

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİYEL ÜRÜNLERİN YÜZEY KUSURLARININ
GÖRÜNTÜ İŞLEME İLE ALGILANMASI VE
TANIMLANMASI

Muhammed Ali Nur ÖZ

DOKTORA TEZİ
Kontrol ve Otomasyon Mühendisliği Anabilim Dalı
Kontrol ve Otomasyon Mühendisliği Programı

Danışman
Doç. Dr. Özgür Turay KAYMAKÇI

Eş-Danışman
Dr. Öğr. Üyesi Muharrem MERCİMEK

Ocak, 2022

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ENDÜSTRİYEL ÜRÜNLERİN YÜZEY KUSURLARININ GÖRÜNTÜ
İŞLEME İLE ALGILANMASI VE TANIMLANMASI**

Muhammed Ali Nur ÖZ tarafından hazırlanan tez çalışması 11.01.2022 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Kontrol ve Otomasyon Mühendisliği Anabilim Dalı Kontrol ve Otomasyon Mühendisliği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Özgür Turay KAYMAKÇI
Yıldız Teknik Üniversitesi
Danışman

Dr. Öğr. Üyesi Muharrem MERCİMEK
Yıldız Teknik Üniversitesi
Eş-Danışman

Jüri Üyeleri

Doç. Dr. Özgür Turay KAYMAKÇI, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Şeref Naci ENGİN, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Tarık Veli MUMCU, Üye
İstanbul Üniversitesi - Cerrahpaşa

Dr. Öğr. Üyesi Onur AKBATI, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Gökhan GELEN, Üye
Bursa Teknik Üniversitesi

Danışmanım Doç. Dr. Özgür Turay KAYMAKÇI sorumluluğunda tarafımda hazırlanan Endüstriyel Ürünlerin Yüzey Kusurlarının Görüntü İşleme ile Algılanması ve Tanımlanması başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Muhammed Ali Nur ÖZ

İmza

Bu alıřma Trkiye Bilimsel ve Teknolojik Arařtırma Kurumu (TBİTAK) tarafından desteklenmiřtir (Proje no: 118E607).

*Aileme
ve Dostlarıma*

TEŞEKKÜR

Çalışmamın her aşamasında bana destek olan, yardım eden, yönlendiren, bilgi ve deneyimini esirgemeyen danışmanım Sayın Doç. Dr. Özgür Turay KAYMAKÇI ve eş danışmanım Dr. Öğr. Üyesi Muharrem MERCİMEK'e sonsuz şükranlarımı sunarım. Desteklerini her zaman hissettiğim, bilgi ve deneyimlerini esirgemeyen tez izleme komitesindeki hocalarım Prof. Dr. Şeref Naci ENGİN ve Dr. Öğr. Üyesi Tarık Veli MUMCU'ya çok teşekkür ederim.

Tez çalışması süresince öneri ve yardımlarıyla bana destek olan hocalarım Dr. Öğr. Üyesi Bilal EROL, Dr. Halit ÖRENBAŞ ve Arş. Gör. Esra Kaya AYANA'a teşekkür ederim. Kontrol ve Otomasyon Mühendisliği Bölümü'ndeki diğer hocalarıma ve tüm Araştırma Görevlisi arkadaşlarıma teşekkür ederim.

En önemlisi çalışmam boyunca her zaman yanımda olan, bana yol gösteren sevgili babam Prof. Dr. Cemil ÖZ'e, manevi desteğini esirgemeyen kıymetli annem Yeter ÖZ'e, kardeşlerim Tuğba ÖZ ve Alperen ÖZ'e çok teşekkür ediyorum. Son olarak, motivasyon kaynağım olan dostlarıma teşekkür ederim.

Muhammed Ali Nur ÖZ

İÇİNDEKİLER

SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	xi
TABLO LİSTESİ	xiii
ÖZET	xiv
ABSTRACT	xvi
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	7
1.3 Orijinal Katkı	7
2 KUMAŞ MUAYENE SİSTEMLERİ	9
2.1 Kumaş Kusurları	9
2.2 İnsan Tabanlı Muayene Sistemleri	11
2.2.1 Geleneksel Kumaş Kontrol Teknikleri	11
2.2.2 İnsan Tabanlı Muayene Sistemlerinin Dezavantajları	13
2.3 Otomatik Kumaş Muayene Sistemleri	14
2.3.1 Sistem Bileşenleri	14
2.3.2 Görüntü Analizi	15
2.3.3 Kusur Algılanması ve Tanımlanması	17
2.3.4 Otomatik Optik Muayene Sistemlerinin İsterleri ve Avantajları	17
3 DERİN ÖĞRENMENİN TEMELLERİ	19
3.1 Makine Öğrenmesi	19
3.1.1 Öğrenme Algoritmaları	19
3.1.2 Kapasite, Aşırı Öğrenme ve Eksik Öğrenme	22
3.1.3 Derin Sinir Ağlarına Ortaya Çıkmasındaki Etkenler	24
3.2 Derin Sinir Ağları	24

3.2.1	Evrişimli Derin Sinir Ağları	25
3.2.2	Optimizasyon	28
3.3	Otokodlayıcılar	29
3.3.1	Gürültü Arındırıcı Otokodlayıcılar	30
3.3.2	Uygulama Alanları	31
3.4	Çekişmeli Üretici Ağlar (GAN)	31
3.4.1	Alt Komponentleri	32
4	ÖNERİLEN YÖNTEMLER	33
4.1	Kümelenmiş Otokodlayıcı (NAE) Yaklaşımı	33
4.2	Ayrık Beyinli Otokodlayıcı (SBAE) Yaklaşımı	38
4.3	Geliştirilmiş DCGAN Yaklaşımı (M-DCGAN)	41
4.3.1	Ablasyon Çalışmaları	45
5	DENEYSEL SONUÇLAR	47
5.1	DeneySEL Sistem	47
5.1.1	Geliştirilen Arayüzlü Program	50
5.2	DeneySEL Sonuçlar	51
5.2.1	Kümelenmiş Otokodlayıcı (NAE) Yaklaşımı Sonuçları	54
5.2.2	Ayrık Beyinli Otokodlayıcı Yaklaşımı Sonuçları	56
5.2.3	Önerilen Geliştirilmiş DCGAN Yaklaşımı Sonuçları	58
6	SONUÇ VE ÖNERİLER	65
6.1	Öneriler	66
	KAYNAKÇA	67
	TEZDEN ÜRETİLMİŞ YAYINLAR	72

SİMGE LİSTESİ

T	Başarılmak İstenen Görev
b	Bias ağırlıkları
E	Elde Edilen Deneyim
φ	Evrişim İşlemi
W	Evrişim Kerneli
p	Koşullu Olasılık Dağılımı
P	Ölçülen Performans
x	Örneklem
L	Yitim Fonksiyonu

KISALTMA LİSTESİ

AE	Otokodlayıcı Ağ
AAMA	Amerikan Giyim Üreticileri
ANOGAN	Anomali Çekişmeli Üretici Ağlar
AOMS	Akıllı Otomatik Optik Muayene Sistemleri
AUC	Eğrinin Altındaki Alan
CAE	Evrişimsel Otokodlayıcı Ağ
CDAE	Evrişimsel Gürültü Giderici Otokodlayıcı Ağ
cDCGAN	Koşullu Derin Evrişimli Çekişmeli Üretici Ağlar
DAE	Gürültü Giderici Otokodlayıcı Ağ
DCGAN	Derin Evrişimli Çekişmeli Üretici Ağlar
DCNN	Derin Evrişimsel Sinir Ağları
GAN	Çekişmeli Üretici Ağlar
GigE	Gigabyte Ethernet
FPR	Yanlış Pozitif Oranı
IMS	İnsan Tabanlı Muayene Sistemleri
IoU	Kesiştirilmiş Bölgeler Ölçütü
MAE	Çok Katmanlı Perceptron
M-DCGAN	Önerilen Geliştirilmiş DCGAN Yaklaşımı
MSCDAE	Çok Ölçekli Evrişimsel Gürültü Giderici Otokodlayıcı Ağ
NAE	Önerilen Kümelenmiş Otokodlayıcı Yaklaşımı
OMS	Otomatik Optik Muayene Sistemleri
PCA	Principal Components Analysis
PRC	Kesinlik Ölçütü

PRO	Bölge Düzeyinde Puanlar Ölçütü
RCL	Duyarlılık Ölçütü
ROC	Alıcı İşletim Karakteristiği
SDGAN	Yüzey Kusur Çekişmeli Üretici Ağlar
SPAE	Önerilen Ayrık Beyinli Otokodlayıcı Yaklaşımı
SSIM	Yapı Benzerlik İndeksi
TPR	Gerçek Pozitif Oranı

ŞEKİL LİSTESİ

Şekil 2.1	Örnek kumaş kusurları	10
Şekil 2.2	İnsan tabanlı muayene sistemi	12
Şekil 2.3	Otomatik optik muayene sisteminin genel şeması	16
Şekil 3.1	Mode kapasitesi ve hata arasındaki ilişki	23
Şekil 3.2	Otokodlayıcının genel mimarisi	29
Şekil 3.3	Çekişmeli üretici ağlar (GAN)	32
Şekil 4.1	Önerilen NAE modelinin genel mimarisi	35
Şekil 4.2	NAE eğitim adımlarının şeması	38
Şekil 4.3	SBAE algoritmasının şeması	39
Şekil 4.4	Eğitim setinin hazırlanması: (a) orjinal kusursuz görüntüler, (b) görüntülerin 64x64 piksellik parçalara bölünmesi, (c) parçalardan eğitim verilerinin oluşturulması, (d) eğitim verisinin Lab renk uzayına dönüştürülmesi.	40
Şekil 4.5	Geliştirilen DCGAN yapısı	42
Şekil 4.6	DCT ile görüntü sıkıştırarak boyut küçültme algoritması	44
Şekil 5.1	Geliştirilen sistemin şeması	48
Şekil 5.2	Geliştirilen sistemin görüntüsü 1	49
Şekil 5.3	Geliştirilen sistemin görüntüsü 2	50
Şekil 5.4	Arayüz programında GAN yöntemi örneği	51
Şekil 5.5	Arayüz programında NAE yöntemi örneği	51
Şekil 5.6	Geliştirilen NAE yönteminin diğer popüler yaklaşımlarla karşılaştırılması	55
Şekil 5.7	Geliştirilen NAE yönteminin restorasyon gücünün popüler yaklaşımlarla karşılaştırılması	56
Şekil 5.8	Kusur barındıran görüntü örnekleri	56
Şekil 5.9	Sonuçlar: yukarıdan aşağıya doğru, giriş görüntüsü, tekrar oluşturulan görüntü, el ile işaretlenmiş kusur haritası, önerilen yapı tarafından işaretlenmiş kusur haritası.	57
Şekil 5.10	Önerilen yapının alıcı işletim karakteristiği (AUC - ROC)	59
Şekil 5.11	Örnek sonuç görüntüleri: önerilen yapının tespit ettiği anomaliler kırmızı renk, el ile işaretlenen kusurlar mavi renk ile verilmiştir. . . .	60

Şekil 5.12 E-DCGAN ile oluşturulan sentetik kumaş görüntüleri(sağda) ve verisetinden alınan kumaş görüntüleri(solda)	61
Şekil 5.13 Halı kategorisi için segmentasyon başarılı bölütleme örnekleri	63
Şekil 5.14 Halı kategorisi için segmentasyon kötü bölütleme örnekleri	64

TABLO LİSTESİ

- Tablo 5.1** Geliştirilen algoritmanın kusurlu görüntüler üzerindeki performansı ve diğer yöntemler ile karşılaştırılması: kusursuz görüntülerin doğru tespit edilme oranı (üst sıra) ve kusurlu görüntüler doğru sınıflandırılması oranı (alt sıra) verilmiştir, bu iki değerin en yüksek ortalaması olan yöntem kalın punto ile vurgulanmıştır. 54
- Tablo 5.2** Geliştirilen SBA yönteminin performansının ve diğer yöntemler ile karşılaştırılması: kusursuz görüntülerin doğru tespit edilme oranı (üst sıra) ve kusurlu görüntüler doğru sınıflandırılması oranı (alt sıra) verilmiştir, en yüksek performans kalın punto ile vurgulanmıştır. 57
- Tablo 5.3** Performansın yaygın olarak kullanılan diğer yöntemlerle karşılaştırılması: yukarıdan aşağıya doğru sırasıyla, doğru sınıflandırılmış kusursuz görüntüler, doğru sınıflandırılmış kusurlu görüntülerin oranı, segmentasyon performansı ve AUC-ROC değerleri verilmiştir. 59
- Tablo 5.4** Önerilen yöntemlerin performansının diğer yaygın yöntemlerle karşılaştırılması: tüm yöntemler için, AUC değeri TPR skoru piksel başına 30%'un altı için hesaplanmış ve normalize edilmiştir ve en iyi performans gösteren yöntem kalın yazı tipiyle vurgulanmıştır. . . . 62

Endüstriyel Ürünlerin Yüzey Kusurlarının Görüntü İşleme ile Algılanması ve Tanımlanması

Muhammed Ali Nur ÖZ

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Doç. Dr. Özgür Turay KAYMAKÇI
Eş-Danışman: Dr. Öğr. Üyesi Muharrem MERCİMEK

Günümüzde ülkemizin sanayi üretiminde en büyük paylarından birine sahip olan tekstil endüstrisi aynı zamanda ülkemizin en köklü sektörlerinden biridir. Buna rağmen son yıllarda sektörde baskın olan Çin ve Hindistan gibi ülkelerle rekabet etmekte sıkıntı yaşanmaktadır. Kaybedilen pazar payını geri kazanmak için, Türk tekstil endüstrisi, devletin desteğiyle üretimini modernize etmeyi ve kendisini yeni teknolojilere uyarlamayı hedeflemektedir. Sektörün anahtar teknolojilerden biri olan otomatik muayene sistemi, geleneksel muayene yöntemlerine kıyasla toplam üretim miktarını ve kalitesini arttırmaktadır.

Bu çalışmanın amacı gürbüz ve verimli kumaş kusur tespit yazılımı ile donatılmış, gerçek zamanlı otomatik bir kumaş inceleme sistemi geliştirmektir. Geliştirilen muayene sistemi, çeşitliliği fazla olması sebebiyle algılanması zor bir görev olan kumaş kusurlarını tespit edebilecektir. Yüksek üretim hızlarını destekleyecek olan bu sistemin aynı zamanda yüksek kusur algılama oranına sahip olması hedeflenmektedir. Ayrıca geliştirilen görsel muayene sistemi, yeni tanıtilen tekstil materyallerini öğrebilen ve muayene edebilen akıllı bir sistem olarak tasarlanacaktır.

Kusurları algılamak için istatistiksel, spektral temelli yaklaşımlardan oluşan bir yöntem kullanılacaktır. Daha sonra, özellik seçimine olan ihtiyacını azaltan ve büyük miktarda veriyi diğer yöntemlerle karşılaştırıldığında daha verimli bir şekilde işleyen derin öğrenme kullanılacaktır. Yeni kumaş çeşitleri tanımak için geliştirilen sistemin parametrelerini otomatik olarak düzenleyen bir teknik geliştirilecektir. Sonunda

geliştirilen yöntemler gerçek zamanlı sistemler için uygun şekilde programlanacaktır.

Anahtar Kelimeler: Optik muayene sistemleri, üretken çekışmeli ağlar, kusur tespiti, makine öğrenmesi, yapay sinir ağları

Detection and Identification of Surface Defects of Industrial Products with Image Processing

Muhammed Ali Nur ÖZ

Department of Control and Automation Engineering

Doctor of Philosophy Thesis

Supervisor: Assoc. Prof. Dr. Özgür Turay KAYMAKÇI

Co-supervisor: Asst. Prof. Dr. Muharrem MERCİMEK

Having the largest share in Turkish industrial production, the textile industry is one of the first established industries in Turkey. In recent years, the industry has been lagging behind in fierce competition with heavyweights such as China and India. To regain momentum, with the support of the government, Turkish textile industry aims to modernize its production, and adapt itself to new technologies. One of the key technologies is the automated inspection systems which improve overall production quantity and quality when compared with the traditional inspection methods.

The purpose of this study is to develop a real-time automated web inspection system equipped with robust and efficient fabric defect detection software. The inspection system will be able to detect real fabric defects which is a challenging task due to the large number of fabric defect classes. Along with high detection rates, the software will support inspection of web materials driven with high speeds. Furthermore developed inspection system will be intelligent, it will adapt itself and will be able to learn and inspect newly introduced web materials.

A combination of the latest techniques from statistical approaches and spectral approaches will be used to detect a variety of defects. Afterwards deep learning will be applied as it reduces the need for feature selection and handles big data more efficiently when compared with other methods. A method that can first learn and then inspect new fabric products will be developed. Finally proposed methods will be programmed appropriately for real time systems.

Keywords: Visual inspection systems, generative adversarial networks, defect detection, machine learning, artificial neural networks

1.1 Literatür Özeti

Sanayinin hızlanan küreselleşmesi ve etki alanının sürekli artması firmalar arasında şiddetli bir rekabete sebep olmaktadır. Pazar payı yarışında avantajı elde edebilmek için hedef tüketicilerin kalite ve miktar gereksinimlerinin eksiksiz karşılanması gerekmektedir. Bu nedenle firmaların gerekli teknolojik donanıma sahip olmaları hayati önem taşımaktadır. Geleneksel muayene yöntemlerine göre toplam üretim miktarını ve kalitesini önemli ölçüde arttırabilen otomatik optik muayene sistemleri (OMS) üretim sektörünün kilit teknolojilerinden biri haline gelmiştir.

Optik muayene, endüstriyel ürünlerin belirli standartlara, spesifikasyonlara veya gerekliliklere uygunluğunun incelenmesi şeklinde tanımlanabilir. Renk, alan/hacim kusurları, doku baskı ofsetleri, iplik/örgü kusurları, inceleme sırasında sıklıkla kontrol edilen özelliklerden bazılarıdır. OMS'lerinin çalışma prensiplerinin belirtilmesi oldukça zahmetlidir çünkü bu sistemler ürün tipi ve detaylandırılan kusurlar bakımından büyük farklılıklar gösterir. Son zamanlarda, genelleştirilebilen bir iş akışına sahip akıllı otomatik optik muayene sistemleri (AOMS), ürün hatlarında kullanılmak üzere geliştirilmekte ve araştırılmaktadır. Bu tezde AOMS'ler araştırma konusu olarak ele alınmıştır.

Birçok araştırmacı tarafından kabul görmüş, temassız, sensör tabanlı bir teknoloji olan optik muayene sistemleri hem esnek hem de yüksek doğrulukta olma avantajlarına sahiptir. Bu nedenle, ürün yüzey muayenesinin otomatik gerçekleştirilmesi ve kusurlu ürün oranlarının azaltılması amacı ile yaygın olarak kullanılmıştır [1]. Yaygın olarak, optik muayene birkaç adımdan oluşur. İlk olarak, bir dijital kamera kullanılarak, ışıktandırılmış koşullar altında ürün yüzeyinin “doku görüntüsü” adı verilen bir görüntüsü çekilir. Ardından, çekilen görüntünün ilgilenilen bölgesi, şablon eşleştirme yöntemleri ile belirlenir [2–4]. Daha sonra optik bir muayene yöntemiyle görüntüdeki dokunun kusurlu veya kusursuz olduğuna karar verilir. Kusurlu dokular daha sonra kusur tiplerine göre sınıflandırılır. Optik inceleme teknolojileri kusurların

birçoğunu etkili bir şekilde tespit edebilir fakat sadece optik inceleme ile bütün kusurlar tespit edilemez. Genellikle tüketiciler ürünlerin belirli bir kalitede olmasını talep etmektedir. Hataların sayısı, yeri, boyutu ve türü ürünün kalitesini belirler. Dolayısıyla, OMS'lerinden kusurların şekli ve lokalizasyonu ile ilgili detaylı raporların çıkarılabilmesi beklenmektedir. Ayrıca, üretim hattındaki arızalı süreçleri tespit etmek ve önlemek için kusurlarla ilgili bilgiler de kullanılabilir. Bu nedenle, bir OMS, kusurlardan kapsamlı analizler çıkarabilmelidir.

Basit uygulamalarda başarılı olmalarına karşın orta ve düşük seviyeli istatistiksel yaklaşımlar ince renk geçişleri ile gizlenen kusurları algılamakta yetersiz kalmaktadır. Bu nedenle, birçok farklı kumaş kusur çeşitliliğinin algılanabilmesi için diğer gürbüz ve verimli görüntü işleme yaklaşımlarını araştırılması önemlidir. Tekstil kumaşları basit desenlerin tekrarlanması ile oluşur. Dolayısıyla doku görüntüleri periyodik gri seviyeli görüntülerdir. Doku görüntülerinin bu özelliği spektral yaklaşımlar ile kusurların tespiti için önemli bir şarttır. Bununla birlikte, rastgele dokulu görüntüler skolastik gri seviyeli dağılımlardan oluşmaktadır, tekrarlamalardan ve periyodiktikten bahsedilemez. Bu nedenle, spektral yaklaşımlar rasgele dokulu malzemelerdeki kusurların saptanması için uygun değildir. Fourier dönüşümü sinyalleri ayrıştırarak farklı frekanslardaki birçok sinyalin toplamı olarak ifade etmek için kullanılan bir metottur [5, 6]. Görüntüler üzerinde tekrar eden gri piksel dağılımlarını ortaya çıkararak kusur algılamak için gerekli anlamlı bilginin ayıklamasını sağlar. Popüler kullanımı olan bu yöntemin en büyük eksiği frekans dağılımı hakkında doğru sonuçlar verirken bu frekanstaki dağılımların görüntünün neresinde olduğu hakkında bilgi veremez. Bu eksikliği gidermek için Wavelet dönüşümü kullanılabilir [7, 8]. Bu dönüşüm görüntü üzerindeki gri seviye dağılımının hem frekans spektrumunu hem de spektrum bileşenlerin görüntü üzerinde nerede olduğunu geçici bir aralık için hesaplayabilir. Fakat bu metot kullanılarak görüntü üzerindeki desenleri ifade etmek kolay değildir. Bazı durumlarda, açılal frekans bant genişlikleri ve merkez frekansı olan Gabor filtreleri Fourier ve Wavelet dönüşümlerine göre görüntü üzerindeki kusurları incelemek için daha uygun olabilmektedir [9, 10].

Görüntü üzerinde kumaş kusurlarıyla ilgisi olmayan bilgilerin yukarıda anlatılan dönüşümler kullanılarak elenmesi kusurların daha sağlıklı algılanması ve tanınması için önemlidir. Kusur algılama gibi uygulamalarda en basit ve en çok kullanılan metotlardan biri eşik değeri belirleme yöntemidir. Bu yöntemde dönüşümden sonra oluşan görüntüde kusurların varlığına gri seviyesinin eşik değerlerin aşıp aşılmadığına bakarak karar verilir. Gürültülerden çok etkilenen bu metoda alternatif olarak görüntülerin istatistiksel parametreleri ile iki görüntü arasında kıyas yapabilen Çapraz Korelasyon (Cross Correlation) metodu kullanılabilir. Bu metot ile kusursuz olan bir görüntü referans alınıp incelenen görüntü ile arasındaki istatistiksel

parametrelerin benzerliklerini ölçülür ve kusur olup olmadığına karar verilir. Bu iki yöntem gürültünün az olduğu görüntülerde kusurların varlığı algılamakta yeterli olmasına karşılık kusurları tanımlamada bir hayli yetersizdir. Tanımlama problemini çözmek için karmaşık karar sınırları oluşturabilen yapay sinir ağları hem az işlem yükü hem de kolaylıkla eğitilebilir olmasından dolayı çok rağbet görmüştür. Günümüzde bulut bilişim teknolojisi gibi gelişmiş veri işleme yeteneklerini kullanarak daha fazla veri işlenebilmesi daha karmaşık sinir ağları oluşturulmasının ve eğitilebilmesinin önünü açmıştır. Daha fazla katmanlar ve katmanlar içerisinde hem ileri hem geri hem de kendi katmanına bağlanabilen nöronlardan oluşan derin öğrenme metotları kullanılmaya başlanmıştır [11, 12].

Üretim hattında muayene edilen ürünler, üretimin zamanla değişmesinden dolayı doku olarak farklı olan güncel ürünlerle değiştirilebilir. Bu nedenle, OMS bu yeni ürünlere uygulanabilir veya hızlı ve kolay bir şekilde ayarlanabilir olmalıdır. Lizarraga-Morales vd. hem kusurlu hem de hatasız görüntülerden ikili özniteliklerin çıkarılmasını ve bu şekilde belirli desenlere sahip tekstiller üzerindeki kusurların tespit edilmesini sağlayan kaba küme tabanlı kurallar önermişlerdir [13]. Yine Kusurların tespiti için Li vd. sınırlı hatasız örneklerle eğitilebilen Fisher kriteri tabanlı istiflenmiş gürültü giderme otokodlayıcılarını önermişlerdir [14]. Luo vd. ise çeşitli imalat endüstrilerine uygulanabilecek seçici baskın yerel ikili örüntüler yaklaşımını önerdiler [15]. Wang vd. görüntünün düşük ranklı yapısını ihlal eden nadir kusurları belirlemek için bir varlık seyrekliği arayışı önerdiler [16]. Alipour ve Harris, çeşitli malzemelerde çatlak tespiti yapılabilmesi için malzemeye özgü derin öğrenme modellerinin gürbüzlüğüne geliştirilmesini önerdi [17]. Bu yöntemlerin en önemli eksikliği, bu modelleri eğitmek veya ayarlamak için büyük bir veri kümesinin gerekli olmasıdır.

Son zamanlarda, derin evrişimsel sinir ağları (DCNN), algılama, segmentasyon ve izleme dahil olmak üzere çok çeşitli makine öğrenmesi uygulamalarında olağanüstü performanslar göstermiştir. DCNN yapılarının başarısından ilham alan, evrişimsel otokodlayıcı ağı (CAE) [18], yerel bölgeler arasındaki ağırlıklarını paylaşmak için DCNN'ler kullanmaktadır ve çok katmanlı perceptrona (MLP) dayanarak geliştirilmiştir. Bir CAE ağı birkaç işlemde oluşur. Öznitelik çıkarma ve veriyi kodlama işlemi evrişim katmanlarını kullanarak giriş görüntüsünün özniteliklerini çıkarır ve ardından bunları tam bağlı katmanlar halinde bir öznitelik koduna indirger. Kod çözme ve yeniden yapılandırma adımlarında, öznitelik kodu ilk önce tam bağlı katmanlar kullanılarak bir öznitelik haritasına dönüştürülür ve daha sonra öznitelik haritası ters evrişim katmanlarını kullanarak giriş görüntüsüyle aynı olacak şekilde yeniden yapılandırılır. Bir CAE, yeniden yapılanma kaybını optimize ederek, örneğin yeniden oluşturulmuş görüntü ile girdi görüntüsünün farkından hesaplanan ortalama

kare hatasının en aza indirilmesiyle eğitilebilir. Ke vd. bir şablon üretmek için CAE'ye dayalı bir yapı önermiş ve daha sonra test görüntülerini uyarlanabilir şablonlarla karşılaştırarak anormal bilgileri tespit etmişlerdir [19].

Vincent vd. eğitim sırasında kısmen bozulmuş bir görüntüden orijinal görüntüyü elde edebilen gürültü giderici otokodlayıcı (DAE) olarak isimlendirdikleri bir AE önerdiler [20]. Benzer şekilde, evrişimsel DAE (CDAE), tuz veya karabiber gürültüsü kullanılarak tahrip edilen görüntüden temiz bir görüntü oluşturabilir. Li vd. CDAE'den yararlanabilmek için, yalnızca sınırlı kusur verisi mevcut olduğunda iyi performans gösteren bir temsil önerdiler [21]. Chalapathy vd. anomalileri saptamak için güçlü CAE (RCAE) yöntemini önerdiler [22]. Bu yaklaşım, bir dizi gerçek dünya veri setinde iyi performans elde etmeyi başardı. Mei vd. sadece kusursuz yamalar kullanılarak eğitilebilen çok ölçekli bir CDAE (MSCDAE) yöntemi önerdiler [23]. MSCDAE yöntemi, çok ölçekli kusur incelemesini gerçekleştirmek için üç katmanlı bir piramit kullanır. Bununla birlikte, MSCDAE yöntemi her katman için eğitilmek ve test edilmek üzere ayrı model gerektirir; bu nedenle zaman alıcıdır ve aşırı bellek kullanımına neden olur.

Endüstriyel üretimde kullanılan sistemler, kusurları en aza indirecek şekilde tasarlandığından, eğitim için ürünlerden yeterli sayıda kusurlu görüntünün elde edilmesi zaman alan ve zor bir süreçtir. Son zamanlarda araştırmacılar, çok amaçlı akıllı OMS'leri geliştirmek için kusurlu verilere ihtiyaç duymayan sistemler kavramını ortaya atmışlardır. Lian vd. sınıflandırıcıların performansını artırmak için görüntüler üzerinde çok sayıda kusurlu örnek oluşturmak için üretken çekişmeli ağlar (GAN) kullanmayı önerdiler [24]. Aynı amaç için, Sun vd. uyarlanabilir çok ölçekli görüntü toplama yöntemi ile aktarım öğrenimi kullandılar [25]. Negatif numuneler olmadan kusurları tespit etmek için Jia vd. hatasız örneklerden öğrenilen şablon istatistiklerine göre görüntüyü karelere bölmeyi ve görüntü benzerliğini ölçmeyi önerdiler [26]. Benzer şekilde, Kang ve Zhang, kumaşlardaki kusurları tespit etmek için bütünleşik görüntü üzerinde Elo derecelendirme algoritmasını kullanmayı önerdiler [27]. Aynı amaç için, İstiflenmiş Gürültü Gideren Evrişimli Otokodlayıcı [28] veya Derin Evrişimli üretken çekişmeli ağlar [29] gibi denetimsiz derin öğrenme yöntemlerini içeren diğer bazı araştırmalar da yapılmıştır.

Yukarıda belirtilen yöntemler ilk aşamada problemi çözmede yeterli olsalar bile sistemi çalışır durumda tutmak için halen önemli miktarda insan müdahalesi gerekmektedir. Yang vd. bu sorunu çözmek için yalnızca hatasız örnekler kullanarak hızlı ve doğru özellikli çok ölçekli öznetelik-kümeleme tabanlı evrişimli otokodlayıcı yöntemi önerdiler; daha az insan müdahalesi ile yüksek doğrulukta kusurların tespiti sağlayabildiler [30]. Benzer şekilde, Mei vd. farklı Gauss piramit seviyelerinden

oluşan denetimsiz-öğrenme tabanlı evrimsel gürültü giderici otokodlayıcı ağlarının kullanımını önerdiler [31]. Bu güncel yöntemlerin dahi eğitim sürelerinin uzunluğu, sunulan ağların boyutunun büyüklüğü ve performansı test etmek için kullanılan veri kümelerinin oldukça basit tutulması gibi eksik yönleri bulunmaktadır.

Yapısı gereği anormal verilerin miktarının normal verilere göre çok az olması dengesiz veri sınıflarına sebep olmakta ve temel işlevi verileri sınıflandırmak olan yapay sinir ağlarının anomali tespiti alanında kullanımını zorlaştırmaktadır. Aktarım öğrenmesi yöntemi kullanılarak gerekli olan eğitim verisinin miktarı azaltılabilse de, yine de anormal veriler eğitim için yeterli değildir. Ek olarak, sıradan veri örneklerinin kendi içlerinde çok varyasyon göstermesi otokodlayıcı tabanlı yapıların yeterli başarıya ulaşmasına engel olmaktadır. Veri sınıflandırma ve dağılımını kestirmede çok yetenekli olan yeni üretken çekişmeli ağlar anomali tespiti uygulamaları için ümit vadetmektedir.

Üretken çekişmeli ağlar, Goodfellow tarafından 2014 yılında ortaya atıldıktan sonra birçok araştırmacının dikkatini çekmeyi başardı [32]. Basitçe, GAN modelleri, eğitim verisinin dağılımını keşfetmek için birbirleriyle çekişmeli bir oyun oynayan bir üretici ve bir sınıflandırıcı yapay sinir ağından oluşur. Sınıflandırıcı girdinin gerçek veya sahte olup olmadığını ayırt etmeye çalışırken, üretici eğitim verilerinin dağılımına benzeyen gerçekçi görüntüler oluşturmaya çalışmaktadır. GAN'lar ve farklı varyasyonları, görüntü işleme, görüntü dönüşümleri, video ve 3D görüntü oluşturma gibi görevlerde yaygın olarak kullanılmaktadır. Haliyle, bu kadar yetenekli bir yapı araştırmacılar tarafından endüstriyel sistemlerdeki zor görevleri çözmek için çokça önerilmiştir.

Teknolojinin ilerlemesi ve sanayinin isteklerinin gelişmesi ile beraber çoğu görüntü işleme problemi Evrimsel sinir ağları ile çözülmeye başlandı. Evrimsel sinir ağlarının görüntülerdeki anomalileri tespiti için eğitilebilmesi için çok az sayıda hem anomali barındıran görüntü hem de normal görüntüye ihtiyaç duymaktadır. Anomali barındıran görüntüler tanımları gereği çok az sayıda bulunmaktadır. İki sınıf arasındaki bu dengesizlik sinir ağlarının eğitimi imkansız kılmaktadır. Bu sorunun önüne geçebilmek için GAN yapısının gerçekçi görüntüler üretebilme yeteneğinden yararlanılması birçok araştırmacı tarafından önerilmiştir. Hu vd. çelik yüzey kusurlarının sınıflandırılması için koşullu derin evrimsel GAN (cDCGAN) ve Resnet18 yapay sinir ağlarının kullanıldığı yarı güdümlü bir eğitim metodu önermişlerdir [33]. Bu yöntem sınırlı olan etiketli eğitim verisinin cDCGAN ağından üretilen yeni örnekler ile artırılması hedeflemiş ve bu sayede eğitilen resnet18 ağına performansının artırılmasını sağlamıştır. Benzer şekilde Zhang vd. dengeli eğitim kümeleri oluşturabilmek için Wasserstein GAN (WGAN) tabanlı veri üretim yaklaşımını önermişlerdir [34]. Lu vd. eğitim setindeki kusurlu ve kusursuz görüntülerin sayılarını

dengeleyebilmek için GAN yapısına pix2pix'i entegre etmeyi önermiştir [35]. Bu düşünceyi bir adım öteye taşıyan Niu vd. sadece kusursuz görüntüler kullanarak çok çeşitli kaliteli yüzey kusurlu görüntüleri elde etmek amacıyla Yüzey Kusuru GAN (SDGAN) yapısını önermiştir [36]. Liu vd. ise kusur oluşturmak için eğitilmiş bir GAN ve desen oluşturmak için eğitilmiş bir başka GAN kullanarak iki aşamada bol miktarda kusurlu görüntü oluşturmayı önermişlerdir [37]. Lian vd. yüzeylerdeki küçük kusurları tanımlamakta kullanılan çeşitli sınıflandırıcıların doğruluğunu arttırmak için abartılmış kusur yöntemini önermiş ve abartılı örnekler üretmek için Çekişmeli Ağlardan yararlanmıştır [38].

Genelde iki aşamadan oluşan bu veri üretimi yöntemi yerine Bian vd. WGAN kayıp fonksiyonu ile eğittikleri koşullu varyasyonel otokodlayıcı yapısı ile restore edilen görüntülerin yapı benzerlik indeksi ölçümü (SSIM) ve L1-norm farklarının toplamından oluşan skorlardan anomalileri tespit etmeye önerdiler [39]. Mao vd. standart GAN yapısındaki sınıflandırıcı ağının çıkışını bir vektör olarak genişlettiler ve Pearson Kayıp Fonksiyonu ekleyerek sınıflandırıcı/kodlayıcı olarak kullanılabilen bir ağ üzerinden restore edilen görüntülerin anomali skorlarını hesaplamayı önerdiler [40]. Lyu vd. anomali skorunu hesaplamak için GAN üretici ağın ve sınıflandırıcı ağın kayıpları kullanmayı önermişlerdir [41]. Kuang vd. akciğer kitlelerinin iyi huylu ve kötü huylu sınıflandırması için GAN kullanmışlar ve yüksek sınıflandırma başarısı elde etmişlerdir [42].

Günümüzde anomali içeren görüntülerin tespit edilmesinin yanı sıra anomalilerin piksel bazında sınıflandırılması daha büyük önem kazanmıştır. Piksel bazında sınıflandırma görüntü içerisindeki anomali hakkında boyut ve lokasyon gibi ihtiyaç duyulan birçok bilgiyi sağladığı için tercih edilmektedir. Komoto vd. kusurlu görüntüleri kusursuz olarak restore edebilmek için GAN yapısını gürültü giderici ağlara uygulamıştır [43]. Schlegl vd. anomali GAN (ANOGAN) adını verdikleri yapıda önce GAN yapısını eğitip, daha sonra bu yapı sayesinde görüntü uzayından kod uzayına haritalama yapan bir kodlayıcı ağı eğitmeyi önermişlerdir [44]. Hu vd. DCGAN yapısını sadece kusursuz desenleri kodlamak için eğitilmiş bir kodlayıcı ağı ekleyerek geliştirmiş ve bu sayede kusurların lokasyonlarını da tespit etmeyi önermiştir [45]. Lin vd. DCGAN yapısındaki sınıflandırıcı ağını geliştirerek gerçek hataları restore edebilen bir ağa dönüştürdüler, oluşturulan DEGAN adını verdikleri yapıya daha hızlı optimize olması ve daha net görüntüler oluşturabilmesi için kusur netleştirme algoritması eklediler [46]. Skilton vd. tekrar üretici - kodlayıcı olarak eğittikleri GAN yapısını kodlayıcı - tekrar üretici olarak çalıştırmış ve yeniden oluşturulmuş görüntü ile orijinal giriş görüntü arasındaki fark üzerinden anomalileri bulmayı önermiştir [47]. Niu vd. CycleGAN adını verdikleri yapıyı kullanarak kusurlu görüntüler uzayı ile kusursuz görüntüler uzayında arasında dönüşüm yapabilen ve

beraber eğitilen iki GAN yapısı önerdiler ve daha sonra adına DefectGAN ismini verdiler [48].

1.2 Tezin Amacı

Bu tezin amacı, hâlihazırda geliştirilmiş otomatik kumaş muayene sistemlerinin yerli olarak geliştirmek ve farklı kumaşlar için kolaylıkla yeniden ayarlanabilen, kusurlu örnekler gerektirmeyen akıllı otomatik optik kumaş muayene sistemi geliştirebilmek için,

- yüksek teknolojiye sahip, performans açısından optimal bir optik görüntüleme sistemi oluşturmak,
- bilgisayar ortamında yüksek hata algılama oranına sahip, kusur barındırmayan dokular ile eğitilebilen bir metot geliştirmek,
- tasarlanan metotların gerçek zamanlı çalışmaya uygun hale getirmektedir.

Bu doğrultuda,

- küçük boyutlu hataları yakalayabilen, yüksek çözünürlük ve hızlı çekim özelliğine sahip maliyeti düşük bir kamera ve bütün kusurları belirgin hale getirebilen uygun ışıklandırma düzeni belirlenecektir,
- desenli ve desensiz kumaşların üzerindeki önemli kumaş kusurlarını %90 algılama oranına ve yüksek segmentasyon başarısına sahip bir metot geliştirilecektir,
- öznetelik seçimi gerektirmeyen ve daha az işlem yükü olan derin öğrenmeyi kullanılacaktır,
- tasarlanan metodun yüksek bant hızlarını destekleyebilecek şekilde gerçek zamanlı çalışmaya uygun olması sağlanacaktır.

1.3 Orijinal Katkı

Bu tez kapsamında geliştirilen yöntemler ve sistem aşağıdaki sebeplerden dolayı özgündür:

- Deseni tekrar eden dokulu ve dokusuz kumaşlar üzerinde oluşabilen çok sayıda farklı kusuru tanıtmaya gereksinimi olmadan yüksek doğrulukla tespit edebilme yeteneğine sahiptir,
- Literatürde yüksek hata algılama oranına sahip birçok kumaş kusur muayene metodu önerilmiştir. Fakat bu metotlar yüksek işlem yükü sebebi ile gerçek zamanlı çalışmaya uygun değildirler. Bu metotların aksine, önerilen metotların işlem zamanı az, kullanılabilirliği yüksek ve kullanımı sırasında uzman gerektirmemektedir,
- Var olan yöntemlerde farklı kumaş ve kusur çeşitleri için hazırdaki sistemlerin geliştirilmesi gerekmektedir. Yeni üretilecek her çeşit kumaş için üreticinin muayene sistemini tekrar geliştirmesi ve dolayısıyla yatırım yapması gerekmektedir. Bu tezde tekrar eden desenli ve desensiz kumaş kusurlarını offline olarak kusursuz kumaşlardan kolayca öğrenebilen ve devamında online olarak kusurları algılayabilen, tanımlayabilen ve yerini piksel hassasiyet ile saptayabilen bir sistem geliştirilmiştir.

2 KUMAŞ MUAYENE SİSTEMLERİ


Muayene sürecinin amacı, var ise meydana gelen hataları veya kusurları tespit etmek, daha sonra uygun şekilde parametreleri değiştirmek veya imalat sürecinin kontrol etmesi için uyarı üretmektir [49]. Modern tekstil endüstrisinde kumaşların optik muayenesi, tekstil ve moda ürünlerinin kalite kontrolünde önemli bir rol oynar çünkü kumaş üzerindeki kusurlar, maliyetler ve nihai ürünlerin derecelendirilmesi üzerinde büyük bir etkiye sahip olabilir. Hazır giyim endüstrisinde bulunan ikinci kalite ürünlerin yaklaşık %85'inin sebebi kumaş kusurlarıdır[50]. İkinci kalite ürün birinci kalite kumaş fiyatının sadece %55-65'ine satılabilmektedir bu da üreticiler için gelir kaybı anlamına gelir [51]. Bu nedenle, düşük kaliteli üretim yapılmasını önlemek için kumaş muayenesi önemli bir önceliktir. Temel olarak, kumaş kusur tespiti, iki tip inceleme modeli kullanır. Birincisi insan tabanlı muayene sistemleri (IMS). İkinci sistem ise otomatik optik muayene sistemleridir (OMS).

2.1 Kumaş Kusurları

Kumaşlar, insanları her türlü dış etmenden korumak için tasarlanmış en eski ve en kullanışlı eşyalardan biridir. Tekstil üretimi, lifleri kumaşa dönüştüren bütün yöntemleri içerir. Sürekli ve artan talepleri karşılamak için çok sayıda kumaş türü ve üretim tekniği ortaya çıkmıştır. Örme, dokuma, dokusuz yüzey olarak bilinen dört ana tekstil yapısı vardır. Örme ve dokuma durumunda, önce lifler ipliklere dönüştürülür, daha sonra imalatla kullanılır. Dokusuz yüzeyler ise doğrudan liflerden üretilir.

Örme tekstiller çeşitli desenlerde birbirine geçen ilmeklerle üretilir. Örme tekstillerin aksine, dokuma tekstiller en az iki iplik sisteminin birbirleriyle belli bir düzen içinde ve dik açı oluşturarak bağlantı yapmalarıyla üretilen tekstil ürünüdür. Sonuç olarak, dokuma tekstiller diğer tekstil yapılarına kıyasla daha güçlüdür ancak daha az esneklik gösterir. Dokunmamış kumaşlar 3D yapılar oluşturmak için liflerin rastgele bir şekilde yerleştirilmesiyle üretilir. Bu üç yapı en sık görülen ve kullanılan tekstillerdir, ancak her kategoride birçok varyasyon bulunmaktadır.

Kumaşlar ipliklerden ve liflerden oluşur. Kumaşların yapıları, ipliklerin simetrik ve periyodik örülmesinin bir ürünü olarak ortaya çıkmaktadır. Genel olarak iplikler, çözgü ve atkı iplikleri olarak adlandırılan birbirine dik iki grup olarak sınıflandırılır. Kumaşların boyu yönündeki iplikler çözgü iplikleri, kumaşların eni yönündeki iplikler atkı iplikleri olarak adlandırılır. Dokuma kumaşlar endüstriyel üretim ile en çok üretilen kumaşlardır.



Şekil 2.1 Örnek kumaş kusurları

Kumaş kusurları, kumaş deseninde meydana gelen bozulmalar olarak tanımlanır. Bozulmalar, çözgü ve atkı ipliklerinde, ipliklerin yoğunluklarında veya çözgü ve atkı iplikleri arasındaki boşluklarda değişikliğe neden olur. Otomatik optik muayene sistemleri olağandışı değişiklikleri algılar. Daha sonra kusurların varlığını ve yerlerini tespit ederler. Kumaş üretimi, iplik üretiminden başlayan birçok aşamada gerçekleşir. İplik imalatında, lifler iplik oluşturmak için işlenir. Ancak liflerin

doğal yapısı veya eğirme işlemleri liflerde incelme, kalınlaşma, yırtılmalara neden olabilir, bu yapısal değişiklikler kumaş desenlerinde bozulmalara neden olur. İplik imalatından sonra, iplikler dokuma tezgahı kullanılarak dokunmaktadır. Aynı zamanda, tezgâhların keskinliği, makinelerin taraklarının anormal hareketleri de kusurlara neden olabilmektedir. Şekil 2.1’de örnek kumaş kusurları gösterilmiştir [52].

Kumaşlar üretim aşamasında birçok işlemten geçer. İşleme aşamalarında farklı makineler ve teknikler kullanılmaktadır. Çok farklı işlemlerden geçen kumaşlar üzerinde oluşan değişken kuvvetler ve gerilimler kusurlara neden olabilir. Kusurlar şekillerine ve yönlerine göre farklı isimler alırlar. Kumaşlarda çok sayıda farklı kusurların oluşabilmesinden ve bu kusurların da çok farklı özelliklerinin olabilmesinden dolayı kumaş kusurların tespitini zor bir görevdir. Aynı zamanda, kusurlar kumaş görüntüleri üzerinde rastgele dağılır, bu nedenle kusurlar görüntünün her tarafında bulunabilmektedir.

2.2 İnsan Tabanlı Muayene Sistemleri

Modern tekstil endüstrisinde kumaşlar çok karmaşık şekilde üretilebilmektedir, ayrıca gelişmiş makineler ile kumaşlar kısa sürede dokunabilmektedir. Bu durumlara ek olarak kumaşlar dış etkenlerden etkilenmeye çok müsaittir. Sonuç olarak muayene süreci oldukça zor ve karmaşık bir süreçtir [53]. Günümüzde halen çoğunlukla insana dayalı muayene sistemleri kullanılmaktadır. İmalattan sonra, dokunan kumaşların kontrolü için muayene tezgahları kullanılmaktadır. Farklı tipte muayene tezgahları olsa da çalışma prensipleri aynıdır. Bir milden diğerine kumaş sarılırken bir denetçi kumaşları kontrol eder. Denetçi, hareketli kumaşta bir kusur fark ettiğinde, kusuru ve yerini kaydeder. Muayene işlemi sırasında, operatör çok fazla kusurla karşılaşarsa, müfettiş, hataların derhal düzeltilmesi için üretim departmanını uyarır. Ya dokuma makinesine yeni parametre girilir ya da üretim durdurulur. Şekil 2.2’de örnek bir insan tabanlı muayene sistemi gösterilmiştir [54].

2.2.1 Geleneksel Kumaş Kontrol Teknikleri

Hataların boyutlarına ve ciddiyetine dayanan çeşitli kumaş kontrol sistemleri bulunmaktadır. Kumaş muayenesi için yaygın olarak kullanılan sistemlerden birisi Dallas sistemidir. 1970 yılında özellikle örme kumaş için geliştirilmiş ve bu sistem Dallas Manufacturers Association tarafından onaylanmıştır. Bu sistemde, bitmiş bir giyside herhangi bir kusur bulunursa, giysi ikinci kalite olarak adlandırılır. Bu sistem ikinci kalite kumaşı her 10 yardlık (9.14 metre) uzunluk için birden fazla kusur



Şekil 2.2 İnsan tabanlı muayene sistemi

bulunduran kumaşlar olarak tanımlar. Örneğin, 60 yard uzunluğundaki bir parçanın en fazla altı kusura sahip olmasına izin verilir.

Graniteville “78” sistemi, kumaş tesviye alanı için 1975 yılında tanıtıldı. Sistem, kusurları büyük ve küçük olmak üzere ikiye ayırır. Büyük kusurlar, çok belirgindir ve ürünlerin ikinci kalite olmasına sebep olan kusurlardır. Küçük kusurlar ise, kumaşlardan üretilecek olan ürüne ve kusurun konumuna bağlı olarak kumaşın ikinci kalite olmasına neden olabilecek kusurlardır. Kumaşların kalitesi kusur büyüklüklerine göre verilen ceza puanlarına bağlıdır.

4 noktalı kontrol sistemi, tekstil ve konfeksiyon endüstrisindeki tüm kumaş türleri için en yaygın olarak kullanılan kumaş kalite kontrol sistemidir. Kumaş kalitesini belirlemek için Amerikan Giyim Üreticileri (AAMA) puan derecelendirme sistemi olarak da adlandırılan 4 puanlık sistem, AAMA ve ASQC (American Society for Quality Control) tarafından onaylanmıştır. 4 puanlık sistem hatanın boyutuna ve önemine göre 1, 2, 3 ve 4 ceza puanı verir. Herhangi bir tek kusur için 4'ten fazla ceza puanı verilemez. Kusur uzunluk veya genişlik yönünde olabilir, sistem aynı kalır ve yalnızca büyük kusurlar dikkate alınır. Küçük kusurlara ceza puanı verilmez. Bu sistemde sevkiyattaki toplam ruloların en az %10'u kontrol edilmeli ve her renk yolundan en az bir rulo seçildiğinden emin olunmalıdır. Her 100 yardlık kumaş için toplam hata

puanı hesaplanır, eğer kumaş ruloları 100 metrekarede 40'tan az ceza puan içeriyorsa, birinci kalite olarak kabul edilir ve bir kabul kriteri olarak kabul edilir. 40'tan fazla ceza puan içeren kumaş rulolar ikinci kalite olarak kabul edilir.

10 noktalı muayene sistemi, rulo başına kalite derecelendirmesi için ölçülebilir bir kılavuz sağlayan sistemdir. 1955'lerde Tekstil Distribütörleri ve Ulusal Tekstil Federasyonu tarafından uyarlandı. Sistem, her kusura boyutuna göre ceza puanı verir. 10 puanlık sistemde, eğer toplam ceza puanları parçanın toplam yardasını geçmiyorsa, bir parça birinci kalite olarak derecelendirilir. Toplam ceza puanı, parçanın toplam yardasını aşarsa, bir parça ikinci kalite olarak derecelendirilir. Bu sistem, çözgü ve atkı hataları için uzunluk başına noktalar farklı olduğu için pratikte kullanımı biraz karmaşık ve zordur.

2.2.2 İnsan Tabanlı Muayene Sistemlerinin Dezavantajları

Tekstil endüstrisinde muayene sürecinin uygulandığı ilk günden itibaren insan tabanlı muayene sistemleri tüm gereksinimleri karşılamaya yetmiştir. Muayene sürecinde hala insan gücü kullanılmasına rağmen, modern dokuma makineleri sayesinde üretim hızı ve üretim örüntü boyutu bir hayli arttırılabilir. Bu nedenle, insan temelli muayene, insanın fizyolojik doğasından kaynaklanan sınırlamalar nedeniyle günümüzde artan üretim hızlarını ve kalite standartlarını karşılama kabiliyetine sahip değildir. Araştırmalar, insan tabanlı muayene sistemlerinin kusurların sadece %60-70'ini tespit edebildiğini göstermektedir. Bununla birlikte, insan tabanlı muayene sistemleri (IMS) birçok dezavantaja sahiptir. Bunlar şu şekilde sıralanabilir:

- İyi bir denetçinin eğitilmesi zaman alır.
- En iyi denetçiler için bile, insan vücudunun sınırları nedeniyle muayene zor ve yorucu bir görev haline gelir.
- İnsan algılama hızı makinelere göre daha yavaş olduğundan üretim süreci uzar.
- İnsan denetçilerin odaklanma zamanları sınırlıdır, çünkü insanlar hızlı yorulur ve sıkılır. Bu nedenle, görev süreleri uzadıkça denetçilerin kusurlu bölgeleri algılama performansları düşer.
- Denetçiler 1.6—2 metre enindeki kumaşları 20 m/dk hızla kontrol edebilmelidir [55]. Bu hızlar insan yetenekleri için zor bir görevdir.
- İnsana dayalı muayene sistemleri hiçbir zaman %100 tespit oranına ulaşamaz.
- İnsan muayene sistemleri daha az maliyetli görünse de, kusurları bulma konusunda sınırlıdır.

Sonuç olarak, tespit edilmeyen kusurlar kumaşların karını azaltır. Bu dezavantajlar üstesinden gelebilmek ve üretimi en üst kapasiteye getirebilmek için, kumaş kalitesinin en nesnel ve en güvenilir değerlendirmeye tabi olması gerekmektedir. Bu sebeple otomatik optik muayene sistemleri geliştirilmekte ve yaygınlaştırılmaktadır.

2.3 Otomatik Kumaş Muayene Sistemleri

İnsan tabanlı muayene sisteminin yüksek maliyeti, düşük performansı ve yavaş denetleme hızları otomatik muayene sistemlerine olan ilgiyi artırmıştır. Bu nedenle günümüzde otomatik muayene sistemleri üzerinde daha fazla araştırma yapılmaktadır. Otomatik optik muayene sistemleri, insan tabanlı muayene sistemlerine göre hassasiyeti, kararlılığı ve hızı artırmak için tasarlanmıştır. Bunun yanında otomatik optik muayene sistemleri yüksek hata tespit oranları da sağlamaktadır. Ayrıca bu sistemler işçilik maliyetlerini düşürür, ürün kalitesini iyileştirir ve üretim verimliliğini artırır.

Genelde normal dokuma kumaşların görüntülerinde kumaş oluşumunda kullanılan dokuma işleminin özelliklerinden dolayı yüksek bir periyodiklik sergileyen bir doku hakimdir. Bir kusur varsa, kumaşın yerel düzenliliği bozulacak ve homojen örüntüye karşı bir anormallik ile sonuçlanacaktır. Bilgisayarlı görme tekniklerinde kusur, homojen dokuda oluşan herhangi bir anormallik olarak tanımlanır. Bu tanım araştırmacıların algılama algoritmaları tasarlaması için bir temel oluşturur. Otomatik kumaş muayene teknikleri temel olarak istatistiksel, spektral ve model tabanlı olmak üzere üç kategoride incelenebilir.

2.3.1 Sistem Bileşenleri

Kumaşların otomatik optik muayenesi için kumaş yüzeyinin görüntüleri dijital ortama sağlıklı bir şekilde aktarılmalıdır. Genelde gerçek zamanlı otomatik muayene sistemlerinde CCD (charge-coupled device) kameraları veya CMOS (complementary metal oxide semiconductor) kameraları ve görüntü alma işlemi için kullanılan bir görüntü yakalayıcı kullanılmaktadır. Son zamanlarda gelişen teknoloji ile beraber GigE (Gigabyte Ethernet) kameralarda kullanılmaya başlanmıştır. Endüstriyel kameralar çizgi tarayan kameralar ve alan tarayan kameralar olmak üzere iki farklı tipte bulunmaktadır. Alan taramalı kameralar bir alan dizisi fotoğraf sensörleri sistemi kullanır. Bu sistem görüntüye tek seferde yakalama avantajına sahipken görüntüyü bir tarama şeklinde yakaladığından tarama sırasında kumaşların hareketli olması sebebiyle görüntüde bozulmalar oluşabilir. Çizgi tarama kamera ise doğrusal dizili foto sensör sistemleri kullanır, bu nedenle doğrusal dizili foto sensör sistemleri, daha

yüksek bir çözünürlük sağlayabilir. Bu sistemin dezavantajı ise kamera tarama hızının ürünün taşıma hızı ile senkronize edilmesi gerekmesidir. Genellikle kumaşın akışı bir enkoder yardımı ile ölçülür ve kameralar enkoderden gelen veri ile senkronize edilir.

Gerçek zamanlı otomatik muayene sistemlerinde hata tespiti için çözünürlük önemlidir. Sensör tipleri, çözünürlük, okuma hızı, doğruluk ve diğer özellikler arasında muazzam farklılık olan çok sayıda kamera, makine görmesi uygulamalarında yer bulmaktadır. Kameranın çözünürlüğü, kameranın sensöründeki piksel sayısı ve kameranın görüş alanı ile doğru ilişkilidir. Kameranın görüş alanı, arka planın özelliklerine ve tespit edilecek kusurların doğasına bağlıdır. Görüntü çözünürlüğünün düşük tutulması hızlı bir muayene yapılmasına imkan sağlar, ancak ayrıntıların gözden kaçırılmasına ve bunun sonucunda küçük kusurların gözden kaçmasına sebep olabilir. Buna karşılık, yüksek görüntü çözünürlüğü, tüm ayrıntıların algılanmasına yol açar, ancak muayene hızını düşürebilir. Kumaş, yansıyan veya iletilen ışıktaki incelemeye izin veren iki bileşenli bir aydınlatma modülünün üzerinden geçer.


Kumaşların düzgün görüntülenebilmesi için önemli ikinci bir faktör ise ışıklandırma. Işıklendirme tipi kumaş yoğunluğuna, özel hata tiplerine veya muayenenin gerçekleştirildiği tekstil proses aşamasına bağlı olarak değişebilir. Genellikle arka veya ön aydınlatma kullanılır. Tüm bu komponentleri bir arada çalıştırmak için ve bazen de muayene algoritmasını koşturmak içinde bir kontrol sistemi bulunur. Algılanan kusurlar gerçek zamanlı olarak monitörden gösterilir ve muayene raporu için kaydedilir. Şekil 2.3'de otomatik optik muayene sisteminin genel şeması verilmiştir.

2.3.2 Görüntü Analizi

Kameralar vasıtasıyla elde edilen ham görüntülerde desen ve renk gibi birçok veri bulunmaktadır. Bu denli yoğun veri üzerinde işlem yapabilmek ve kusur algılayabilmek oldukça zordur. Sistemde ele alınan kumaşlar tekrar eden veya düz desenli olduğundan kusurlar bu tekrar eden yapıyı bozmaktadır. Dolayısıyla kumaş üzerinde monotonluğu bozan kısımların ayırt edilip incelenmesi hem işlem yükü hem de sistemin sağlıklı çalışabilmesi açısından önemlidir. Literatürde bu işlem için önerilen metotları 2 ayrı yaklaşım altında incelenebilir.

2.3.2.1 İstatiksel Yöntemler

Bu yaklaşım kumaş üzerindeki kusurlu kısımların, kusursuz kısımlara göre farklı istatistiksel özellikler taşımasından yararlanarak kusurları ortaya çıkarmayı hedeflemektedir. Kusursuz kısımların istatistiksel özelliklerin sabit olduğu bu yaklaşım



Şekil 2.3 Otomatik optik muayene sisteminin genel şeması

için önemli bir kabuldür. Bu yöntemin en büyük avantajı işlem yükünün az olmasıdır. Dolayısıyla gerçek zamanlı çalışan sistemlerde çok kullanılmış olan bu yaklaşım, gürültüye karşı olan hassasiyetinden ve farklı çeşit kusurları tanımlamada yetersiz kalmasından dolayı günümüzde tercih edilmemektedir.

2.3.2.2 Spektral Yöntemler

Ortak ve düşük seviyeli istatistiksel yaklaşımlar ince renk geçişleri ile gizlenen kusurları algılamakta yetersiz kalır. Bu nedenle, çok sayıdaki kumaş kusur çeşitliliğinin algılanabilmesi için diğer gürbüz ve verimli görüntü işleme yaklaşımlarını keşfetmek önemlidir. Tekstil kumaşları daha öncede bahsedildiği gibi basit desenlerin tekrarlanması ile oluşmaktadır. Kumaş görüntüleri periyodik gri seviyeli görüntülerdir. Spektral yaklaşımlar ile kusurların tespiti için kusur barındırmayan görüntülerin periyodik olması şarttır. Bununla birlikte, rastgele dokulu görüntüler skolastik gri seviyeli dağılımlardan oluşmaktadır, tekrarlamalardan ve periyodiklikten bahsedilemez. Bu nedenle, spektral yaklaşımlar rasgele dokulu malzemelerdeki kusurların saptanması için uygun değildir.

2.3.3 Kusur Algılanması ve Tanımlanması

Görüntü üzerinde kumaş kusurlarıyla ilgisi olmayan bilgilerin yukarıda anlatılan dönüşümler kullanılarak elenmesi kusurların daha sağlıklı algılanması ve tanınması için önemlidir. Kusur algılama gibi uygulamalarda en basit ve en çok kullanılan metotlardan biri eşik değer belirleme yöntemidir. Bu yöntemde dönüşümden sonra oluşan görüntüde kusurların varlığına gri seviyesinin eşik değerlerin aşılp aşılmadığına bakarak karar verilir. Gürültülerden çok etkilenen bu metoda alternatif olarak görüntülerin istatistiksel parametreleri ile iki görüntü arasında kıyas yapabilen çapraz korelasyon (cross correlation) metodu kullanılmaktadır. Bu metot ile kusursuz olan bir görüntü referans alınıp incelenen görüntü ile arasındaki istatistiksel parametreleri benzerliklerini ölçülür ve kusurun varlığına karar verilir. Bu iki yöntem gürültünün az olduğu görüntülerde kusurları algılamakta yeterli olmasına karşılık kusurları tanımlamada bir hayli yetersizdir. Tanımlama problemini çözmek için karmaşık karar sınırları (decision boundries) oluşturabilen yapay sinir ağları hem az işlem yükünden hem de kolaylıkla eğitilebilir olmasından dolayı popüler olarak kullanılmıştır. Günümüzde bulut bilişim teknolojisi gibi gelişmiş veri işleme yeteneklerini kullanarak daha fazla veri işlenebilmesi, karmaşık sinir ağları oluşturulmasının ve eğitilebilmesinin önünü açmıştır. Daha fazla katmanlar ve katmanlar içerisinde hem ileri hem geri hem de kendi katmanına bağlanabilen nöronlardan oluşan derin öğrenme metotları kullanılmaya başlanmıştır.

2.3.4 Otomatik Optik Muayene Sistemlerinin İsterleri ve Avantajları

Araştırmalar, minimum maliyetler harcayarak faydalı yöntemler veya sistemler tasarlamayı amaçlamaktadır. Kumaş kontrol sistemlerinin yazılımlarındaki gelişmeler, kusurların ve desenlerin daha iyi tanınmasını kolaylaştırmaktadır. Bu yüzden kumaş kusur tespit sistemlerinin en önemli parçası olarak işletim sistemi yazılımı ve kusur tespit algoritması gösterilebilir. Mevcut otomatik optik muayene sistemlerinin dezavantajları olarak, yüksek donanım ve yazılım geliştirme maliyetleri, büyük hesaplama çabalarının gerekli olması söylenebilir. Bu sistemlerin isterleri ise aşağıdaki gibi sıralanabilir.

- En önemli gereksinim, sistemlerin minimum maliyetlerle tasarlanmasıdır.
- Otomatik muayene sistemleri, gerçek zamanlı muayene koşullarının ihtiyaçlarını sağlamalıdır.
- Sistemler sadece bir kumaş deseni için tasarlanmamalı, farklı kumaş desenlerini de muayene edebilmelidir.

- Sistemler, tekstil endüstrisi ortamının kötü koşullarına hem donanım hem de yazılım olarak dayanıklı olmalıdır.
- Sistemlerin, herkesin zorlanmadan kullanabileceği kolay ve anlaşılır bir kontrol mekanizması olmalıdır.

3

DERİN ÖĞRENMENİN TEMELLERİ

3.1 Makine Öğrenmesi

Derin öğrenme, makine öğrenmesinin özel bir alanıdır. Derin öğrenmeyi anlayabilmek için makine öğrenmesinin temel ilkelerini düzgün bir şekilde anlamak gerekir. Bu başlık altında öğrenme algoritmasının ne olduğunun bir tanımı yapılmış ve örnekler verilmiştir. Ardından, eğitim setinde bulunmayan verilere de genelleştirilebilen örüntüler bulmanın eğitim verilerine eğri uydurmaktan nasıl farklı olduğunu açıklanmıştır. Makine öğrenmesi algoritmalarının büyük bir kısmında öğrenme algoritmasının haricinde belirlenmesi gereken hiperparametreler adı verilen tasarım parametreleri bulunmaktadır. Bunların nasıl belirlendiği ele alınacak ve açıklanacaktır. Makine öğrenmesi algoritmaları, denetimli öğrenme ve denetimsiz öğrenme kategorilerine ayrılabilir. Bu kategoriler bu bölümde incelenmiştir. Son olarak, geleneksel makine öğrenmesinin genelleme yeteneğini sınırlayan bazı faktörlere değinilmiştir. Bu sınırlamaların üstesinden gelebilmesi için geliştirilmiş derin öğrenme algoritmaları hakkında bilgi verilmiştir.

3.1.1 Öğrenme Algoritmaları

Bir makine öğrenme algoritması, örnek verilerden öğrenme sağlayabilen bir algoritmadır. Bir bilgisayar programının T görevindeki P ile ölçülen performansı E deneyimi ile iyileşirse, programın E deneyiminden öğrendiği söylenebilir.

Makine öğrenmesi, insanlar tarafından yazılan ve tasarlanan geleneksel programlarla çözülmesi çok zor olan görevlerin üstesinden gelmemizi sağlamaktadır. Makine öğrenmesi birçok açıdan ilgi çekicidir çünkü makine öğrenmesi konusundaki anlayışımızı geliştirebilmemiz için önce zekanın altında yatan ilkelere ilişkin anlayışımızı geliştirmemiz gerekir.

“Görev” kelimesi ile kastedilen öğrenme sürecinin kendisi değildir. Öğrenme, belirtilen görevleri yerine getirme becerisini elde edebilme yeteneğidir. Örneğin, bir robotun

zıplayabilmesini istiyorsak, burada görev robotun zıplayabilmesidir. Bu görevi robota direk programlayabiliriz veya nasıl yürüneceğini öğrenebileceği bir algoritma geliştirebiliriz.

Makine öğrenmesi görevleri genellikle bir örneklemin işleme süreci olarak tanımlanır. Makine öğrenmesi sisteminin ele alacağını nesnelerinden veya olaylardan toplanan nicel ölçütlere örneklem denir. Genellikle, örneklem $x \in \mathbb{R}^n$ olan x_i öznitelik girdisinden oluşan bir vektör olarak temsil edilir. Görüntülerin ölçülen piksel değerleri örnekleme örnek olarak verilebilir.

Makine öğrenimi yapısı itibarıyla farklı görevleri yerine getirilebilir. En çok rastlanılan makine öğrenme görevlerinden aşağıdaki gibidir:

- **Sınıflandırma:** Sınıflandırma görevinde görev algoritmanın girdileri k adet kategoriden ait olduğu kategoriye atamasıdır. Bu görevi çözmek için, öğrenme algoritmasından genellikle bir $f = \mathbb{R}^n \rightarrow \{1, \dots, k\}$ fonksiyon üretmesi istenir. $y = f(x)$ fonksiyonuyla, model x vektörü ile tanımlanan bir girişi sayısal kod y ile tanımlanan bir kategoriye haritalanabilir.
- **Eksik girdilerle sınıflandırma:** Eğer bilgisayar programına girdi vektöründeki her ölçümün her zaman sağlanacağı garanti edilemiyorsa, sınıflandırma görevi çok daha zor hale gelir. Normal sınıflandırma görevini çözebilmek için, öğrenme algoritmasının yalnızca bir vektör girişinden kategorik bir çıkışa tek bir fonksiyon haritalaması tanımlaması yeterlidir. Girdilerden bazıları eksik olduğunda, tek bir fonksiyon haritalaması yerine, öğrenme algoritması bir dizi fonksiyon haritalamasını öğrenmelidir. Her fonksiyon, x girdi vektörünün farklı bir alt kümesi eksik iken yapılan bir sınıflandırılmaya karşılık gelir. Bu tür bir durumlara tıbbi teşhiste tıbbi testlerin pahalı veya invaziv olmasından dolayı çok sık rastlanır.
- **Regresyon:** Bu görevde, bilgisayar programından verilen girdilere karşılık sayısal bir değeri tahmin etmesi istenir. Çözüm için, öğrenme algoritmasından bir $f = \mathbb{R}^n \rightarrow \mathbb{R}$ fonksiyonunun üretmesi istenir. Bu görev, çıkış formatının farklı olması dışında sınıflandırmaya benzer.
- **Transkripsiyon:** Bu görevde, makine öğrenimi sisteminden, yapılandırılmamış bir tür verinin temsilini gözlemlemesi ve onu ayırık, metinsel forma dönüştürmesi istenir.
- **Makine çevirisi:** Bir makine çevirisi, bir girdinin bilgisayar programı tarafından başka bir dile dönüştürülmesidir.

- **Yapılandırılmış çıktı:** Yapılandırılmış çıktı, çıktının öğeleri arasında önemli ilişkiler bulunan bir vektör (veya birden çok değer içeren başka bir veri yapısı) olduğu tüm görevlerdir.
- **Anormallik tespiti:** Bu tür bir görevde, bilgisayar programı bir dizi olay veya nesneyi gözden geçirdikten sonra bazılarını olağandışı veya anormal olarak işaretlemesidir. Örnek olarak kredi kartı sahtekarlığı algılaması verilebilir.
- **Sentez ve örnekleme:** Bu tür görevlerde, makine öğrenme algoritmasından eğitim veri setindeki örneklerle benzer yeni örnekler üretmesi istenir. Makine öğrenimi yoluyla sentez ve örnekleme, bir sanatçının elle oluşturmasının pahalı veya sıkıcı olabileceği uygulamaları için faydalı olabilir.
- **Gürültü giderme:** Makine öğrenme algoritmasına temiz bir örnek $x \in \mathbb{R}$ 'den bir bozulma işlemiyle elde edilmiş bozuk örnek $\tilde{x} \in \mathbb{R}$ girdi olarak verilir. Öğrenci, temiz x örneğini bozuk $\tilde{x}$ versiyonundan tahmin etmeli veya daha genel ifade edilirse koşullu olasılık dağılımını $p(x|\tilde{x})$ tahmin etmelidir.

Yukarıda listelenen görevler dışında da makine öğrenmesi ile daha birçok görev yerine getirilebilir.

Bir makine öğrenme algoritmasının yeteneklerini değerlendirebilmek için performansının nicel bir ölçüsünün hesaplanması gerekir. Genellikle performans ölçüsü P , sistem tarafından yürütülen T görevine göre seçilir. Sınıflandırma, eksik girdilerle sınıflandırma ve transkripsiyon gibi görevlerde genellikle modelin doğruluğu ölçülür. Doğruluk, modelin doğru çıktıyı ürettiği örneklerin tüm örneklerle oranıdır. Ayrıca, modelin yanlış çıktı ürettiği örneklerin oranı olan hata oranını ölçerek de eşdeğer performans ölçümü yapılabilir. Hata oranı bazen beklenen $0 - 1$ yitimi(loss) olarak adlandırılır. Belirli bir örnekteki $0 - 1$ yitimi, doğru sınıflandırılmışsa 0, değilse 1'dir. Her görev için performansın doğruluk, hata oranını veya bir $0 - 1$ yitiminin ölçülmesi doğru bir yaklaşım olmayabilir, örneğin yoğunluk tahmini görevi. Bunun yerine, modele her örnek için sürekli değer veren farklı bir performans metriği kullanılmalıdır.

Genellikle, makine öğrenmesi algoritmasının daha önce görmediği veriler üzerinde ne kadar iyi performans gösterdiği önemsenir, çünkü gerçek dünyada ne kadar iyi çalışacağı bu veriler üzerinden ölçülebilir. Dolayısıyla, makine öğrenmesi sistemini eğitmek için kullanılan verilerden ayrı bir test veri seti kullanarak da performans ölçümü yapılmaktadır.

Sistemlerden beklenen göreve uygun bir performans ölçütü belirlemek istenilen görevi

tam olarak ölçen ölçütü belirlemenin zor olması sebebiyle zorlu bir iştir. Diğer durumlarda, ölçmek istenilen ölçüt bellidir fakat ölçmek zor olabilir.

Makine öğrenmesi algoritmaları, eğitim sürecinde uygulanan deneyime göre denetimsiz veya denetimli olarak ikiye ayrılabilir. Öğrenme algoritmalarının çoğu bir veri kümesi ile eğitilir. Bir veri kümesi birçok örnekten oluşan bir koleksiyondur. Bazen örnek veri olarak da adlandırılır.

Denetimsiz öğrenme algoritmalarında, algoritma birçok özellik içeren bir veri kümesini deneyimler, daha sonra veri kümesinin yapısının yararlı özniteliklerini öğrenmeye çalışır. Genellikle yoğunluk tahmininde, sentez ve gürültü giderme gibi görevlerde kullanılan derin öğrenme uygulamalarının veri kümesinde oluşan tüm olasılık dağılımının öğrenebilmesi gerekmektedir. Öte yandan bazı denetimsiz öğrenme algoritmaları da veri kümesini benzer örnek kümelerine bölerek kümeleme gibi başka rolleri yerine getirmek için kullanılmaktadır. Denetimli öğrenme algoritmaları, öznitelikler içeren bir veri kümesini deneyimler fakat farklı olarak her örnek aynı zamanda bir etiket veya hedefle ilişkilendirilir. Öğrenme paradigmasının başka çeşitleri de bulunmaktadır. Örneğin, yarı denetimli öğrenmede, bazı örnekler bir hedef ve etiket içerirken diğerleri içermez. Çok örnekli öğrenmede, tüm bir örnek koleksiyonu bir sınıf örneğini içeriyor veya içermiyor şeklinde etiketlenir, ancak koleksiyonun üyeleri teker teker etiketlenmez. Önceden belirlenmiş veri kümeleriyle eğitilmeyen makine öğrenme algoritmaları da mevcuttur. Örneğin, pekiştirmeli öğrenme algoritmaları bir ortamla etkileşime girer ve öğrenme sistemine algoritmanın deneyimlerinden sonuçlarından geri bildirim aktarılır.

3.1.2 Kapasite, Aşırı Öğrenme ve Eksik Öğrenme


Makine öğrenmesindeki zor görevlerden bir nedeni modelin eğitim setinde bulunmayan yeni girdilerde iyi performans göstermesinin beklenmesidir. Daha önce gözlemlenmemiş girdiler üzerinde iyi performans gösterme yeteneğine genelleme yeteneği denir. Genelde makine öğrenme modeli bir eğitim seti üzerinden eğitilir, bu eğitim seti üzerinde eğitim hatası adı verilen bazı hata ölçüleri hesaplanır ve eğitim süresince bu hata azaltılmaya çalışılır. Buraya kadar işlem aslında sadece bir en iyileme (optimizasyon) problemidir. Makine öğrenimini en iyileme işleminde ayıran ise, test hatası olarak da adlandırılan genelleme hatasının da düşük olmasının istenmesidir. Genelleme hatası, eğitim setinde olmayan bir girdinin haritalandırma hatasının beklenen değeri olarak tanımlanır. Burada beklenti, sistemin uygulamada karşılaşmasını beklediğimiz girdilerin dağılımından elde edilen farklı olası girdiler üzerinden alınır. Genelde makine öğrenmesi modelinin genelleme hatası, modelin performansının eğitim setinden ayrı olarak toplanan bir test setinde ölçülmesiyle

tahmin edilir.

Sadece eğitim seti gözlemlenerek test setindeki performansı etkileyebilmek için istatistiksel öğrenme teorisi alanından faydalanılabilir. Öncelikle eğitim ve test setinin nasıl toplandığı hakkında bazı varsayımlarda bulunulması gerekmektedir. Veri setindeki her bir örnek birbirinden bağımsız olmalı ve eğitim seti ile test seti aynı dağılıma sahip olmalıdır. Bu varsayım sayesinde bir modelin beklenen eğitim hatasının, o modelin beklenen test hatasına eşit olması beklenmektedir. Eğitim sonucunda beklenen test hatasının eğitim hatasının beklenen değerinden büyük veya ona eşit olması beklenmektedir. Bir makine öğrenimi algoritmasının ne kadar yetenekli olduğu aşağıdakileri becerilere ne derece sahip olduğuna bağlıdır:

- Eğitim hatasını azaltabilmesine.
- Eğitim ve test hatası arasındaki farkı küçültebilmesine.

Bu iki faktör, makine öğreniminde aşırı öğrenme ve eksik öğrenme adı altındaki iki önemli konuya denk gelir. Model eğitim setinde yeterince düşük bir hata değeri elde edemediğinde eksik öğrenme meydana gelir. Eğitim hatası ile test hatası arasındaki boşluk çok büyük olduğunda ise aşırı öğrenme meydana gelir. Bir modelin kapasitesini değiştirilerek eksik öğrenme veya aşırı öğrenme durumunu kontrol edilebilir. Bir modelin kapasitesi, çok çeşitli fonksiyonu öğrenebilme yeteneğidir. Düşük kapasiteli modeller eğitim setini öğrenmede zorlanabilir. Yüksek kapasiteli modeller, test setindeki gereksiz bilgileri de öğrenerek aşırı öğrenme durumuna sebep olabilir.



Şekil 3.1 Model kapasitesi ve hata arasındaki ilişki

Kapasite ve hata arasındaki ilişki Şekil 3.1’de verilmiştir.

3.1.3 Derin Sinir Ağlarına Ortaya Çıkmasındaki Etkenler

Basit makine öğrenmesi algoritmaları, birçok önemli problemi çözmede başarılı olmuştur. Fakat, ses tanıma veya nesneleri tanıma gibi yapay zekanın ana problemlerini çözmede yetersiz kalmıştır. Derin öğrenmenin gelişiminin bir sebebi de geleneksel algoritmaların bu tür yapay zeka görevlerinde iyi bir genelleme yapamamasından kaynaklanmıştır.

Veri boyutlarının artmasıyla makine öğrenimi problemi eksponansiyel derecede zorlaşır. Çok boyutluluğun lanetinde, girdi uzayının boyutundaki artış olası konfigürasyonlarının miktarını eksponansiyel olarak arttırdığından eğitimde zorluklar ortaya çıkar. Geleneksel makine öğrenmesi algoritmasına göre bir girdinin çıktısının, en yakın eğitim girdisinin çıktısına yakın olması gerektiğini belirtir. Yüksek boyutlu uzaylarda konfigürasyonların sayısı örneklerin sayısından çok daha fazla olduğundan tipik bir girdinin kendisiyle ilişkilendirilmiş bir eğitim örneği olmayabilir. Dolayısıyla geleneksel makine öğrenmesi algoritmalarından sağlıklı sonuç elde etmek zorlaşır.

Makine öğrenmesinde genellemenin doğru yapılabilmesi için bazı öncel kabuller yapılmaktadır. Bu öncellerin en yaygın kullanılanı düzgünlük veya lokal sürekliliktir. Bu kabul öğrenilen fonksiyonun ani değişimler barındırmaması gerektirdiği anlamına gelir. Birçok basit algoritma, yalnız bu kabul varsa iyi genelleme yeteneğini olduğu söylenebilir. Sonuç olarak, yapay zeka düzeyindeki görevleri çözmeyle ilgili istatistiksel zorluklarla baş edemezler.

Makine öğrenmesinde birçok fikrin kökünde önemli bir kavram olan manifold kavramı bulunmaktadır. Manifold, bağlantılı bir bölgeye verilen addır. Matematiksel olarak, her noktanın etrafındaki noktalarla bir komşuluk ilişkisinin olduğu noktalar kümesi olarak tanımlanabilir. Her noktada var olan komşuluk tanımı, manifold üzerinde bir konumdan komşu bir konuma hareket etmek için uygulanabilecek dönüşümlerin varlığını ima eder. Makine öğrenmesi bağlamında, manifoldun boyutsallığının noktalar arasında değişmesine izin verilir. Bu genellikle bir manifold kendisiyle kesiştiğinde olur. Örneğin, sekiz rakamı, çoğu yerde tek bir boyutu olan ancak merkezdeki kesişme noktasında iki boyutu olan bir manifolddur. Makine öğrenmesi algoritmasının tüm $\mathbb{R}^n$ 'de ilginç varyasyonlara sahip fonksiyonları öğrenmesi pek mümkün değildir.

3.2 Derin Sinir Ağları

Genellikle ileri beslemeli sinir ağları veya diğer adıyla çok katmanlı algılayıcılar (MLP) olarak da bilinen ağlar, derin öğrenme modellerinin temeli olarak kabul edilirler. İleri beslemeli bir ağın amacı, bir f^* gerçek fonksiyonunu yaklaşık olarak elde etmektir.

Örneğin, bir sınıflandırıcı, $y = f^*(x)$, bir x girdisini bir y kategorisine haritalar. İleri beslemeli ağ bir $y = f(x; \theta)$ eşlemesini tanımlar ve en iyi fonksiyon yaklaşımıyla elde edilen θ parametrelerinin değerini öğrenmeye çalışır.

Bu modeller ileri beslemeli olarak adlandırılır çünkü bilgi, x girdisinden f 'yi tanımlamak için kullanılan ara hesaplamalar aracılığıyla y çıktısına doğru akar. Modelin çıktılarını tekrar katmanlarına geri beslendiği hiçbir geri besleme bağlantısı yoktur. İleri beslemeli sinir ağların, geri besleme bağlantılarını içerecek şekilde genişletildikleri ağlarda mevcuttur.

İleri beslemeli sinir ağları, birçok farklı fonksiyonun bir araya getirilmesinden oluşmaktadır. Model fonksiyonların nasıl birleştiğini açıklayan yönlendirilmiş döngüsel olmayan graf ile ilişkilendirilir. Örneğin, $f^{(1)}$, $f^{(2)}$ ve $f^{(3)}$ isimli üç fonksiyonu zincir şeklinde bağlayarak $f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x)))$ elde edilebilir. Bu zincir yapısı makine öğrenmesinde en çok tercih edilen yapıdır. Yapıda, $f^{(1)}$, ağın birinci katman, $f^{(2)}$ ise ikinci katman olarak adlandırılır ve adlandırma bu şekilde devam eder. Derinlik yapıdaki katman sayısı ile ölçülür. "Derin öğrenme" terimi bu terimden gelmektedir. İleri beslemeli ağın son katmanına çıkış katmanı denir. Sinir ağı eğitimi sırasında, ağın çıktısı olan $f(x)$ 'i gerçek $f^*(x)$ ile eşleştirmeye çalışılmaktadır. Örneklem verileri bize farklı eğitim noktalarından gürültülü, yaklaşık $f^*(x)$ örnekleri sağlar. Her x örneğine karşılık bir $y = f^*(x)$ etiketi bulunur. Eğitim örnekleri, çıktı katmanının her x noktasında ne üretmesi gerektiğini doğrudan belirler (y 'ye yakın bir değer). Diğer katmanların davranışı, eğitim verileri tarafından doğrudan belirtilmez. Öğrenme algoritması, istenen çıktıyı üretmek için bu katmanların hangi işlevi yerine getirmesi gerektiğini öğrenmelidir. Eğitim verileri bu katmanların her biri için istenen çıktıyı göstermediğinden bu katmanlara gizli katmanlar denir. Gizli katmanların boyutu, modelin genişliğini belirler. Bir gizli katmanın her bir elemanı bir nöron rolü oynuyor olarak düşünülebilir.

3.2.1 Evrişimli Derin Sinir Ağları

Evrişimli sinir ağı (CNN) olarak da bilinen evrişimsel ağlar ızgara benzeri topolojiye sahip verileri işlemek için özelleşmiş sinir ağıdır. Örnek olarak düzenli zaman aralıklarında numune alınan tek boyutlu ızgara olarak düşünülebilecek zaman serisi verileri ve iki boyutlu piksel ızgarası olarak düşünülebilecek görüntü verileri gösterilebilir. Uygulamada çokça kullanılan evrişimli ağlar yeteneğini birçok kez ispatlamıştır. Evrişimli sinir ağı adı, ağın evrişim adı verilen matematiksel bir işlem kullanmasından dolayı verilmiştir. Evrişim, doğrusal olan özel bir işlem türüdür. Katmanlarından evrişim işlemi kullanılan tüm sinir ağları evrişimli sinir ağları olarak adlandırılır.

3.2.1.1 Evrişim katmanları

Matematiksel olarak iki fonksiyon arasındaki evrişim, bir fonksiyonun şeklinin diğer fonksiyon tarafından nasıl değiştirildiğini ifade eden üçüncü bir fonksiyon üretir. Genellikle bu işlem dijital ortamda gerçekleştiğinden iki boyutlu evrişim denklemi 3.1'deki gibi ifade edilebilir,

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (3.1)$$

Denklemde i ve j görüntüdeki piksellerin eksenlerinin indislerini, K ise ağırlıkları içeren çekirdek matrisini ifade etmektedir. Sonuç ise bazen öznitelik haritası olarak adlandırılır. Evrişim katmanı, görüntü analizi uygulamalarında en çok tercih edilen ağ katmanı türlerinden biridir.

Bir evrişim katmanı, küçük iki boyutlu filtre/öznitelik detektörlerinden oluşur. Geleneksel makine öğreniminde kullanılan ve uzman tarafından belirlenen özniteliklerin aksine derin ağlarda öznitelikler filtreler aracılığıyla ağ eğitimi sırasında öğrenilir. Derin evrişimli ağlarda alt evrişim katmanları (girdi katmanına yakın katmanları) düşük seviyeli özellik detektörleri olarak kabul edilebilir. Genelde, derin evrişli Sinir Ağları (DCNN), bir evrişim katmanından gelen çıktının bir sonraki evrişim katmanına beslendiği ardışık çoklu evrişim katmanlarından oluşan bir hiyerarşi kullanılır. Sonuç olarak hem düşük seviyeli hem de yüksek seviyeli öznitelikler DCNN tarafından tespit edilebilir. Görüntüde içerisindeki kenarlar ve yerel dokular gibi basit örüntüler düşük seviyeli öznitelikler olarak adlandırılır. Bu düşük seviyeli öznitelikler ilerleyen katmalarda daha kompleks yüksek seviyeli öznitelikleri oluşturur.

Evrişim çekirdek matrislerinin bir diğer adıyla filtrelerinin boyutları nispeten küçüktür (tipik aralık 3×3 ila 11×11 piksel arasındadır) ve küçük bir yerel komşuluk içindeki görüntü piksellerinin güçlü uzamsal korelasyonlara sahip olduğu gerçeğinden yararlanır. Evrişim filtresinin boyutu kullanıcı tarafından belirlenir ve algısal alan adı verilir. Algı alanının boyutu, önceki katmandan mevcut katmandaki bir nörona bağlı olan nöronların sayısını ifade eder. Evrişim katmanları paylaşılan ağırlıklar kullanır, yani evrişim filtresinin ağırlıkları, görüntünün her yerinde aynı değerlere sahiptir. Bu sayede optimizasyon parametreleri olan ağ ağırlıklarının sayısında azalma olur. Bu nedenle, evrişim ağları, genelde tamamen bağlı ağlardan daha az ağırlığa sahiptir. Evrişim katmanında belirlenmesi gereken önemli bir diğer parametre ise filtresinin evrişim işleminden sonra ne kadar kaydırılacağını belirleyen adım kaydırma parametresidir.

3.2.1.2 Örnekleme ve seyreltme katmanları

Yaygın olarak kullanılan bir diğer katman ise örnekleme katmanıdır. Boyut, adım kaydırma ve tür parametrelerine sahiptir ve genelde evrişim katmanından sonra konumlandırılır. Tüm katman çıktılarının diğer katmanlara aktarılması ağı boyutlarının çok büyümesine ve yavaşlamasına sebep olur. Bunun yerine sadece en önemli bilgiler örnekleme katmanı ile bir sonraki katmana aktarılır. Örnekleme katmanı boyut parametresi yani örnekleme işlemini yapacağı boyutta belirlenmesi gereken bir parametredir. Adım kaydırma parametresi ise evrişimli ağlardaki gibi bir sonraki örnekleme grubunun yerini belirler. En yaygın örnekleme türleri maksimum (maksimum örnekleme olarak da adlandırılır) ve ortalama örneklemedir. Maksimum örneklemede, yalnızca örnekleme penceresindeki baskın öznitelik korunur ve bir sonraki katmana iletir. Öte yandan, havuzlama penceresindeki tüm özelliklerin ortalama yanıtını hesaplayan ve bir sonraki katmana aktaran katmana ortalama örnekleme katmanı denir.

Her seyreltme katmanı, kullanıcı tarafından belirlenen bir ilişkili seyreltme olasılığı parametresine sahiptir. Seyreltme olasılığı, bir eğitim iterasyonu sırasında ilgili katmanın öğelerinin "açılıp/kapatılma" sıklığını belirtir. Örneğin, 0,5 olasılık, belirli bir iterasyonu sırasında nöronların yarısının rastgele kapatıldığı anlamına gelir. Sonuç olarak, bu nöronlar ne ileri ne de geri geçişte yer almazlar. Bir eğitimin, k iterasyonu sırasında kapatılan bir nöron mevcut iterasyonda yer almayacak, ancak bir önceki ağırlıkları korunacak (yani, $k - 1$ yinleme sırasında elde edilen/güncellenen ağırlık değeri) ve sonraki $k + 1$ iterasyonunda kullanılacaktır. Test aşamasında tüm nöronlar ileri geçişte yer alır ve ağırlıkları normalleştirilir. Seyreltme katmanının ağıdaki varyansı ve aşırı öğrenmeyi azaltma gibi düzenleyici bir etkisi vardır.

3.2.1.3 ReLU (Doğrultulmuş Doğrusal Birim) aktivasyon fonksiyonu

ReLU, katmanlarla birlikte kullanılabilen bir etkilenim fonksiyonu örneğidir. Derin öğrenmede en sık kullanılan aktivasyon fonksiyonu haline geldi ve hatta hiperbolik tanjant ve sigmoid fonksiyonlardan daha popüler hale geldi. ReLU denklem 3.2'deki gibi formüle edilebilir.

$$f(x) = \max(0, x) \quad (3.2)$$

3.2.1.4 Toplu normalleştirme

Toplu normalizasyon (BN) katmanı tanıtıldığından çok kısa bir süre içinde özellikle çok derin sinir ağlarının eğitimi için popüler hale geldi. Bu katman ReLU işlemi

gibi doğrusal olmayan bir durumdan önce tanıtılır ve BN katmanına beslenen her bir öznitelik yanıtı kümesi için normalleştirme işlevi gerçekleştirir. BN katmanı öznitelik yanıtları setini standart bir normal dağılıma dönüştürür. Toplu normalleştirme, öznitelik yanıtlarının yalnızca yarısının aktivasyon eşiğinin üzerinde olmasını sağlayarak öğrenmede çok önemli bir rol oynar. Bu nedenle, bir BN işleminden sonra, bir öznitelik yanıtının doğrusal olmayan aktivasyona katkısı, mutlak değerine değil göreceli değerine bağlıdır. Öte yandan, negatif giriş değerlerinde dolayı doğrusal olmayanların aktivasyonların hiçbirinin etkinleştirilmediği bir durumla karşı karşıya kalınabilir. Bir BN katmanının dahil edilmesi, tamamen pozitif veya negatif değer aralığını sıfır ortalamalı birim standart sapma dağılımına dönüştürür. Böylece öznitelik yanıtlarının yarısının her zaman gradyan için bir güncelleme ile sonuçlanmasını sağlar.

3.2.1.5 Yitim fonksiyonları

Derin ağları eğitmek için veriler, veri ve hedef çiftleri (x_i, t_i) biçiminde sağlanır; burada x_i , belirli bir girdi veri örneğidir ve t_i girdiye karşılık gelen sınıf etiketidir. Sinir ağı, doğrusal ve doğrusal olmayan aktivasyonların bir dizi iterasyonundan oluşan bir f fonksiyonu olarak düşünülürse, giriş vektörü x_i için f 'nin çıktısının genelleştirilmesi denklem 3.3'daki gibi yazılabilir.

$$y_i = f(x_i, W) \quad (3.3)$$

Denklemden W , optimizasyon parametreleri olarak hizmet eden ağırlıklar kümesidir. İlk bakışta ağırlıkların eğitiminin amacının çıktısı y_i ve hedef t_i arasındaki farkı en aza indirmek olduğu görülebilir. Sonuçların iyiliğini belirlemek için kullanılan ölçü yitim fonksiyonu olarak adlandırılır. Literatürde softmax, kare hata, ortalama mutlak hata, ortalama kare hatası, ikili çapraz entropi öklid yitim fonksiyonları gibi birçok farklı kayıp fonksiyonu türü vardır.


3.2.2 Optimizasyon

Bir sinir ağının eğitimi, iterasyonlu bir optimizasyon sürecidir. Yitim fonksiyonu L_f hesaplanması iki farklı niceliğe bağlıdır. Birincisi W ağırlık seti, ikincisi ise mevcut mini parti X 'i oluşturan girdi örnekleri setidir. Bu iki girdiden, ağırlıklar seti W , optimizasyonun parametreleri olarak kabul edilir, yani X verisi uygulandığında, ağırlık seti W eğitim verileri doğru bileşen sınıflarına ayrılacak şekilde güncellenir. Literatürde, ağırlık kaybını en aza indirmek için bir dizi farklı optimizasyon yöntemi önerilmiştir. Bu optimizasyon yöntemlerinin çoğu, yerel bir

arama paradigmasında tasarlanmış gradyan tabanlı optimizasyona dayanmaktadır. Yaygın kullanılan optimizasyon yöntemlerinden bazıları gradyan inişı (GD), minibatch gradyan inişı (MBGD), stokastik gradyan inişı (SGD), AdaDelta (uyarlanabilir öğrenme oranına dayalı), uyarlamalı gradyan, Adam ve Nesterov's hızlandırılmış gradyandır.

3.3 Otokodlayıcılar

Otokodlayıcı, çıktısında girdisinin aynısını üretmek için eğitilmiş bir sinir ağıdır. Girdiyi gizli katmanlarında girdinin özniteliklerini barındıran bir koda indirger. Ağın iki bölümden oluştuğu düşünülebilir: kodlayıcı fonksiyonu $h = f(x)$ görevinin yerine getiren alt ağ ve yeniden oluşturma fonksiyonu $r = g(h)$ görevini yerine getiren alt ağ (kod çözücü). Otokodlayıcı mimarisi şekil 3.2'de sunulmuştur. Bir otomatik kodlayıcı, her girdiyi $g(f(x)) = x$ 'i şeklinde basitçe öğrenmeyi başarması halinde kullanışlılığını kaybeder. Bunun yerine, otokodlayıcılar mükemmel bir kopyalamayı öğrenemeyecek şekilde tasarlanmıştır. Genellikle, yalnızca yaklaşık olarak kopyalamalarına ve yalnızca eğitim verilerine benzeyen girdileri kopyalamalarına izin verecek şekilde kısıtlanırlar. Model, girdinin hangi yönlerinin kopyalanması gerektiğine öncelik vermeye çalışırken verilerin yararlı özelliklerini öğrenir.



Şekil 3.2 Otokodlayıcının genel mimarisi

Otokodlayıcılar ilk tanıtıldıklarında boyut azaltma veya özellik öğrenme görevleri için kullanıldı. Son zamanlarda ise, otokodlayıcılar ve gizli değişken modeller arasındaki teorik bağlantılar, otokodlayıcıları üretici modellemenin önemli bir parçası haline getirdi.

Girdinin çıktıya kopyalanması ilk bakışta gereksiz gibi gelebilir fakat zaten genellikle kod çözücünün çıktısıyla ilgilenilmemektedir. Bunun yerine, otokodlayıcının girdi kopyalama görevini gerçekleştirebilmesi için eğilirken, girdinin yararlı öznitelikleri çıkartabilme yeteneğine sahip olacağı umulmaktadır. Otokodlayıcıdan faydalı öznitelikleri elde etmenin bir yolu, girdi ile çıktı arasında ağı olabildiğinde küçültmektir. Bu şekilde eğitimde, otokodlayıcı verilerinin en belirgin özelliklerini yakalamaya zorlanır. Öğrenme süreci, denklem 3.4’de gösterildiği gibi bir yitim fonksiyonunun minimize edilmesi olarak tanımlanabilir.

$$L(\mathbf{x}, g(f(\mathbf{x}))) \quad (3.4)$$

Denklemden L , ortalama kare hatası gibi, girdiyi temsil eden $\mathbf{x}$ ’ten farklı olduğu için $g(f(\mathbf{x}))$ ’i cezalandıran yitim fonksiyonudur.

Kod çözücü doğrusal ve L ortalama kare hatası olarak seçildiğinde, bir otokodlayıcı PCA ile aynı işlevi yerine getirir. Bu şartlar altında girdiyi çıktısına kopyalamak için eğitilmiş bir otokodlayıcı, aynı zamanda eğitim verilerinin öznitelik alt uzayını öğrenmektedir. Doğrusal olmayan kodlayıcı ve kod çözücü içeren otokodlayıcılar ise PCA’den farklı olarak doğrusal olmayan genelleştirmeleri öğrenebilirler. Bir dezavantaj ise, kodlayıcı ve kod çözücü çok fazla kapasite sahip olursa, otomatik kodlayıcı, verilerin dağıtımını hakkında yararlı bilgiler çıkarmayı öğrenmeden kopyalama görevini gerçekleştirmeyi öğrenebilir.

3.3.1 Gürültü Arındırıcı Otokodlayıcılar

Yitim fonksiyonunun yeniden oluşturma hata terimini değiştirerek gürültüden arındırabilen otokodlayıcı elde edilebilir. Gürültü arındırıcı otokodlayıcı (DAE) denklem 3.4’de verilen geleneksel yitim fonksiyonu yerine denklem 3.5’de gösterilen yitim fonksiyonunu minimize etmeye çalışır.

$$L(\mathbf{x}, g(f(\tilde{\mathbf{x}}))) \quad (3.5)$$

burada $\tilde{\mathbf{x}}$, $\mathbf{x}$ ’in bir tür gürültü tarafından bozulmuş kopyasıdır. Bu nedenle, otomatik kodlayıcıları, girdiyi kopyalamak ile beraber aynı zamanda bozulmayı da düzeltmelidir.

3.3.2 Uygulama Alanları


Otokodlayıcılar, boyut azaltma ve öznitelik çıkarma görevleri için başarıyla kullanılmışlardır. Girdileri düşük boyutlu gösterimlere indirmek, özellikle sınıflandırma olmak üzere gibi birçok görevde başarıyı arttırabilir. Daha küçük modeller daha az bellek gerektirir ve daha hızlı sürede sonuç üretir.

Boyut azaltmadan işlevinden en çok yararlanan görevlerden bir tanesi de ilişkili veya benzer bulma görevi yani veri tabanında bulunan bilgilerden sorgu girdisine benzeyenleri bulma görevi. Boyut azaltma algoritmasını düşük boyutlu ve ikili bir kod üretmek için eğitirsek, tüm veri tabanı girişlerini ikili kod vektörlerini girişlere eşleyen bir karma tablosunda saklayabiliriz. Bu karma tablo, sorgu ile aynı ikili koda sahip tüm veri tabanı girişlerini geri döndürerek bilgi bulmamızı sağlar. Boyut azaltma ve ikilileştirme yoluyla bilgi bulmaya semantik hashing denir.

Ayrı otokodlayıcılar girdileri tekrar üretirken eğitilmedikleri dağılımlardaki verileri başarılı olarak tekrar üretmezler. Bu özelliklerinden faydalanılarak tekrar oluşturulan girdi ve girdi arasındaki fark üzerinden kusur denetimi ve anomali tespiti gibi görevlerde kullanılabilir.

3.4 Çekişmeli Üretici Ağlar (GAN)

Günümüzde, üretici modellerin ilerlemesiyle, sinir ağları görüntüleri tanımanın ve sınıflandırmanın yanında ses ve gerçekçi görüntüler üretmek için de kullanılmaktadır. GAN'lar, üretken modellerin bir örneğidir. GAN, çoğunlukla girdi verilerinin dağılımından yeni örnekler oluşturmaya odaklanır. GAN yapısını daha iyi anlamak için para kalpazanlığı yapan bir suçlu ile polis arasındaki gerçek dünya ilişkisi bir analogi olarak ele alınabilir. Başarılı bir kalpazan olabilmesi için suçlunun polisi kandırması gerekir yani polisin sahte para ile gerçek para arasındaki farkı anlayamaması gerekmektedir. Polisin ise sahte parayı olabildiğince etkili bir şekilde tespit edebilmesi gerekmektedir. Bu, oyun teorisinde bir minimax oyun olarak modellenenebilir. Bu fenomene rakip süreç denir. Ian Goodfellow tarafından tanıtılan GAN, iki sinir ağının birbiriyle rekabet ettiği çekişmeli sürecin özel bir durumudur. Birinci ağ veri üretirken ikinci ağ, gerçek veriler ile birinci ağ tarafından üretilen sahte veriler arasındaki farkı bulmaya çalışır. İkinci ağ, genel olarak gerçek veri olasılığını temsil eden bir skaler $[0, 1]$ çıktısı vermektedir. Şekil 3.3'te GAN şeması verilmiştir.



Şekil 3.3 Çekişmeli üretici ağlar (GAN)

3.4.1 Alt Komponentleri

GAN yapısında, ilk ağ üretici olarak adlandırılır ve genellikle $G(z)$ ile temsil edilir ve ikinci ağ ise sınıflandırıcı olarak adlandırılır ve genellikle $D(x)$ ile temsil edilir. Minimax oyunundaki optimal nokta olan denge noktasında, ilk ağ gerçek verilere çok yakın yeni veriler üretebilecek ve ikinci ağ, ilk ağın çıktısında gerçek verilerde ayırt etmekte zorlandığından 0.5 değerini üretecektir. Bazen iki ağ sonunda dengeye ulaşır, ancak bu her zaman garanti edilmez ve iki ağ uzun süre öğrenmeye devam edebilir. GAN yitim fonksiyonu denklem 3.6’de verilmiştir.

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (3.6)$$

Üretici ağı, girdi olarak rastgele gürültü alır ve yeni bir veri örneği oluşturmaya çalışır. Şekil 3.3’de, $G(z)$ üretici ağının $p(z)$ olasılık dağılımından bir z girdisi aldığını ve daha sonra $D(x)$ sınıflandırıcı ağa beslenen verileri ürettiği gösterilmiştir.

Sınıflandırıcı ağ gerçek verilerden ve üreticinin ürettiği verilerden girdi alır ve girdinin gerçek mi yoksa üretici ağ tarafından oluşturulmuş mu olduğunu tahmin etmeye çalışır. Gerçek veri dağıtımını $P_{data}(x)$ verisinden bir girdi alır ve ardından 0 ila 1 skaler aralığında çıktı veren bir ikili sınıflandırma problemini çözer.

Kullanılabilir etiketlenmemiş veri miktarı etiketlenmiş veri miktarından çok daha fazladır dolayısıyla, GAN’lar denetimsiz öğrenme kabiliyetleri sayesinde çok popülerlik kazanmıştır. Popülerliklerinin bir başka nedeni de GAN’ların üretken modeller arasında en gerçekçi görüntüleri üretebilmeleridir. Bu subjektif olmasına rağmen, çoğu araştırmacı tarafından paylaşılan bir fikirdir.

4 ÖNERİLEN YÖNTEMLER

Literatür araştırmaları sonucunda, daha önce bahsedilen tezin amacı doğrultusunda tasarlanması hedeflenen sistemin var olan yöntemlerle yapılamayacağına karar verilmiş yeni bir yaklaşım arayışına girilmiştir. Bir yöntemin yeni kumaş ve desenlere zahmetsizce uygulanabilmesi için kendi kendini eğitebilen bir yapıda olması gerekmektedir. Bu amaca en uygun yöntem derin öğrenme yöntemidir. Derin öğrenmenin aksine literatürde var olan diğer metotların yeni verilere uyarlanabilmesi için bir uzman tarafından parametrelerin ve bazen yöntemin değiştirilmesi gerekmektedir. Bununla beraber derin öğrenmenin kompleks yapısından kurtulabilmek ve hızlı bir yapı kurabilmek için öznitelik çıkarımı gibi bazı yöntemler derin öğrenme ile beraber kullanılabilir.

Dokuların temsil edilmesi ve özniteliklerinin çıkartılması ile ilgili birçok yöntem bulunmaktadır. Fakat bu yöntemler ile elde edilen özniteliklerden görüntüye geri dönüş yapılamamaktadır. Tek taraflı bir dönüşüm olduğunda dokunun kusurlu olup olmadığına karar verilebilmekte fakat kusurların haritasının çıkartılması imkansız hale gelmektedir. Tekstil sektöründe üretilen ürünlerin kalıpları uzun kumaşlar üzerinden kesildiğinden dolayı kumaşların kusurlu bölgeleri ve büyüklükleri üretilen kumaşın kalitesinde önemli olmaktadır. Örneğin tek bir bölgede 100 adet kusur bulunduran bir kumaş, tamamına dağılmış 100 adet kusur bulunduran kumaştan daha kalitelidir. Kusur haritasının çıkartılabilmesi için kusurlu görüntülerin tespit edilmesinin yanında kusurların görüntünün hangi piksellerine denk geldiğinin de bilinmesi gerekmektedir.

4.1 Kümelenmiş Otokodlayıcı (NAE) Yaklaşımı

Geleneksel olarak, sinir ağları, görüntülerdeki kusurlu bölgeleri algılamak ve bölütleme için hem kusurlu hem de kusur barındırmayan örneklerin etiketlenmiş görüntülerini kullanarak eğitilir. Genelde kusurlar çok nadir olduğundan, çok sayıda kusur türünü içeren dengeli bir eğitim seti oluşturmak zorlu bir iştir. Etiketlenmiş veri gerektirmeyen denetimsiz öğrenme yaklaşımlarından yararlanan yapay sinir ağları,

kusurlu örnekler olmadan kusurları bölütleme için eğitilebilir.


AE'ler, denetimsiz öğrenme görevleri için en yaygın kullanılan mimarilerdendir. AE'ler, bir kullanıcının manipülasyonuna veya etikete ihtiyaç duymadan bir görüntüyü yeniden oluşturabilir. Yöntem verileri bir darboğazdan geçmeye zorlar ve ardından kod olarak da adlandırılan darboğaz gösteriminden orijinal verileri yeniden yapılandırır. Standart tam bağlantılı AE'ler, görüntülerde düşük performans gösterir ve kabul edilebilir performans için sinir ağının boyutu çok büyük olmalıdır. Bu, zayıf ve yavaş bir eğitime sebep olmaktadır.

Otokodlayıcı yöntemi temel bileşen analizi (PCA) yöntemi ile çok benzerdir. Aslında, otokodlayıcı içinde kullanılan aktivasyon fonksiyonu her katmanda doğrusal ise, darboğazda bulunan öznitelik vektörü (code) doğrudan PCA'nın ana bileşenlerine karşılık gelir. Genelde, otokodlayıcılarda kullanılan aktivasyon fonksiyonu doğrusal değildir, tipik aktivasyon fonksiyonları ReLU (Rektifiye Doğrusal Birim) ve sigmoittir.

Evrişimli otokodlayıcılar ise çekirdek adı verilen filtreler dizisi ve çok sayıda katmanla yerel boyutsal özellikleri yakalayabilir, bir görüntüden üst düzey öznitelikler çıkarabilir. Evrişim ve havuzlama katmanını kullanılarak darboğaz etkisi oluşturan ve bu sayede aynı zamanda bir öznitelik temsili üreten bir kodlayıcı tasarlanabilir. Öznitelik gösteriminden görüntüyü yeniden oluşturan kod çözücü, üst örnekleme ve evrişim katmanları kullanılarak oluşturulabilir.

Evrişimli otokodlayıcılar hatasız örnekler üzerinde eğitildiğinde, CAE'nin yalnızca hatasız örneklerle ilgili öznitelik çıkarma yeteneği kazandığı varsayılır. Bu varsayıma göre, test edilen görüntüde bir kusur olduğunda CAE, çıktısında aynı kusuru yeniden oluşturamayacaktır. Bu özellikten yararlanarak, ağın girdisi olan ve tekrar oluşturduğu görüntünün rezidüsü kullanılarak kusurlar tespit edilebilir ve bölütleme yapılabilir. Fakat, bu varsayımla ilgili önemli bir eksik AE'lerin giriş görüntüsüne göz atma eğiliminde olmalarıdır, bu nedenle AE'ler, dokunun kusur barındırmayan halindense kusurlu giriş görüntüsüne daha benzer bir görüntü oluşturur [56]. Bu göz atma davranışı, AE'lerin eğitim sırasında öğrendiği özniteliklerin bir sonucudur ve bu öğrenilen öznitelikleri istemsiz olarak görüntülerinin kusurlu alanlarını da temsil edebilir.

Bu sorunun üstesinden gelmenin basit bir yolu, daha dar bir darboğaz kullanmaktır. Bu çözüm daha iyi yeniden yapılandırma performansına sebep olur, fakat aynı zamanda yeniden yapılandırma aşamasında detayların kaybolmasına sebep olur. Diğer bir yöntem, CAE'leri Gürültü Giderme AE'lerine benzer şekilde görüntülere rastgele uygulanan kararmaları tahmin etmek için eğitmektir. Ancak, bu yöntem uygulamada gerektirdiği işlem gücü açısından oldukça maliyetlidir.



Şekil 4.1 Önerilen NAE modelinin genel mimarisi

Bu çalışmada, gerçek zamanlı kusur tespiti için, kusurlu görüntüleri kusursuz hallerine dönüştürebilen ve incelenen görüntülerde görülen doku kusurlarının yüzeydeki lokasyonunu işaretleyebilen yeni bir AE mimarisi önerilmiştir. Önerilen yöntem düşük çalışma ve eğitim süresinin yanı sıra, basit bir ağ yapısına sahiptir. Önerilen mimaride, iki adet AE iç içe geçmiş bir yapıda kullanılarak geleneksel yöntemde oluşan ve istenmeyen "göz atma" durumunun giderebilmektedir. İlk AE, görüntünün yeniden yapılandırılması için yararlı öznitelikleri çıkaran evrişimli sinir ağlarından (CNN) oluşur ve bu ağ öznitelik çıkarma AE olarak anılacaktır. Öznitelik çıkarma AE'sinin kodlama modülü E , önce kusurlu girdi görüntüsünü $\tilde{X}$ öznitelik uzayına dönüştürür, burada görüntü tek boyutlu bir öznitelik vektörü C olarak kodlanır. Kodlayıcı modülü doğrusal olmayan bir haritalama işlemi olarak tanımlanabilir ve (4.1) denklemindeki gibi ifade edilebilir; burada W_E , b_E ve φ_E sırasıyla kernelleri, bias vektörlerini ve evrişim işlemini temsil eder.

$$E : X \rightarrow C$$

$$C = E(X) \quad (4.1)$$

$$C = \varphi_E(W_E \circ I + b_E)$$

Kusursuz bir görüntüyü yeniden oluşturmak yerine, tahmin AE P olarak adlandırdığımız ikinci AE, çıkarılan öznitelik vektörünün kusur barındırmayan karşılıklarını tahmin eder. Kusurlu öznitelik vektöründen $\tilde{C}'$ kusursuz bir resim öznitelik vektörü C' tahmin etmek çok daha etkili ve güvenilirdir çünkü AE'nin girdi görüntüsünü veya öznitelik vektörünü kullanarak kopya çekmesi engellenmiş olur. Yeniden yapılandırma modülü doğrusal olmayan bir haritalama işlemi olarak

tanımlanabilir ve (4.2) şeklinde ifade edilebilir; burada W_R , b_R ve φ_R sırasıyla kernelleri, bias vektörlerini ve evrişim işlemini temsil eder.

$$\begin{aligned} C' &= R(\tilde{C}') \\ C' &= \varphi_R(W_R \tilde{C}' + b_R) \end{aligned} \quad (4.2)$$

Son olarak, öznitelik çıkarma AE'nin kod çözücü modülü, tahmini hatasız öznitelik vektörü C' ve girdi görüntü öznitelik vektörü $\tilde{C}'$ 'dan iki görüntü üretir. Sonuç olarak, tahmini kusursuz bir görüntü X' ve yeniden yapılandırılmış görüntü $\tilde{X}'$ elde edilir. Kod çözücü modülü, doğrusal olmayan bir eşleme işlevi olarak tanımlanabilir ve (4.3) şeklinde ifade edilebilir; burada W_D , b_D ve φ_D sırasıyla kernelleri, bias vektörlerini ve evrişim işlemini temsil eder.

$$\begin{aligned} X' &= D(C') \\ X' &= \varphi_D(W_D \circ C' + b_D) \\ \tilde{X}' &= D(\tilde{C}') \\ \tilde{X}' &= \varphi_D(W_D \circ \tilde{C}' + b_D) \end{aligned} \quad (4.3)$$

Tahmini hatasız görüntü X' ile yeniden oluşturulmuş girdi görüntüsü $\tilde{X}'$ arasındaki fark hesaplanır, ardından farkın mutlak değeri denklem (4.4)'de verildiği gibi bir hata haritası EM elde etmek için kullanılır. Hata haritasında AE tarafından modellenemeyen ayrıntıları kaldırmak için orijinal resim $\tilde{X}$ yerine bu iki resim kullanılır.

$$EM = |X' - \tilde{X}'| \quad (4.4)$$

Kusurların yerlerinin saptandığı görüntü S , kusurlar tespit edildikten ve (4.5) içinde gösterildiği gibi sabit eşik T kullanılarak elde edilir.

$$S(x, y) = \begin{cases} 1 & \text{if } EM(x, y) \geq T \\ 0 & \text{otherwise} \end{cases} \quad (4.5)$$

Önerilen modelin genel mimarisi Fig. 4.1'de verilmiştir.

Gerçek zamanlı bir denetim sisteminin tasarımı uzun ve zahmetli bir görevdir. Algoritmaların çalışma süreleri, üretim hızının taleplerini karşılayabilmesi için kesin

ve düşük olmalıdır. Bir hata tespit algoritması yüksek tespit oranları sağlarken aynı zamanda olabildiğince basit olmalıdır. Dahası, algoritma görüntünün içeriğinde bağımsız şekilde bölünmüş görüntüleri paralel olarak işleyebilmelidir. Bu durumda, X eğitim girdi görüntüleri, en küçük tekrarlayan modelin boyutlarına bölünmelidir. Önerilen hata tespit şemasında, parçalanmış görüntülerin işlenmesinde herhangi bir gecikme olmaksızın eğitim ve testler gerçekleştirilir. Yöntem geliştirilirken aydınlatmanın optimal olduğu ve görüntü alma sisteminin kararlı çalıştığı varsayımı yapılmıştır.


NAE'yi az miktarda kusursuz örneklerle eğitebilmek için, parçalanmış görüntülere X_T kasıtlı olarak kusurlar enjekte edilir. Bu adım, DAE eğitime benzer, ancak rastgele gürültü yerine, görüntülere rastgele oluşturulmuş çizgiler, düz ve yarı saydam daireler gibi yapay kusurlar enjekte edilir. Bu yapay kusurlar, ağı eğitmek için deneysel olarak seçilmiştir ve gerçek hayatta sistemlerde karşılaşılan kusurlarla benzer özellikler taşır.

Önerilen mimari iki aşamada eğitilmiştir, öznitelik çıkarma AE eğitimi ilk aşamadır. Bu AE, incelenen görüntüleri tek boyutlu tersinir öznitelik uzayına taşır. Bu kapsamda, hem kusursuz kumaş görüntüler X_T hem de hata enjekte edilen görüntüler $\tilde{X}_T$ birleştirilir ve öznitelik çıkarma AE'yi eğitmek için kullanılır. Yeniden yapılandırılmış görüntülerde en küçük doku lifleri ve minimum boyut kusurları doğru bir şekilde modellendiğinde eğitim başarılı olarak kabul edilir. Öznitelik çıkarma AE, denklem (4.6)'de gösterildiği gibi ortalama kare hatasına L_{fea} göre eğitilir. Denklemden N batch boyutudur.

$$L_{out} = \frac{1}{N} \sum_{i=1}^N \|X_{Ti} - X'_{Ti}\|^2 \quad (4.6)$$

İkinci aşamada, tahmin AE girdilerine karşılık gelen kusursuz özellik vektörünü tahmin etmek için eğitilir. Öznitelik çıkarma AE'nin başarılı eğitiminden sonra, iyi kumaş örnekleri ve hatalı enjekte edilmiş örnekleri, dış AE'nin kodlayıcısından geçirilerek hatalı öznitelik vektörleri $\tilde{C}_T$ ve bunlara karşılık gelen kusursuz öznitelik vektörleri C_T hesaplanır. Kusurlu öznitelik vektörleri ve hatasız öznitelik vektörleri $C_{in} = \tilde{C}_T + C_T$ tahmin AE'unun eğitimi için kullanılır, tahmin AE'sinin bu vektörlere karşılık gelen kusursuz öznitelik vektörlerini $C_{out} = C_T + C_T$ hesaplaması beklenir. Tahmin AE, (4.7)'de gösterildiği gibi, ortalama kareler L_{pr} kullanılarak eğitilir. Eğitim adımlarının şeması şekil 4.2'de verilmiştir.

$$L_{pr} = \frac{1}{N} \sum_{i=1}^N \|C_{in} - C'_{out}\|^2 \quad (4.7)$$




Şekil 4.2 NAE eğitim adımlarının şeması

Kusur tespiti yapılacak olan görüntüler parçalara ayrıldıktan sonra öznitelik AE'nin enkoder ağından geçirilir ve öznitelik vektörü elde edilir. Daha sonra öznitelik vektörüne karşılık gelen kusursuz öznitelik vektörü tahmin AE tarafından tekrar oluşturulur. Kusurlu ve kusursuz öznitelik vektörleri daha sonra öznitelik AE'nin dekoder modülünden geçirilerek düzeltilmiş ve düzeltilmemiş iki görüntü oluşturulur.

Bu iki görüntü basit bir fark işlemi işleminden geçirilir ve kusur haritası çıkartılır. Kusurların olduğu bölgelerin daha net görüntülenebilmesi için kusur haritası basit bir ortalama filtresinden geçirilir. Daha sonra kusursuz test görüntüler üzerinden ROC haritası oluşturulur ve yanlış pozitif parametre (False Positive) değeri sıfır olacak şekilde eşik değeri belirlenir.

4.2 Ayrık Beyinli Otokodlayıcı (SBAE) Yaklaşımı

Bu çalışmada önerilen bir diğer yaklaşım ise Ayrık Beyinli Otokodlayıcı (SBAE) yaklaşımıdır. Bu yaklaşımda genelde RGB renk uzayında oluşturulan ve saklanan ürün görüntüleri daha güçlü özelliklerin çıkarılabileceği Lab renk alanına dönüştürülür. Görüntüler daha sonra iki altkümeye bölünür ve çapraz kanal tahmini yapan SBAE ağında geçirilir. Ortaya çıkan rekonstrüksiyon rezidüsü, kusur tespiti ve segmentasyon için kullanılır.




Şekil 4.3 SBAE algoritmasının şeması

CIELAB temel olarak insan renk algısının matematiksel modellemesi için bir araç olarak sunulmuştur. Bu modelle, 3B renk uzayını kullanarak evrende oluşabilecek tüm renkler matematiksel olarak modellenenebilir. 1940’larda Richard Hunter tarafından kullanılmasına rağmen, anca 1976’da Uluslararası Aydınlatma Komisyonu (CIE) tarafından tanımlanmış ve standartlaştırılmıştır.

CIELAB renk uzayı $C = [L, a, b]^T$ ile ifade edilebilir burada L gri tonlamayı, a ve b ise renkli kanalları ifade etmektedir. Bir görüntü X , H görüntünün Yüksekliği, W Genişliği olmak üzere CIELAB ren uzayında $X \in \mathbb{R}^{H \times W \times C}$ olarak tanımlanabilir. Görüntü iki ayrı alt küme $X_1 \in \mathbb{R}^{H \times W \times C_1}$ ve $X_2 \in \mathbb{R}^{H \times W \times C_2}$ ’ye $C_1 = [L]$ ve $C_2 = [a, b]$ olmak üzere ayrılabilir.

L eksen, renk oluştururken kullanılacak ışık miktarını karakterize eder. En küçük 0 değeri bir uçtaki siyaha karşılık gelir ve 100 değeri, eksenin diğer ucundaki beyaza karşılık gelir. A — eksen, rengin içeriğindeki Yeşil ve Kırmızı oranını gösterir. Minimum -127 (Yeşil) ile maksimum +127 (Kırmızı) değerleri arasında değişir. B — eksen, rengin içeriğindeki Sarı ve Mavi oranını gösterir. Minimum -127 (Mavi) ile maksimum +127 (Sarı) değerleri arasında değişir. Görüntüler RGB renk alanı yerine CIELAB renk uzayında incelenirse, görüntü alt kanallara daha düzgün bir şekilde ayrılabilir.

Zhang ve ark. tarafından ortaya atılan SBAE yaklaşımı iki ayrık alt ağdan oluşmaktadır. Bu yapının alt ağlarının her birine, görüntü kanallarının alt kümeleri sunulur ve diğer görüntü kanallarını tahmin etmesi istenir [57]. Ayrık alt ağlar, giriş görüntüsünün tamamından özellikler çıkarmak için birlikte çalıştırılır. Geleneksel AE’ye benzer şekilde, giriş görüntüsü ve çıkış görüntüsü X ile aynı görüntüdür. Ancak, ayrık ağlar yeniden inşa sürecini bir tahmin sürecine dönüştürür ve bu da sistemin yeniden inşa ve temsil kabiliyetlerini artırır. ayrık beyinli otokodlayıcının diyagramı Şekil 4.3’de verilmiştir. L kanalını içeren Lab renk uzayındaki X_1 alt kümesini kullanarak, a ve b kanallarını içeren X_2 alt kümesini tahmin etmek için bir renklendirme alt ağı F_1 tanımlanabilir. Benzer şekilde, bir alt ağ, (4.8)’de ifade edildiği gibi verilen X_1 ’ dan X_2



Şekil 4.4 Eğitim setinin hazırlanması: (a) orjinal kusursuz görüntüler, (b) görüntülerin 64x64 piksellik parçalara bölünmesi, (c) parçalardan eğitim verilerinin oluşturulması, (d) eğitim verisinin Lab renk uzayına dönüştürülmesi.

'ı tahmin etmek için tanımlanır; burada L_1 ve L_2 (4.12) içinde tanımlanan ortalama kare hata kaybı işlevlerini temsil eder.

$$\begin{aligned} F_1^* &= \arg \min_{F_1} L_1(F_1(X_1), X_2) \\ F_2^* &= \arg \min_{F_2} L_2(F_2(X_2), X_1) \end{aligned} \quad (4.8)$$

İki ayrı alt ağı eğitmek için kullanılan X_1 ve X_2 görüntüleri, Şekil 4.4'da gösterildiği gibi giriş görüntüsünden L ve ab kanalının bölünmesiyle elde edilir. Eğitimden önce, RGB renk uzayındaki görüntüler piksel bloklara bölünür ve daha sonra Lab renk uzayına dönüştürülür.

Eğitim verilerinin hazırlanması, ab 'nin kırmızı ve yeşil kanallar olmak üzere, Şekil 4.3'da verilmektedir. Şekil 4.4 iki ağın giriş, çıkış görüntüleri ve temsilini kısaca göstermektedir.

Yapay sinir ağırları ile kullanılmadan önce eğitim setleri 0 ile 1 arasındaki değerlere normalleştirilmelidir ve veri setleri denklemler (4.9-4.11)'de belirtildiği gibi ölçeklendirilmelidir. Yapay sinir ağırlarından elde edilen çıkışlar, aynı denklemlerin tersi kullanılarak geriye doğru ölçeklenebilir.

$$L_s = \frac{L}{100.0} \quad (4.9)$$

$$a_s = \frac{a + 128.0}{255.0} \quad (4.10)$$

$$b_s = \frac{b + 128.0}{255.0} \quad (4.11)$$

Burada L_s ölçeklenmiş L kanalını, a_s ölçeklenmiş a kanalını ve b_s ölçeklenmiş b kanalını ifade etmektedir.

Yapay sinir ağırları, Denklem (4.12) belirtilen ortalama kareler kayıp fonksiyonu ile eğitilir.


$$Loss(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^N (y - \hat{y}_i)^2 \quad (4.12)$$

Burada $\hat{y}$ tahmin edilen değeri, y gerçek değeri ve N eğitim verilerinin sayısını ifade etmektedir.

4.3 Geliştirilmiş DCGAN Yaklaşımı (M-DCGAN)

Literatürde var olan çözümlerin gerek performansının düşük olması gerekse fazla karmaşık olması sebebiyle endüstriyel uygulamalarda kullanışlı olmadığı gözlemlenmektedir. Çalışmamızda eğitimi ve yapısı literatürdeki diğer yapılara göre daha basit olan ve gerçek zamanlı uygulamalarda kullanılmak üzere geliştirilmiş bir DCGAN yapısına önerilmektedir.

DCGAN, sentetik görüntülerin üretimindeki başarısı ile ünlü olan bir GAN yapısıdır [58]. Bu yapıyı oluşturan üretici ve sınıflandırıcı rakip olarak çalışan iki adet derin evrişimli sinirsel ağıdır. Az sayıda örnek ile denetimsiz eğitilerek birçok sayıda, gerçeğe çok yakın örnekler üretebilir. Standart DCGAN yapısında sınıflandırıcı “gerçek” ve “sahte” görüntüleri ayırt etmek için kullanılan ikili bir sınıflandırıcıdır. Üretici ise girişine verilen beyaz gürültüye karşılık ürettiği gerçekçi görüntüler ile sınıflandırıcıyı kandırmaya çalışır.



Şekil 4.5 Geliştirilen DCGAN yapısı

Standard DCGAN yapısı gerçekçi görüntüler üretmekte başarılı olmasına karşılık görüntülerdeki anomalilerin algılanması ve yerlerini saptanması için yetersiz kalmaktadır. Önerdiğimiz modifikasyon ile sınıflandırıcı direk olarak görüntülerde bulunan anomalileri segmente edebilecektir. Böylelikle tek aşamada eğitilmiş bir modifiye-DCGAN yapısı ile çözülmesi zor olan endüstriyel görüntü işleme problemleri kolaylıkla çözülebilecektir.

Standard DCGAN'da sınıflandırıcı (D), 2 boyutlu bir görüntüyü tek bir skaler değer $D(\cdot)$ 'e indirgeyen standart bir CNN'dir. Sınıflandırıcı çıkışı $D(\cdot)$, sınıflandırıcı (D)'ye verilen girdinin, eğitim verisi X 'den veya üreticiden çıktı olarak alınan $G(z)$ eğitim verisinden olmasının olasılığı olarak yorumlanabilir. D ve G , $V(G; D)$ kayıp fonksiyonuna sahip iki kişilik minimax oyunu ile aynı anda optimize edilir [32].

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (4.13)$$

Sınıflandırıcı, gerçek eğitim örneklerine "gerçek" ve p_z üretilmiş görüntülere de "sahte" etiketi verme olasılığını en üst düzeye çıkaracak şekilde eğitilmiştir. Üretici G ise sürekli olarak sınıflandırıcı kandırılmak için eğitilmektedir. Sınıflandırıcı gerçek ve sahteyi ayırt etmede geliştikçe, üreticide G sınıflandırıcıyı kandırabilmek için daha gerçekçi görüntüler oluşturmaktadır.

Sınıflandırıcının anomalileri bölütleyebilmesi için, Sınıflandırıcının çıkışı olan $D(\cdot)$ 'nin tek bir skaler değer yerine girdi ile aynı boyutlarda olduğu durumda da denklemde verilen formüller yine geçerlidir. Fakat burada temel sorun sınıflandırıcı D 'nin çıkışındaki çıktılar girdideki o bölgeye karşılık gelen lokal özellikleri temsil etmeyebilir. Bunun önüne geçmek için tüm boyut düşürücü fonksiyonlar sınıflandırıcının yapısında çıkartılır ve sadece evrişim fonksiyonları ile leaky relu aktivasyon fonksiyonları kullanılır. Evrişimli fonksiyonlar girişte fiziksel olarak yakın olan girişlerin, yakın olan çıkışlarla ilişkili olduğu mantığına dayanarak ortaya atılmıştır. Bu şekilde bir sınıflandırıcı ile eğitim birebir standart DCGAN ile aynı olmasına rağmen test aşamasında sınıflandırıcıya verilen görüntüdeki anomalileri segmente edebilme yeteneği kazanır.


Üreticinin önerdiğimiz yapıdaki görevi standart DCGAN yapısındaki gibi bize normal veri dağılımdan örnek oluşturmaktan daha çok, sınıflandırıcıya sahte görüntüler üretmektir. Üreticinin zamanla daha gerçekçi görüntüler üretmesi, sınıflandırıcının görüntülerin normal dağılımlı kavrayabilmesini sağlar. Bu standart evrişimli ağlar ile mümkün olmayan bir konsepttir.

Fakat boyut düşürmenin kullanılmadığı evrişimli ağlarda en büyük problem aşırı kernel parametre sayısından dolayı ağın çok büyük boyutlara ulaşması hem de ağın çalışma hızın çok yavaşlamasıdır. Bu problemi çözmek için ise görüntüleri boyutlarının küçültüldüğü fakat mekânsal özelliklerinin korunduğu bir gizli uzaya taşınmasını önerildi.

Görüntü sıkıştırma, az sayıda bilgi depolamak, işlemek veya iletmek için görüntü verilerindeki fazlalığın azaltılması yani orijinal görüntüdeki sadece önemli bilgilerin saklanmasıdır. Son birkaç yıldır görüntü sıkıştırma için en popüler teknik ayrık kosinüs dönüşümüdür (DCT). DCT, veri sıkıştırma için kodlayıcı (lineer dönüştürücü) olarak kullanılır. DCT, sabit bir temel fonksiyon setine sahip dik bir dönüşümdür. DCT, görüntü alanını bir frekansa eşlemek için kullanılır. DCT'nin birçok avantajı vardır:

1. Görüntü verilerini yoğun olarak düşük frekanslarla ifade etme özelliğine sahiptir.
2. Engelleme artefakt etkisini azaltma özelliğine sahiptir ve bu etki alt görüntüler arasındaki sınırların görünür hale gelmesinden kaynaklanmaktadır [59].

İlk olarak siyah-beyaz(gray-scale) görüntüler 8×8 bloklara bölünmektedir. 8 bitlik görüntü de bloktaki her piksel $[0, 255]$ aralığındadır. Orijinal bloktaki her öğeden orta noktası (128 değeri) çıkarılarak ortalaması 0 olan dağılım üretilir, böylece değer aralığı $[0, 255]$ 'den $[-128, 127]$ 'ye kaydırılır. Görüntüler DCT tarafından farklı



Şekil 4.6 DCT ile görüntü sıkıştırarak boyut küçültme algoritması

frekanslardaki parçalara ayrılır. Bir sonraki niceleme (quantization) adımında daha az önemli frekansları atılır ve dekompresyon adımı görüntüyü almak için önemli frekansları kullanır. Denklem 4.14’de $u = 0, \dots, N - 1$ and $v = 0, \dots, N - 1$ olmak üzere ileri 2D-DCT dönüşümün formülü verilmiştir.

$$F(u, v) = \frac{2}{N} C(u)C(v) \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \cos\left[\frac{\pi(2x+1)u}{2N}\right] \cos\left[\frac{\pi(2y+1)v}{2N}\right] \quad (4.14)$$

Burada $N = 8$ ve $C(k)$ fonksiyonu denklem 4.15’deki gibidir.

$$c(k) = \begin{cases} 1/\sqrt{2} & \text{for } k = 0 \\ 1 & \text{otherwise} \end{cases} \quad (4.15)$$

Denklem 4.14’de $x = 0, \dots, N - 1$ and $y = 0, \dots, N - 1$ olmak üzere ileri 2D-DCT dönüşümün formülü verilmiştir.

$$F(x, y) = \frac{2}{N} \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} C(u)C(v) f(u, v) \cos\left[\frac{\pi(2x+1)u}{2N}\right] \cos\left[\frac{\pi(2y+1)v}{2N}\right] \quad (4.16)$$

Burada $N = 8$ ve $C(k)$ fonksiyonu denklem 4.15’deki gibidir.

Bu aşamada fazlalık olarak kabul edilen veriler atılır. Dönüştürülmüş görüntü olan DCT matrisi seçilen niceme matrisine (Q) bölünür. Elde edilen matrisin değerleri daha sonra yuvarlanır. Nicelenen katsayı denklem 4.17’de tanımlanmıştır ve evrik

işlem denklem 4.18 ile gerçekleştirilebilir. Burada evrik işlem ile orijinal görüntünün elde edilmesi mümkün değildir.

$$F(u, v)_{Quantization} = round\left(\frac{F(u, v)}{Q(u, v)}\right) \quad (4.17)$$

$$F(u, v)_{deQ} = F(u, v)_{Quantization} \times Q(u, v) \quad (4.18)$$

Nicemleme matrisindeki elemanlar sıkıştırma oranını belirler, daha büyük değerler daha çok sıkıştırma anlamına gelmektedir. Tipik bir nicemleme matrisi (orijinal JPEG Standardında belirtildiği gibi %50 kalite için) aşağıdaki gibidir:

$$Q = \begin{bmatrix} 16 & 11 & 10 & 16 & 24 & 40 & 51 & 61 \\ 12 & 12 & 14 & 19 & 26 & 58 & 60 & 55 \\ 14 & 13 & 16 & 24 & 40 & 57 & 69 & 56 \\ 14 & 17 & 22 & 29 & 51 & 87 & 80 & 62 \\ 18 & 22 & 37 & 56 & 68 & 109 & 103 & 77 \\ 24 & 35 & 55 & 64 & 81 & 104 & 113 & 92 \\ 49 & 64 & 78 & 87 & 103 & 121 & 120 & 101 \\ 72 & 92 & 95 & 98 & 112 & 100 & 103 & 99 \end{bmatrix} \quad (4.19)$$

Nicemleme, daha az önemli olan yüksek frekanslı DCT katsayılarının çoğunu sıfıra indirmeyi amaçlar, görüntü ne kadar çok sıfır barındırırsa o kadar iyi sıkıştırılmıştır. Görüntüyü yeniden yapılandırmak için daha düşük frekanslar kullanılır, çünkü en çok bilgi bu frekanslarda saklıdır.

Nicemlemeden sonra, zig-zag dizisi şekil 4.6'te gösterildiği gibi nicemlenmiş katsayıların ilk 10 tanesini sıralar. Zig-zag dizisinde, önce düşük frekanslı (tipik olarak daha yüksek değerlerle) ve daha yüksek frekanslı katsayıları kodlar (genellikle sıfır veya neredeyse sıfır). Sonuçtan, 8×8 'lik bir görüntü parçası $1 \times 1 \times 10$ 'luk bir diziye dönüştürülür. Böylelikle, boyutları küçültülmüş ve sıkıştırılmış görüntüler artık daha küçük yapay zeka ağları ile işlenebilir. Bu işlemin tek olumsuz yanı, anomali segmente edilirken en küçük tespit edilebilecek kusurun 8×8 piksel boyutunda olmasıdır.

4.3.1 Ablasyon Çalışmaları

Ablasyonun asıl anlamı vücut dokusunun cerrahi olarak çıkarılmasıdır. "Ablasyon çalışması" teriminin kökleri 1960'lar ve 1970'leride deneysel nöropsikoloji alanında,

hayvanların beyinlerinin bazı bölümlerinin davranışları üzerindeki etkisini incelemek için çıkarılmasına dayanmaktadır.

Makine öğrenimi ve özellikle karmaşık derin sinir ağları bağlamında, ağın davranışını daha iyi anlamak için ağın belirli bölümlerinin kaldırılıp sonuçların incelenmesi prosedürüne “ablasyon çalışması” adı verilmiştir. Ablasyon çalışmaları, derin öğrenme araştırması için çok önemli olduğu çoğu kez vurgulanmıştır. Sisteminizdeki nedenselliği anlamak ve güvenilir bilgi üretmenin en basit yoludur olarak gösterilmiştir [60]. Bunlarla beraber ablasyon çok az çaba gerektiren bir yöntemdir. Herhangi bir karmaşık derin öğrenme modelinde, performans kaybı olmadan birkaç modül kaldırılabilme (veya bazı eğitilmiş özellikleri rastgele olanlarla değiştirebilme) olasılığı oldukça yüksektir.

Ablasyon deneyleri sonrasında görüntü sıkıştırma kullanmanın gereksiz olduğu sonucuna ulaşıldı. Bunun yerine çok daha iyi sonuçlarla birlikte daha da iyi algoritma çalışma süreleri elde edebiliğimiz sınıflandırıcı yapısını kademeli evrişim katmanları içerecek şekilde değiştirdik. Aslında, sonuçlarımız çok daha hızlı olmakla birlikte en iyi performans gösteren son teknoloji yöntemlerle neredeyse aynıdır.

5


DENEYSEL SONUÇLAR

5.1 Deneyisel Sistem

Bilgisayar görmesine dayalı otomatik optik muayene sistemleri, insan gözüyle hatanın hızlı ve doğru şekilde ayırt edilmesinin oldukça zor olduğu durumlarda ve uzun vadede sistem maliyetinin makul düzeyde olduğu durumlarda başvurulacak bir yoldur. Bununla birlikte, bu sistemler için en önemli bileşenlerden biri kusur tespiti için kullanılacak görüntü işleme yöntemlerine uygun görüntü alma düzeneğidir. Görüntü alma sürecinin performansı, başta aydınlatma olmak üzere, görüntülenene cisimlerin şekli, geometrisi ve hammaddesi, görüntü alma düzeneğinin esneklik kabiliyeti, kullanılacak kamera ve lenslerin parametreleri gibi birçok etkene ve bu komponentlerin uyum içinde çalıştırılmasına bağlıdır.

Kullanımı kolay olan alan tarama kameraları görsel muayene sistemlerinde uzun zamandır başarılı ile kullanılmaktadır. Fakat kullanım kolaylığı ve nispeten ucuz olması gibi avantajlarının yanında optik muayene sistemlerinde kullanılmalarının önemli olan birkaç sınırlaması mevcuttur. Örneğin, inceleme altındaki bir nesne büyükse, sürekli hareket ediyorsa veya görüntüleme görevi bulanıklık olmadan son derece yüksek çözünürlük gerektiriyorsa, alan taramalı kameralar yetersiz kalmaktadır. Bu tarzdaki problemlerin çözümü için çizgi taramalı kamera kullanılması iyi bir seçim olacaktır.

Alan taramalı ve çizgi taramalı kameralar arasında temel fark varlıklardan en önemlisi, bir görüntünün nasıl elde edildiğidir. Tüm nesneyi tek bir karede yakalayan alan tarama kamerasının aksine, çizgi tarama kamerası, yüksek yoğunluklu aydınlatma eşliğinde nesne boyunca satır satır görüntü veren piksel satırı kullanır. Tamamlanmış bir görüntü, bu çizgilerin birbirine eklenmesi ile oluşur. Bir nesnenin yetersiz veya fazla örneklenmesini önlemek için, konveyöre bağlı programlanabilir bir enkoder kamerayı oluşturacağı darbeler ile hareketli sistem ve ışıklandırma ile senkronize eder. Görüntünün her satırı daha sonra yazılımla analiz edilmek üzere bir çerçeve oluşturmak suretiyle birbirine eklenir. Bu tasarımı nedeniyle, çizgi taramalı kameralar




Şekil 5.1 Geliştirilen sistemin şeması

silindirik nesnelerin düz bir görüntüsünü üretmede, çok büyük nesneleri yüksek çözünürlüklü görüntülemeye veya montaj hatlarındaki parçalar gibi sürekli hareket halindeki nesnelerin görüntülerini elde etmede çok iyi sonuçlar üretebilir.

Bütün bu gereksinimlerin yanı sıra, görüntü işlemeye dayalı kusur tespitine yönelik görüntü alma sürecinin performansını hayati şekilde etkileyen en önemli etkenlerden birisi ortam aydınlatmasıdır. Görüntü alma süreci, cisimlerden ya da ortamdan yansıyan her türlü istenmeyen ışığı yok edecek şekilde baskın olan aynı zamanda, görüntü alma alanındaki hedef bölgeleri düzgün dağılan şekilde ışıklandıran bir aydınlatma bileşenine sahip olmalıdır.

Endüstriyel amaçlı olarak kullanılması beklenen optik muayene sistemleri, çoğu durumda çok sayıda üretilen parçalardaki kusur tespitini amaçlamaktadır. Bu sebepten dolayı, görüntü alma sürecinin gerçek zamanlı ya da gerçek zamana yakın olması gerekmektedir. Dolayısıyla, görüntü alma süreci belli sayıda parçanın belli zaman aralıkları içinde işlenmesi ve sınıflandırmasını sağlayacak şekilde yapılandırılmalıdır. Bu bağlamda, kusur tespiti yapılacak olan ürünlerin görüntülerinin hızlı şekilde alınması temel bir gereksinim olarak ortaya çıkmaktadır.




Şekil 5.2 Geliştirilen sistemin görüntüsü 1

Böyle bir gereksinimi karşılamak için çoğunlukla enkoder, motor, aydınlatma ve görüntü işleme yazılımını senkronize etmek gerekmektedir.

Görüntü almak üzere kurulan mekanik düzenek, bant üzerine monte edilebilmekte ve üzerindeki kamera ve aydınlatma cihazlarının yüksekliklerini ayarlayabilmek için hareket ettirilebilen bağlantılı parçalarına sahiptir. Görüntü alma sürecinde, düzgün dağılan baskın bir ortam ışığı sağlayan bir aydınlatma sistemi ile tasarım yapılmıştır.

Geliştirilen sistemde offline eğitim ve düşük hızlardaki bantta kullanılması için iki adet alan taramalı kamera kullanılmıştır. Hızlı hareket eden bantlarda kullanılmak için ise bir adet çizgi taramalı kamera bulunmaktadır. Kusurların sağlıklı bir şekilde anlatılabilmesi için algılanması istenilen minimum kusur boyutunun beş piksele denk gelmesi gerekmektedir. Tüm kameralar lensler yardımı ile görüş alanı 1 mm'ye minimum beş piksel karşılık gelecek şekilde ayarlanmıştır. Daha sonra ışıklandırma ile beraber bir bant üzerine yerleştirilmiştir. I/O kablosu ile bant üzerindeki enkoderden gelen tetiklemeler kamera ile iletilecek ve kameraların senkronizasyonu sağlanacaktır. Geliştirilen sistemin şeması şekil 5.1'de verilmiştir. Aynı zamanda sistemin görüntüleri de şekil 5.2 ve 5.3'te verilmiştir.

PC'nin ethernet portu üzerinden PLC ile haberleşebilmekte ve bantın hızı




Şekil 5.3 Geliştirilen sistemin görüntüsü 2

ayarlanabilmektedir. Enkoderden gelen sinyaller vasıtasıyla yüzeyin görüntüleri alınmaktadır. Bu sırada kamerada biriken görüntüler görüntü alma işlemi sonunda PC'ye ethernet üzerinden aktarılmakta ve hata tespit algoritması girdisi olacak şekilde işlenmektedir.


5.1.1 Geliştirilen Arayüzlü Program

Sistemin bir kullanıcı tarafından kontrol edilebilmesi için bir arayüz geliştirilmiştir. Şekil 5.4'de verilen arayüz, kamera ve PLC ile haberleşerek yüzeyin taranması işlemini başlatmaktadır. Ethernet bağlantısı vasıtasıyla elde edilen görüntüleri işler ve ürünün kusurlu olup olmadığı saptar. Görüntü elde edildikten sonra 0.1 sn içerisinde sonuç ekranda gösterilmektedir. Arayüz üzerinde kullanılan kameranın tipinin seçilmesi için bir liste bulunmaktadır. Kamera seçildikten sonra kameranın tipine göre görüntünün alınması için gerekli kamera ayarlarının girişine izin verilmektedir. GAN yöntemi ile alınan örnek bir sonuç şekil 5.4 ve NCAE ile alınan örnek bir sonuç 5.5'de verilmiştir. Arayüzün sol alt tarafında görüntü alma stratejisini sürekli veya tek sefer görüntü alma olarak belirlenebildiği bir alan bulunmaktadır. Görüntüler alındıktan sonra seçili olan yöntem üzerinden kusur denetimi yapılmakta ve ekrana yazdırılmaktadır. Giriş ve çıkış görüntülerinin kaydetme özelliği bulunmaktadır.

Alınan görüntünün ve oluşturulan sonuç görüntüsünün kaydının alınabilmesi için bir dosya yolu istenmektedir. Sonuçlarda belirtilen kusurların lokasyonları ve adetleri bir rapor olarak kaydedilmektedir. Son olarak kusur olarak sayılabilecek minimum kusur derinliğinin ve çizik boyutunun seçilebildiği iki adet parametre eklenmiştir.



Şekil 5.4 Arayüz programında GAN yöntemi örneği



Şekil 5.5 Arayüz programında NAE yöntemi örneği

5.2 Deneysel Sonuçlar

Geliştirilen algoritmalar MVTec Anomaly Detection veriseti kullanılarak denenmiştir [31]. Veriseti, eğitim ve doğrulama için 3629 görüntü ve test için 1725 görüntü

bulundurur ve 15 kategoriden oluşur. Fakat algoritma proje konumuz ile alakalı tekstil ürünü olan halı kategorisi üzerinde test edilmiştir. Eğitim seti sadece kusursuz görüntülerden oluşmaktadır. Test seti, çeşitli kusur türlerini içeren görüntüler ve kusursuz görüntülerden oluşur. Kusurlar, gerçek endüstriyel muayene senaryolarında ortaya çıkabilecek anormalliklere benzeyecek şekilde manuel olarak üretilmiştir. Tüm görüntü çözünürlükleri 1024 x 1024 piksel boyutundadır. Görüntüler yüksek kontrollü aydınlatma koşullarında elde edilmiştir. Her kusurlu görüntü bölgesi için piksel hassasiyette bölütlenmiş sonuç görüntüsü bulunmaktadır.

Bu çalışmada önerilen optik muayene sistemi kusurları görmeden eğitildiğinden bir çeşit anomali tespiti algoritması gibi düşünülebilir. Anomali tespiti için geliştirilen yöntemler genellikle görüntü düzeyinde doğru sınıflandırılan görüntülerin oranı ve piksel düzeyinde ise doğru sınıflandırılan piksellerin oranı kullanılarak değerlendirilir. Bununla birlikte, diğer son teknoloji yöntemde olduğu gibi, önerilen yöntemler görüntü düzeyinde zaten beklentilerin çok üzerinde performans göstermektedir. Çoğu uygulamada, anomalinin şeklinin, boyutunun ve konumunun tam olarak belirlenmesinin başarılı bir görsel inceleme için gerekli olduğu da düşünülerek, bu çalışmada temel olarak bölütleme performansına odaklanılmaktadır.

Önerilen yaklaşımlar, test görüntüsündeki her piksel bloğu için bir anormallik puanı üretebilir. Bu piksel bloklarının boyutu, kullanılan yöntem ve dizayna göre değişmektedir. Bu piksel blokları için anomali değerleri üretilmesine rağmen diğer yöntemlerle karşılaştırılabilmesi için performansları piksel düzeyinde incelenecektir. Anomali puanları [0,1] arasında değerler alabilir, bölütleme sonuçlarını kesin gerçek görüntüleri ile karşılaştırmak için bir eşik değeri belirlenmelidir.

Eşikleme işlemi yapılarak bir piksel anormal veya normal olarak etiketlenir. Bölütleme başarısını değerlendirmek için dört temel değer hesaplanması gerekir. Gerçek pozitif piksellerin sayısı (TP), yanlış pozitif piksellerin sayısı (FP), gerçek negatif piksellerin sayısı (TN) ve yanlış negatif piksellerin sayısı (FN). Anormal olarak etiketlenen bir piksel, doğru sınıflandırılmışsa TP olarak kabul edilir, aksi takdirde FP olarak kabul edilir. Benzer şekilde, normal olarak etiketlenen bir piksel, doğru şekilde sınıflandırılmışsa TN olarak kabul edilir, aksi takdirde yanlış negatif FN olarak kabul edilir. Bu değerler denklem (5.1-5.4)'de verilmiştir. Denklemde G , görüntü piksellerinin gerçek sınıflarını temsil eder; burada A , piksellerin anomali puanlarıdır ve t , eşiği temsil eder.

$$TP = \sum_{i=1}^n \{G_i = 1\} \cap \{A_i > t\} \quad (5.1)$$

$$FP = \sum_{i=1}^n \{G_i = 0\} \cap \{A_i > t\} \quad (5.2)$$

$$TN = \sum_{i=1}^n \{G_i = 0\} \cap \{A_i \leq t\} \quad (5.3)$$

$$FN = \sum_{i=1}^n \{G_i = 1\} \cap \{A_i \leq t\} \quad (5.4)$$

En yaygın olarak kullanılan bölütleme performans metrikleri bu değerlerden türetilir. Önerilen yöntemi farklı bakış açılarıyla değerlendirmek için farklı metrikler kullanılır. Gerçek pozitif oran (TPR), yanlış pozitif oranı (FPR), kesinlik (PRC) ve duyarlılık (RCL) metrikleri denklem (5.6-5.8)'de tanımlanmıştır.

$$TPR = \frac{TP}{TP + FN} \quad (5.5)$$

$$FPR = \frac{FP}{FP + TN} \quad (5.6)$$

$$PRC = \frac{TP}{TP + FP} \quad (5.7)$$

$$RCL = \frac{TP}{TP + FN} \quad (5.8)$$

Yaygın olarak kullanılan diğer bir metrik, önerilen yöntemle anormal olarak etiketlenmiş pikseller ile gerçek etiketler arasındaki örtüşme oranıyla hesaplanan kesiştirilmiş bölgeler metriğidir (IoU). Bu metriği hesaplamak için kullanılan denklem (5.9)'de verilmiştir.

$$IoU = \frac{TP}{TP + FP + FN} \quad (5.9)$$

Çalışmalarda performans yöntemlerini değerlendirmek için bölge düzeyinde bir puan olan bölge başına örtüşme de (PRO) kullanılmıştır. Piksel düzeyindeki puanların yanı sıra, bölge düzeyindeki puanlar, yöntemin küçük anomalileri doğru şekilde sınıflandırma yeteneğini daha iyi yakalar. Bölge düzeyinde puanlar her görüntü için

denklem (5.10)'deki gibi hesaplanır. Denklemde A , eşikten sonra anormal olarak etiketlenen pikseller kümesini temsil eder, G , gerçek anormal pikseller kümesini temsil eder ve N , test görüntülerinin sayısıdır.

$$PRO = \frac{1}{N} \sum_i^N \frac{A_i \cap G_i}{G_i} \quad (5.10)$$

Bahsedilen metriklerin tümü bir eşik değerine bağlıdır. Seçilen eşığe göre sonuçlar değişebileceğinden, çeşitli eşik değerleri için puanlar hesaplanır ve eğriler halinde çizilir. Önerilen yaklaşımı diğer yöntemlerle güvenilir bir şekilde karşılaştırmak için eğrinin altındaki alan (AUC) yaygın bir şekilde kullanılır. AUC ne kadar yüksek olursa, modelin piksel sınıflarını tahmin etmedeki performansı o kadar iyi olur. Benzer şekilde, AUC ne kadar yüksek olursa, model anormal pikselleri ve normal pikselleri ayırt etmede o kadar iyidir.

Geliştirilen algoritmaların hız ve performans sonuçları irdelenmiştir. Diğer popüler metotlar ile karşılaştırılmış. Karşılaştırılan metotların kötü performansları veri setinin ne kadar zor olduğunu göstermektedir ve önerilen metotların başarısını da ortaya çıkarmaktadır.


5.2.1 Kümelenmiş Otokodlayıcı (NAE) Yaklaşımı Sonuçları

Önerilen metodun kusur tespit ve kusur bölütleme performanslarının diğer popüler metotlarla karşılaştırılması tablo 5.1'de gösterilmiştir. Kusurlu görüntüler ve onların onarılmış görüntüleri ile beraber eşik değeri sonrasında elde edilen segmentasyon görüntüleri şekil 5.6'te verilmiştir.

Tablo 5.1 Geliştirilen algoritmanın kusurlu görüntüler üzerindeki performansı ve diğer yöntemler ile karşılaştırılması: kusursuz görüntülerin doğru tespit edilme oranı (üst sıra) ve kusurlu görüntüler doğru sınıflandırılması oranı (alt sıra) verilmişti, bu iki değerin en yüksek ortalaması olan yöntem kalın punto ile vurgulanmıştır.

Per.	NAE	AE (SSIM)	AE (L2)	AnoGAN	CNN Feature Dictionary	Texture Inspection
Algılama	0.97	0.43	0.57	0.82	0.89	0.57
Oranı	0.95	0.97	0.42	0.16	0.36	0.61
Seg.	0.78	0.69	0.38	0.34	0.20	0.29


Vanilya AE'lerin ve Denoising AE'lerin standart AE metotlarının rekonstrüksiyon gücünü önerilen metot ile görsel olarak karşılaştırabilmek için şekil 5.9'de aynı



Şekil 5.6 Geliştirilen NAE yönteminin diğer popüler yaklaşımlarla karşılaştırılması

katmanlara sahip olacak şekilde eğitilmiş yapıların sonuçları verilmiştir. Bu sonuçlarda yapının diğer yöntemlerden daha üstün olduğu açıkça görülmektedir. Daha önce bahsedildiği gibi, hem AE'yi hem de vanilla AE'yi kusursuz bir görüntüyü yeniden oluşturmada başarısız olmasının en önemli nedeni, bunların giriş görüntüsüne olan doğrudan bağlantılarının AE'lerin kopya çekmesine sebep olmasıdır. Önerilen yöntem, en zorlu durumlarda bile kusurlu görüntüden kusursuz bir numuneyi yeniden oluşturabilir.


Önerilen yöntem, 32 GB RAM, Intel i7-9700k işlemci ve Windows 10 64 bit işletim sistemi ile donatılmış Nvidia RTX 2080 GPU'lu bir bilgisayarda eğitilmiştir. Ağ, 6 saatin altında eğitilebilir. Algoritmanın çalışma süresi 1024x1024 çözünürlüklü bir görüntü için 400 ms'dir. Bir mm'nin 5 piksele karşılık geldiği ve yöntemimizin paralel çalışma için uygun olduğu düşünüldüğünde, algoritmanın 0.5 m/s'de akan kumaş ağlarını birkaç paralel kamera ile inceleyebileceği sonucuna varılabilir. Ayrıca literatürdeki çoğu modelden farklı olarak, bu ağ sadece 300 MB boyutundadır, gömülü sistemlerde kullanılabilir.



Şekil 5.7 Geliştirilen NAE yönteminin restorasyon gücünün popüler yaklaşımlarla karşılaştırılması

5.2.2 Ayırık Beyinli Otokodlayıcı Yaklaşımı Sonuçları

Önerilen yaklaşımın performansı, renk, kesme, katlama, yapışkan ve delinme kusurları olan deri numuneleri kullanılarak değerlendirilmiştir. Kusursuz örnekler de dahil olmak üzere toplam 132 görüntü test edilmiştir. Bu testlerde, görüntüler eğitimden önce parçalanır ve daha sonra LAB renk uzayına aktarılır. Veriler $[0, 1]$ aralığına normalleştirilir ve iki eğitimli ağı sunulur. AE'lerin doğası nedeniyle, yeniden yapılandırılan görüntüdeki kusurlu bölgeler yüksek kalıntılar üretir. Kusur örnekleri şekil 5.8'de verilmiştir.




Şekil 5.8 Kusur barındıran görüntü örnekleri

Test için kullanılan görüntüler ön hazırlıklardan sonra ağlara sunulur. Ağların tekrar oluşturduğu görüntüler incelendiğinden kusurların iyileştirildiği gözlemlenebilir. Çıkış ve giriş görüntüleri arasındaki fark hesaplanarak, giriş görüntüsünün kusurlu bölgeleri algılanır. Fark görüntüsünde var olan gürültüyü gidermek için eşik filtreleme ve morfolojik işlemler gerçekleştirilir ve bir hata görüntüsü oluşturulur. Sonuçlar şekil

5.9’da verilmiştir.

Tablo 5.2 Geliştirilen SBA yönteminin performansının ve diğer yöntemler ile karşılaştırılması: kusursuz görüntülerin doğru tespit edilme oranı (üst sıra) ve kusurlu görüntüler doğru sınıflandırılması oranı (alt sıra) verilmiştir, en yüksek performans kalın punto ile vurgulanmıştır.

Performance	SBA	AE (SSIM)	AE (L2)	AnoGAN	CNN Feature Dictionary	Texture Inspection
Algılama	0.9687	0.00	0.06	0.91	0.63	0.00
Oranı	0.9565	0.92	0.82	0.12	0.71	0.99
Seg.	0.6723	0.71	0.67	0.34	0.74	0.98



Şekil 5.9 Sonuçlar: yukarıdan aşağıya doğru, giriş görüntüsü, tekrar oluşturulan görüntü, el ile işaretlenmiş kusur haritası, önerilen yapı tarafından işaretlenmiş kusur haritası.

Önerilen yapının başarısını tablo 5.2’de verilmiştir. Tablodaki karşılaştırmalı yöntemlerin performans ölçümleri, MVTec Anomali Tespit Veri Kümesini de içeren ilgili yayından alınmıştır [31]. Tablo 5.2’de yapılan testler sonucunda elde edilen görüntülerin sınıflandırılmasındaki başarı oranlarını gösterir. Algılama oranlarının ilk satırında, kusursuz veriler için deney sonuçları ve ikinci satırında ise kusurlu veriler

için sonuçlar verilmiştir. Segmentasyon sonuçları, kusurlu bölgeleri etiketlemenin başarı oranı olarak ortaya çıkmıştır. Algoritmanın çalışma hızı 1024 piksellik bir görüntü için 800 milisaniyedir. Eğer 1 mm'ye 5 piksel düştüğünü kabul edersek ve yöntemimizin paralel çalışmaya müsait olduğunu da düşünürsek algoritmanın 0.25 m/s hızında akan bir kumaş parçasının paralel birkaç kamera ile gerçek zamanlı muayene edebileceği söylenebilir.

5.2.3 Önerilen Geliştirilmiş DCGAN Yaklaşımı Sonuçları

Bu bölümde önerilen DCGAN yapısı, üzerinde çalışılması zor ve karmaşık olan bir veri seti ile denenmiş ve performans sonuçları verilmiştir. Kumaş kusurları genel yapıyı bozan ve az rastlanılan yapılar olduğundan anomali olarak ele alınabilir. Tasarlanan yapı performansı birkaç açıdan ele alınacak fakat segmentasyon performansı üzerinde durulacaktır.


Kumaşlarda kusurun doğru bir şekilde denetlenebilmesi için kusurun algılanması ile beraber şeklinin ve boyutunun hassas bir şekilde saptanması gerekmektedir. Yöntemin performansı bu iki husustaki başarısına bağlıdır. Kusur algılama performansının değerlendirilebilmesi için doğruluk (ACC), TPR, FPR ve PRC değerleri kullanılmıştır. Diğer metotlarla yapılan karşılaştırmalı sonuçlar tablo 5.3'da verilmiştir.

Fig. 5.10'de verilen alıcı işletim karakteristik (AUC - ROC) eğrisi, çeşitli eşik değerleri için sınıflandırma probleminin performans ölçümüdür. ROC bir olasılık eğrisidir ve AUC sınıflandırıcının performansının veya ölçüsünü temsil eder. Modelin sınıfları ne kadar ayırt edebildiğini gösterir. AUC ne kadar yüksek ise, modelin sınıfları doğru olarak tahmin etme performansı o kadar iyidir. Analoji ile, AUC ne kadar yüksekse, model kusurlu olan pikselleri ve kusurlu olmayan pikselleri ayırt etmekte o kadar iyidir. ROC eğrisi, TPR'nin y ekseninde ve FPR'nin x ekseninde olduğu FPR'ye karşı TPR ile çizilir. Şekil'de verilen lineer $y = f(x)$ eğrisi rasgele seçim yapan bir sınıflandırıcıyı temsil etmektedir. MVTEC veri setinin tanıtıldığı çalışmada en yüksek AUC-ROC değeri 0.88 olarak verilmiştir.

Şekil 5.11'de önerilen yapının datasette bulunan kusur çeşitlerine uygulandıktan sonra oluşan segmentasyon sonuçlarında örnek görüntüler bulunmaktadır. Yukarıdan aşağıya doğru renk, kesik, delik, metal kalıntıları ve iplik kusurlarından örnekler verilmiştir. Son olarakta yapının segmentasyon sonuçları kırmızı, bazı alınan el ile segmentasyon sonuçları mavi renk ile gösterilmiştir. Önerilen yöntem bu denli zor bir datasetten dahi kusurları başarılı olarak segmente edebilmektedir. Fakat segmentasyon başarısının hataların büyüklüğüne bağlı olduğu gözlemlenmiş. İnce ve küçük hatalardan eksiklerinin olduğu gözlemlenmiştir. Önemli bir not segmentasyon

Tablo 5.3 Performansın yaygın olarak kullanılan diğer yöntemlerle karşılaştırılması: yukarıdan aşağıya doğru sırasıyla, doğru sınıflandırılmış kusursuz görüntüler, doğru sınıflandırılmış kusurlu görüntülerin oranı, segmentasyon performansı ve AUC-ROC değerleri verilmiştir.

Kategori	Önerilen	AE (SSIM)	AE (L2)	AnoGAN	CNN Feature Dictionary	Texture Inspection
Halı	0.96	0.43	0.57	0.82	0.89	0.57
	1.00	0.90	0.42	0.16	0.36	0.61
	0.58	0.69	0.38	0.34	0.20	0.29
	0.96	0.87	0.59	0.54	0.72	0.88



Şekil 5.10 Önerilen yapının alıcı işletim karakteristiği (AUC - ROC)


başarısının seçilen eşik değere bağlı olduğu göz önünde bulundurulmalıdır. Ek olarak, önerilen yapı kusur değil anomali bulmak için eğitildiğinden kusur kabul edilmeyen fakat esneme gibi durumları da işaretlemektedir.

Önerilen yapı aynı zamanda yeni eğitim görüntüleri oluşturmak içinde kullanılabilir. Şekil 5.12’de bu görüntülere yer verilmiştir. Şekilde sol tarafta bulunan görüntüler MVTEC veri setinden, sağ tarafta bulunan görüntüler ise önerilen yapı tarafından oluşturulmuştur.

Algoritmanın çalışma hızı 1024 piksellik bir görüntü için 300ms’dir. Eğer bir mm ye 5 piksel düşüğünü kabul edersek ve yöntemimizin paralel çalışmaya müsait olduğu da düşünülürse algoritmanın 0.5 m/s hızlarda akan bir kumaş parçasının paralel birkaç kamera ile denetleyebileceğini görülebilir. Ayrıca literatürdeki birçok modelin aksine



Şekil 5.11 Örnek sonuç görüntüleri: önerilen yapının tespit ettiği anomaliler kırmızı renk, el ile işaretlenen kusurlar mavi renk ile verilmiştir.



Şekil 5.12 E-DCGAN ile oluşturulan sentetik kumaş görüntüleri(sağda) ve verisetinden alınan kumaş görüntüleri(solda)

sadece 11 Mb'lık yer kaplayan bu ağ istenildiği takdirde gömülü sistemlerde veya orta düzeyde bir PC ile kullanılabilir.


5.2.3.1 Ablasyon çalışmaları sonrası GAN yaklaşımı sonuçları

Önerilen için dört önlemin AUC değerleri hesaplanmış ve diğer en gelişmiş yöntemlerle birlikte Tablo 5.4'de verilmiştir [61]. Bu ölçümler, Gerçek Pozitif Oranı (TPR) ve Yanlış Pozitif Oranı olan ROC eğrisidir. PRO'ya karşı FPR olan PRO eğrisi, Duyarlılığa karşı Pozitif tahmin değeri olan PR eğrisi ve son olarak FPR üzerindeki IoU değeri olan IoU eğrisi. Çünkü %30'un üzerindeki yanlış pozitifler gerçek hayattaki sistemlerde geçerli değildir. %30 FPR'ye kadar eğriler çizilir ve AUC değerleri normalleştirilir.


Tablo 5.4 Önerilen yöntemlerin performansının diğer yaygın yöntemlerle karşılaştırılması: tüm yöntemler için, AUC değeri TPR skoru piksel başına 30%'un altı için hesaplanmış ve normalize edilmiştir ve en iyi performans gösteren yöntem kalın yazı tipiyle vurgulanmıştır.

Yöntemler	Halı			
	AU-ROC	AU-PR	AU-PRO	AU-IoU
Önerilen	0.919	0.675	0.918	0.13
f-AnoGAN	0.251	0.025	0.253	0.025
Feature dictionary	0.943	0.679	0.895	0.139
Student teacher	0.927	0.711	0.914	0.139
ℓ^2 -autoencoder	0.287	0.042	0.306	0.03
SSIM-autoencoder	0.365	0.035	0.392	0.034
Texture inspection	0.874	0.568	0.855	0.123
Variation model	0.162	0.017	0.165	0.015

Halı veri setinin her bir anomali türü için iyi bölütleme örnek görüntüleri Şekil 5.13 kötü bölütleme örnek görüntüleri ise Şekil 5.14'de verilmiştir. Önerilen yöntem, karmaşık bir veri kümesinde bile anormallikleri başarıyla bölümlere ayırabilir. Ancak bölütlemenin başarısının hataların boyutuna ve şekline bağlı olduğu gözlemlenmiştir. Bu nedenle yöntem, ince ve düzensiz şekilli anomalilerde kötü performans gösterir. Bölütlemenin başarısının seçilen eşik değerine bağlı olduğuna dikkat etmek önemlidir. Ayrıca önerilen yapı bir kusuru değil, bir anormalliği bulmak için eğitildiğinden, kırıksıklık gibi kusur olarak değerlendirilemeyecek durumları da tespit eder.



Şekil 5.13 Halı kategorisi için segmentasyon başarılı bölütleme örnekleri



Şekil 5.14 Halı kategorisi için segmentasyon kötü bölütleme örnekleri

6 SONUÇ VE ÖNERİLER

Gelişen teknolojinin ve rekabetçi endüstriyel ortamın etkisiyle, akıllı optik muayene sistemleri için büyük bir talep ortaya çıktı. Akıllı bir görsel denetim sistemi, farklı dokulu ve desenli yüzeylere uygulanabilmeli ve yeni ürünler için hızlı bir şekilde ayarlanabilmelidir. Üstelik yüksek üretim hızına ayak uydurmalıdır. Önerilen yöntemler gerçek dünyadaki yüzey kusurlarını yalnızca kusursuz örnek görüntüler ile eğitilerek tanıyabilir. Tekrarlanan dokulu görüntülerde piksel düzeyindeki anormallikleri sınıflandırabilen bu yöntem literatürdeki diğer yöntemlerinin aksine, sade bir yapıya sahiptir. Aynı zamanda benzer performans sağlarken uygulama süresini, vasıflı işçiliği ve maliyetleri azaltır. Önerilen yaklaşım, doğruluğu kabul edilmiş bir anormallik algılama veri seti üzerinde test edilmiştir. Sonuçlar, önerilen modelin mevcut son teknoloji tekniklerle rekabet edebildiğini göstermiştir. Basit eğitimi ve düşük hesaplama karmaşıklığı nedeniyle, önerilen yöntem endüstriyel uygulamalar için olağanüstü bir potansiyel göstermektedir.

Proje hedefleri doğrultusunda 1 mm'lik kusurların kaliteli fotoğraflarını çekebilen ve bunları online olarak işleyebilen bir sistem geliştirilmiştir.

Ayrıca geliştirilen yöntemler

- Ortalama %97 kusur algılama oranına ve ortalama %65 segmentasyon performansı oranlarına sahiptir.
- Sadece kusursuz görüntüler kullanılarak eğitilebilirler.
- Farklı kumaşlara uygulanılması istendiğinde az miktarda kusursuz örnek görüntü ile bir günden kısa sürede eğitilebilir.
- Tasarlanan metotlar düşük yer kaplamaktadır ve 0.5 m/s saniyedeki bantlardan alınan görüntüleri gerçek zamanlı olarak işleyebilmektedir.

6.1 Öneriler

Sonuçlar göze alındığında yöntemlerin segmentasyon başarılarının daha da arttırılabileceği görülmektedir. Bu projenin devamı olarak hiçbir örneğe ihtiyaç duymadan tek bir görüntü üzerinden genel örüntüyü bozan kusurlu kısımları algılayabilen ve bölütleyebilen bir yöntem geliştirilebilir.

- [1] B.-K. Kwon, J.-S. Won, D.-J. Kang, "Fast defect detection for various types of surfaces using random forest with vov features," *International Journal of Precision Engineering and Manufacturing*, vol. 16, no. 5, pp. 965–970, 2015.
- [2] H. Yang, S. Zheng, J. Lu, Z. Yin, "Polygon-invariant generalized hough transform for high-speed vision-based positioning," *IEEE Transactions on Automation Science and Engineering*, vol. 13, no. 3, pp. 1367–1384, 2016.
- [3] B. Zhang, H. Yang, Z. Yin, "A region-based normalized cross correlation algorithm for the vision-based positioning of elongated ic chips," *IEEE Transactions on Semiconductor Manufacturing*, vol. 28, no. 3, pp. 345–352, 2015.
- [4] —, "A spatial-constraint-based feature point matching algorithm for the positioning of multiple ic instances," *IEEE Transactions on Semiconductor Manufacturing*, vol. 29, no. 2, pp. 137–144, 2016.
- [5] S.-H. Park, H.-T. Kim, K.-T. Kim, "Cross-range scaling algorithm for isar images using 2-d fourier transform and polar mapping," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 2, pp. 868–877, 2010.
- [6] J. Zhu, R. Balieu, X. Lu, N. Kringos, "Microstructure evaluation of polymer-modified bitumen by image analysis using two-dimensional fast fourier transform," *Materials & design*, vol. 137, pp. 164–175, 2018.
- [7] A. Bakhshipour, A. Jafari, S. M. Nassiri, D. Zare, "Weed segmentation using texture features extracted from wavelet sub-images," *Biosystems Engineering*, vol. 157, pp. 1–12, 2017.
- [8] J. Chi, M. Eramian, "Enhancing textural differences using wavelet-based texture characteristics morphological component analysis: A preprocessing method for improving image segmentation," *Computer Vision and Image Understanding*, vol. 158, pp. 49–61, 2017.
- [9] J. Zhou, J. Wang, "Unsupervised fabric defect segmentation using local patch approximation," *The Journal of The Textile Institute*, vol. 107, no. 6, pp. 800–809, 2016.
- [10] L. Tong, W. K. Wong, C. K. Kwong, "Differential evolution-based optimal gabor filter model for fabric inspection," *Neurocomputing*, vol. 173, pp. 1386–1401, 2016.
- [11] J.-K. Park, B.-K. Kwon, J.-H. Park, D.-J. Kang, "Machine learning-based imaging system for surface defect inspection," *International Journal of Precision Engineering and Manufacturing-Green Technology*, vol. 3, no. 3, pp. 303–310, 2016.

- [12] K. Gopalakrishnan, S. K. Khaitan, A. Choudhary, A. Agrawal, "Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection," *Construction and Building Materials*, vol. 157, pp. 322–330, 2017.
- [13] R. A. Lizarraga-Morales, F. E. Correa-Tome, R. E. Sanchez-Yanez, J. Cepeda-Negrete, "On the use of binary features in a rule-based approach for defect detection on patterned textiles," *IEEE Access*, vol. 7, pp. 18 042–18 049, 2019.
- [14] Y. Li, W. Zhao, J. Pan, "Deformable patterned fabric defect detection with fisher criterion-based deep learning," *IEEE Transactions on Automation Science and Engineering*, vol. 14, no. 2, pp. 1256–1264, 2016.
- [15] Q. Luo *et al.*, "Surface defect classification for hot-rolled steel strips by selectively dominant local binary patterns," *IEEE Access*, vol. 7, pp. 23 488–23 499, 2019.
- [16] J. Wang, Q. Li, J. Gan, H. Yu, X. Yang, "Surface defect detection via entity sparsity pursuit with intrinsic priors," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 1, pp. 141–150, 2019.
- [17] L. Tonnaer, J. Li, V. Osin, M. Holenderski, V. Menkovski, "Anomaly detection for visual quality control of 3d-printed products," in *2019 International Joint Conference on Neural Networks (IJCNN)*, IEEE, 2019, pp. 1–8.
- [18] J. Masci, U. Meier, D. Cireşan, J. Schmidhuber, "Stacked convolutional auto-encoders for hierarchical feature extraction," in *International conference on artificial neural networks*, Springer, 2011, pp. 52–59.
- [19] M. Ke, C. Lin, Q. Huang, "Anomaly detection of logo images in the mobile phone using convolutional autoencoder," in *2017 4th International Conference on Systems and Informatics (ICSAI)*, IEEE, 2017, pp. 1163–1168.
- [20] P. Vincent, H. Larochelle, Y. Bengio, P.-A. Manzagol, "Extracting and composing robust features with denoising autoencoders," in *Proceedings of the 25th international conference on Machine learning*, 2008, pp. 1096–1103.
- [21] Y. Li, W. Zhao, J. Pan, "Deformable patterned fabric defect detection with fisher criterion-based deep learning," *IEEE Transactions on Automation Science and Engineering*, vol. 14, no. 2, pp. 1256–1264, 2016.
- [22] R. Chalapathy, A. K. Menon, S. Chawla, "Robust, deep and inductive anomaly detection," in *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, Springer, 2017, pp. 36–51.
- [23] S. Mei, H. Yang, Z. Yin, "An unsupervised-learning-based approach for automated defect inspection on textured surfaces," *IEEE Transactions on Instrumentation and Measurement*, vol. 67, no. 6, pp. 1266–1277, 2018.
- [24] J. Lian *et al.*, "Deep learning based small surface defect detection via exaggerated local variation-based generative adversarial network," *IEEE Transactions on Industrial Informatics*, 2019.
- [25] J. Sun, P. Wang, Y.-K. Luo, W. Li, "Surface defects detection based on adaptive multiscale image collection and convolutional neural networks," *IEEE Transactions on Instrumentation and Measurement*, vol. 68, no. 12, pp. 4787–4797, 2019.

- [26] A. Mujeeb, W. Dai, M. Erdt, A. Sourin, "Unsupervised surface defect detection using deep autoencoders and data augmentation," in *2018 International Conference on Cyberworlds (CW)*, IEEE, 2018, pp. 391–398.
- [27] X. Kang, E. Zhang, "A universal defect detection approach for various types of fabrics based on the elo-rating algorithm of the integral image," *Textile Research Journal*, vol. 89, no. 21-22, pp. 4766–4793, 2019.
- [28] H. Xie, Y. Zhang, Z. Wu, "Fabric defect detection method combining image pyramid and direction template," *IEEE Access*, vol. 7, pp. 182 320–182 334, 2019.
- [29] G. Hu, J. Huang, Q. Wang, J. Li, Z. Xu, X. Huang, "Unsupervised fabric defect detection based on a deep convolutional generative adversarial network," *Textile Research Journal*, p. 0 040 517 519 862 880, 2019.
- [30] H. Yang, Y. Chen, K. Song, Z. Yin, "Multiscale feature-clustering-based fully convolutional autoencoder for fast accurate visual inspection of texture surface defects," *IEEE Transactions on Automation Science and Engineering*, vol. 16, no. 3, pp. 1450–1467, 2019.
- [31] P. Bergmann, M. Fauser, D. Sattlegger, C. Steger, "Mvtec ad—a comprehensive real-world dataset for unsupervised anomaly detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019, pp. 9592–9600.
- [32] I. Goodfellow *et al.*, "Generative adversarial nets," in *Advances in Neural Information Processing Systems 27*, Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, K. Q. Weinberger, Eds., Curran Associates, Inc., 2014, pp. 2672–2680.
- [33] Y. He, K. Song, H. Dong, Y. Yan, "Semi-supervised defect classification of steel surface based on multi-training and generative adversarial network," *Optics and Lasers in Engineering*, vol. 122, pp. 294–302, 2019, ISSN: 0143-8166.
- [34] H. Zhang, Z. Chen, C. Zhang, J. Xi, X. Le, "Weld defect detection based on deep learning method," in *2019 IEEE 15th International Conference on Automation Science and Engineering (CASE)*, 2019, pp. 1574–1579.
- [35] Y. Lu, K. Liu, C. Hsu, "Conditional generative adversarial network for defect classification with class imbalance," in *2019 IEEE International Conference on Smart Manufacturing, Industrial Logistics Engineering (SMILE)*, 2019, pp. 146–149.
- [36] S. Niu, B. Li, X. Wang, H. Lin, "Defect image sample generation with gan for improving defect recognition," *IEEE Transactions on Automation Science and Engineering*, pp. 1–12, 2020.
- [37] J. Liu, C. Wang, H. Su, B. Du, D. Tao, "Multistage gan for fabric defect detection," *IEEE Transactions on Image Processing*, vol. 29, pp. 3388–3400, 2020.
- [38] J. Lian *et al.*, "Deep-learning-based small surface defect detection via an exaggerated local variation-based generative adversarial network," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 2, pp. 1343–1351, 2020.

- [39] J. Bian, X. Hui, S. Sun, X. Zhao, M. Tan, "A novel and efficient cvae-gan-based approach with informative manifold for semi-supervised anomaly detection," *IEEE Access*, vol. 7, pp. 88 903–88 916, 2019.
- [40] S. Mao, J. Guo, Z. Li, "Discriminative autoencoding framework for simple and efficient anomaly detection," *IEEE Access*, vol. 7, pp. 140 618–140 630, 2019.
- [41] Y. Lyu, Z. Han, J. Zhong, C. Li, Z. Liu, "A generic anomaly detection of catenary support components based on generative adversarial networks," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 5, pp. 2439–2448, 2020.
- [42] Y. Kuang, T. Lan, X. Peng, G. E. Selasi, Q. Liu, J. Zhang, "Unsupervised multi-discriminator generative adversarial network for lung nodule malignancy classification," *IEEE Access*, vol. 8, pp. 77 725–77 734, 2020.
- [43] K. Komoto, S. Nakatsuka, H. Aizawa, K. Kato, H. Kobayashi, K. Banno, "A performance evaluation of defect detection by using denoising autoencoder generative adversarial networks," in *2018 International Workshop on Advanced Image Technology (IWAIT)*, 2018, pp. 1–4.
- [44] T. Schlegl, P. Seeböck, S. M. Waldstein, G. Langs, U. Schmidt-Erfurth, "F-anogan: Fast unsupervised anomaly detection with generative adversarial networks," *Medical Image Analysis*, vol. 54, pp. 30–44, 2019, ISSN: 1361-8415.
- [45] G. Hu, J. Huang, Q. Wang, J. Li, Z. Xu, X. Huang, "Unsupervised fabric defect detection based on a deep convolutional generative adversarial network," *Textile Research Journal*, vol. 90, no. 3-4, pp. 247–270, 2020. DOI: 10 . 1177 / 0040517519862880.
- [46] S. Lin, Z. He, L. Sun, "Defect enhancement generative adversarial network for enlarging data set of microcrack defect," *IEEE Access*, vol. 7, pp. 148 413–148 423, 2019.
- [47] R. Skilton, Y. Gao, "Combining object detection with generative adversarial networks for in-component anomaly detection," *Fusion Engineering and Design*, vol. 159, p. 111 736, 2020, ISSN: 0920-3796.
- [48] S. Niu, H. Lin, T. Niu, B. Li, X. Wang, "Defectgan: Weakly-supervised defect detection using generative adversarial network," in *2019 IEEE 15th International Conference on Automation Science and Engineering (CASE)*, 2019, pp. 127–132.
- [49] T. S. Newman, A. K. Jain, "A survey of automated visual inspection," *Computer vision and image understanding*, vol. 61, no. 2, pp. 231–262, 1995.
- [50] A. Goyal, "Automation in fabric inspection," in *Automation in Garment Manufacturing*, Elsevier, 2018, pp. 75–107.
- [51] K. Srinivasan, P. Dastoor, P. Radhakrishnaiah, S. Jayaraman, "Fdas: A knowledge-based framework for analysis of defects in woven textile structures," *Journal of the textile institute*, vol. 83, no. 3, pp. 431–448, 1992.
- [52] *Standard fabric defect glossary - cotton incorporated - quality products*, May 2020. [Online]. Available: <https://www.cottoninc.com/quality-products/textile-resources/fabric-defect-glossary/#>.
- [53] A. Conci, C. Proença, "A computer vision approach for textile inspection," *Textile Research Journal*, vol. 70, no. 4, pp. 347–350, 2000.

- [54] *Flow chart of woven fabric inspection in garment industry*, Dec. 2020. [Online]. Available: <https://garmentsmerchandising.com/flow-chart-of-woven-fabric-inspection-in-garment-industry/>.
- [55] D. Brzakovic, N. Vujovic, "Designing a defect classification system: A case study," *Pattern recognition*, vol. 29, no. 8, pp. 1401–1419, 1996.
- [56] A. Bhattad, J. Rock, D. Forsyth, "Detecting anomalous faces with 'no peeking' autoencoders," *arXiv preprint arXiv:1802.05798*, 2018.
- [57] R. Zhang, P. Isola, A. A. Efros, "Split-brain autoencoders: Unsupervised learning by cross-channel prediction," in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jul. 2017.
- [58] A. Radford, L. Metz, S. Chintala, "Unsupervised representation learning with deep convolutional generative adversarial networks," *arXiv preprint arXiv:1511.06434*, 2015.
- [59] R. Reininger, J. Gibson, "Distributions of the two-dimensional dct coefficients for images," *IEEE Transactions on Communications*, vol. 31, no. 6, pp. 835–839, 1983.
- [60] C. Wang, S. Dong, X. Zhao, G. Papanastasiou, H. Zhang, G. Yang, "Saliencygan: Deep learning semisupervised salient object detection in the fog of iot," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 4, pp. 2667–2676, 2020. DOI: 10.1109/TII.2019.2945362.
- [61] P. Bergmann, K. Batzner, M. Fauser, D. Sattlegger, C. Steger, "The mvtec anomaly detection dataset: A comprehensive real-world dataset for unsupervised anomaly detection," *International Journal of Computer Vision*, pp. 1–22, 2021.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. M. A. N. Oz, O. T. Kaymakci, and M. Mercimek, "A nested autoencoder approach to automated defect inspection on textured surfaces," *International Journal of Applied Mathematics and Computer Science*, vol.31, no. 3, pp. 515-523, 2021. <https://doi.org/10.34768/amcs-2021-0035>
2. M. A. N. Oz, M. Mercimek, O. T. Kaymakci, "Anomaly localization in regular textures based on deep convolutional generative adversarial networks," *Applied Intelligence*, 2021. <https://doi.org/10.1007/s10489-021-02475-3>

Konferans Bildirisi

1. T. Ulutas, M. A. N. Oz, M. Mercimek and O. T. Kaymakci, "Split-Brain Autoencoder Approach for Surface Defect Detection," *2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, 2020, pp. 1-5, doi: 10.1109/ICECCE49384.2020.9179311.

Proje

1. Kumaş Hatalarının Endüstriyel Görüntü İşleme Teknikleri İle Tanılanması, TÜBİTAK 3001 Projesi, Proje no: 118E607.