme Ders Notları*. Aydın Adnan Menderes Üniversitesi.
- Van Veen, F., ve Leijnen, S. (2019). *A mostly complete chart of Neural Networks*. *The Neural Network Zoo*. Retrieved December, 28, 2020.
- Yıldız, K., Buldu, A., ve Demetgul, M. (2016). *A thermal-based defect classification method in textile fabrics with K-nearest neighbor algorithm*. *Journal of Industrial Textiles*, 45(5), 780-795.



EKLER

EK-1 EVSA Tekstil KVKK izin formu.



EVSA Ev Tekstil San. Tic. A.Ş. firma sahibi olarak firmamıza ait kumaş kalite kontrol makinesi görsellerinin, işletme çalışanlarımızın fotoğraflarının, işletmemize ait görsellerin ve diğer verilerin proje, bilimsel çalışmalar, (makale, bildiri, konferans vb.) ve üniversite tez çalışmaları kapsamında KVKK açık rıza metnine ilişkin onayımın olduğunu beyan ederim.

Ali Erdem AYAZ





ÖZ GEÇMİŞ

Soyadı, Adı : Topçu, Uğur Can

Yabancı Dil : İngilizce

E-posta Adresi :

EĞİTİM Derece - Kurum	Mezuniyet tarihi(Yıl)
Doktora: -	
Y. Lisans: Aydın Adnan Menderes Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği	2024
Lisans: Pamukkale Üniversitesi Elektrik Elektronik Mühendisliği	2017

İŞ DENEYİMİ Yıl	Yer/Kurum	Unvan
2017-2018	Yön Yapı Denetim	Kontrol Mühendisi
2018-2019	Koralay Mühendislik	Elektrik Elektronik Mühendisi
2020-2022	Menderes Tekstil	Elektrik Otomasyon Tasarım Kıdemli Mühendisi
2022-...	Invisiotech	Kurucu Ortak

AKADEMİK ÇALIŞMALAR

1. MAKALELER

Ertuna, İ., Topçu, U. C., Yalçinkaya, Ç., Açıkgöz, D., Cırık, E., ve Göde, C. (2021). Design and manufacturing of the prototype system for recycling waste generated in 3 dimensional production to filaments by fused deposition modeling method. *Celal Bayar University Journal of Science*, 17(3), 261-266

Ertuna, I., Güngör, Y., Karaoğlu, F., Dindar, N., Topçu, U. C., Çalış, G., ve Göde, C. (2021). Design and Production of Smart Wearable Textile Products Using Layered Manufacturing Technology with Photovoltaic Energy. *South Florida Journal of Development*, 2(2), 1636-164



