

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MELEZ BİR ÖĞRENME YAKLAŞIMI İLE EK YERİ
PROSESLERİNDE ANOMALİ TESPİT VE SINIFLANDIRMA

ENES BAYTÜRK

KOCAELİ 2023

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MELEZ BİR ÖĞRENME YAKLAŞIMI İLE EK YERİ
PROSESLERİNDE ANOMALİ TESPİT VE SINIFLANDIRMA

ENES BAYTÜRK

Prof. Dr. Oğuzhan Urhan

Danışman, Kocaeli Üniversitesi

.....

Doç. Dr. Aysun Taşyapı Çelebi

Jüri Üyesi, Kocaeli Üniversitesi

.....

Doç. Dr. Ali Can Karaca

Jüri Üyesi, Yıldız Teknik Üniversitesi

.....

Tezin Savunulduğu Tarih: 24.01.2023

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmada,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler Brisa Bridgestone Sabancı Lastik Sanayi ve Ticaret A.Ş. tarafından AR-GE çalışmaları kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Enes BAYTÜRK

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanımı bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim.

Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan ***“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”*** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

Enes BAYTÜRK

ÖNSÖZ VE TEŞEKKÜR

Çalışma boyunca her türlü desteğini esirgemeyen BRISA BRIDGESTONE SABANCI Lastik İmalat A. Ş'ye çok teşekkür ederim. Ve bu çalışma sırasında Anıl ÇALIŞKAN, Volkan ÖZDEMİR ve Murat ÖZGEN ile çalışmak büyük bir onurdu. Ayrıca bu tezde emeği geçen tüm meslektaşlarıma ve yöneticilerime teşekkür ederim.

Bu yolculukta bana her zaman destek olan ve yol gösteren tez danışmanım Prof. Dr. Oğuzhan URHAN'a en içten teşekkürlerimi sunarım ve son olarak bugüne kadar hem maddi hem manevi gelişimime katkıda bulunan ve bulunmaya devam eden aileme teşekkür ederim.

Ocak – 2023

Enes BAYTÜRK



İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ.....	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ	v
TABLOLAR DİZİNİ.....	vi
SİMGELER VE KISALTMALAR DİZİNİ	vii
ÖZET	viii
ABSTRACT	ix
1.GİRİŞ.....	1
2. PROBLEM TANIMI.....	3
2.1. Anomali Türleri	4
2.2. Literatür Araştırması.....	6
3. TEORİK ARKA PLAN.....	8
3.1. Makine Öğrenmesi	8
3.2. Derin Öğrenme	10
3.3. Performans Metrikleri.....	20
4. DENEYSEL KURULUM	21
5. GELİŞTİRİLEN YÖNTEM	24
5.1. Veri Seti.....	24
5.2. Sistem Mimarisi.....	25
6. DENEYSEL SONUÇLAR.....	29
6.1. Otokodlayıcı Sistem Sonuçları	29
6.2. Sınıflandırma Model Sonuçları	31
6.3. Melez Model Sonuçları	34
7. SONUÇLAR.....	36
KAYNAKLAR.....	37
KİŞİSEL YAYIN VE ESERLER.....	40
ÖZGEÇMİŞ.....	41

ŞEKİLLER DİZİNİ

Şekil 1.1.	Örnek Rulo Makinesi	1
Şekil 1.2.	Ek ekleme yöntemleri. Uç uca ekleme(sol), üst üste bindirerek ekleme (orta), V şeklinde ekleme (sağ)	2
Şekil 2.1.	Ek Yeri Açıklık Örneği	4
Şekil 2.2.	Hatalı Ek Yeri Örneği.....	4
Şekil 2.3.	Dağılım Bozukluğu Örneği	5
Şekil 2.4.	Eksik Kaplama Örneği	5
Şekil 2.5.	Uygunsuz Kenar Alma Örneği.....	5
Şekil 3.1.	Makine Öğrenmesi Akış Şeması	8
Şekil 3.2.	Makine Öğrenmesi Yöntemleri	9
Şekil 3.3.	Sinir Hücresinin Matematiksel Modeli	10
Şekil 3.4.	Persepton Modeli	11
Şekil 3.5.	Çok Katmanlı Algılayıcı Örneği	12
Şekil 3.6.	Basit Bir Evrişimsel Sinir Ağı Mimarisi	14
Şekil 3.7.	LeNet Mimarisi	15
Şekil 3.8.	Derin Öğrenme Tabanlı Nesne Tespit Algoritmaları.....	16
Şekil 3.9.	YOLOV3 Mimarisi	17
Şekil 3.10.	YOLOV5 Mimarisi	18
Şekil 3.11.	Basit Otokodlayıcı Örneği.....	19
Şekil 3.12.	Derin Otokodlayıcı Örneği.....	19
Şekil 4.1.	Tasarlanan Sistem	21
Şekil 5.1.	Geliştirilen Melez Sistem Mimarisi	25
Şekil 5.2.	Hareketsiz Durum Tespiti, (a) Hareketsiz durumdayken çerçeve farkı, (b) hareketli durumda ardışık çerçeve farkı.....	26
Şekil 5.3.	Kat Bileşen Parçalarının Genişlik Tespiti	26
Şekil 5.4.	Ek Yeri Ekleme Bölgesinin Tespit Edilmesi.....	27
Şekil 5.5.	Otokodlayıcı Sistem	27
Şekil 5.6.	Otokodlayıcıların Ağ Yapısı	28
Şekil 6.1.	Otokodlayıcı Modellerin Kayıp Grafiği.....	29
Şekil 6.2.	Anomali Tespit Sonuçlarına Ait Örnek Görüntüler	31
Şekil 6.3.	Sınıflandırma Model Sonuçlarına Ait Görseller, (a) Orijinal Görüntüler, (b) YOLOV5 tespit sonuçları, (c) Faster- RCNN tespit sonuçları	34

TABLolar DİZİNİ

Tablo 5.1. Veri Seti Dağılımı	24
Tablo 5.2. Anomali İçeren Görüntülerin Sınıf Bazlı Dağılımı.....	24
Tablo 5.3. Otokodlayıcı Sistemin Karar Mekanizması	28
Tablo 6.1. Otokodlayıcıların Karmaşıklık Matrisi	30
Tablo 6.2. Otokodlayıcı Sistemin Performans Değerleri	30
Tablo 6.3. Sınıflandırma Eğitiminde Kullanılan Veri Seti.....	31
Tablo 6.4. Performans Testinde Kullanılan Anomali Tipi Bazlı Veri Sayısı.....	32
Tablo 6.5. Sınıflandırma Modellerinin Anomali Tespitindeki Karmaşıklık Matrisi....	32
Tablo 6.6. Faster R-CNN Modeli Anomali Tipi Bazlı Karmaşıklık Matrisi.....	32
Tablo 6.7. Faster R-CNN Modeli Performans Sonuçları	33
Tablo 6.8. YOLOV5 Modeli Anomali Tipi Bazlı Karmaşıklık Matrisi.....	33
Tablo 6.9. YOLOV5 Modeli Performans Sonuçları.....	33
Tablo 6.10. Anomali Tespit Sonuçları Karşılaştırması	35
Tablo 6.11. Anomali Tipi Sınıflandırma Başarım Sonuçları.....	35

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

ANN	: Artificial Neural Network (Yapay Sinir Ağı)
BGR	: BLUE GREEN RED (MAVİ YEŞİL KIRMIZI)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
ESA	: Evrışimli Sinir Ağları
FP	: False Positive (Yanlış Pozitif)
FN	: False Negative (Yanlış Negatif)
PVC	: Polivinil Klorür
ReLU	: Rectified Linear Unit (Doğrultulmuş Lineer Birim)
TP	: True Positive (Doğru Pozitif)
TN	: True Negative (Doğru Negatif)
YOLO	: You Only Look Once (Sadece Bir Kez Bak)
YSA	: Yapay Sinir Ağları

MELEZ BİR ÖĞRENİM YAKLAŞIMI İLE EK YERİ PROSESLERİNDE ANOMALİ TESPİT VE SINIFLANDIRMA

ÖZET

Lastik imal süreçlerinin adımlarından biri olan kalenderleme metodunda farklı komponentler bir araya gelerek lastik için uygun tekstil veya çelik malzemelerin üretilmesini sağlar. Kalenderleme işleminde lastik performans gruplarına göre kalınlıkları, dayanımları vb. fiziksel özellikleri seçilmiş olan tekstil veya çelik malzemeler özel haddeleme metoduyla kauçuk ile kaplanır. Ana malzemelerde oluşabilecek hatalar, kaplama kauçuğunun karakteri, proses parametrelerindeki değişkenlikler gibi sebepler ile zaman zaman üretimde hatalı ürün olarak tanımlanan özürlerin oluşmasına sebebiyet vermektedir. Ortaya çıkan bu hatalı ürünler yüksek performanslı ve güvenli lastiklerin üretilmesi için tespit edilerek ayıklanmalı ve lastiğe dönüşümü engellenmelidir. Özürlü olarak tanımlanan malzemelerin lastik pişme işleminden sonra tespit edilmesi gerek verim, enerji gerekse hammadde kaybına sebebiyet vermektedir. Bu çalışmada akan bir bant üzerindeki kalenderleme prosesinde üretilen kauçuk kaplı tekstil malzemelerinin üretim aşamasında meydana gelebilecek hata veya özürlerin makine görüşü ile tespitine odaklanılmıştır. Çalışma kapsamındaki özürler; eksik kauçuk kaplama, mevcut bezler üzerindeki kırıksıklık, bez bileşen ek yerlerindeki uygunsuz açıklık gibi fiziksel olarak tespit edilebilen olgulardır. Özür tespitlerinde geleneksel olarak nesne tespitinden faydalanılabilecekken bu çalışmada farklı bir yöntem önerilmiştir. Girdi olarak alınan görüntü ilk olarak denetimsiz bir anomali tespit modeline verilmektedir. Bu aşamada anomali bir durum tespit edildiği durumda girdi görüntüsü sınıflandırma modeline girmekte ve özür tipi tespit edilmektedir. Anomali tespitinde, otokodlayıcı modelin doğruluğu %94,1 seviyelerinde, sınıflandırıcı modelin doğruluğu ise %93,2 seviyelerindedir. Otokodlayıcı ve sınıflandırıcı modelini melez bir model olarak kullanıldığında %95,3'lük doğruluk elde edilmiştir. Özür tiplerinin sınıflandırılmasında, sınıflandırıcı modelin doğruluğu %91,5, melez modelin doğruluğu %91.9 olmaktadır.

Anahtar Kelimeler: Anomali Tespiti, Denetimli Öğrenme, Denetimsiz Öğrenme, Nesne Tespiti, Sınıflandırma.

DETECTION AND CLASSIFICATION OF ANOMALIES IN THE SPLICE ADDING PROCESSES WITH A HYBRID LEARNING APPROACH

ABSTRACT

In the calendering method, which is one of the steps of tire production processes, different components come together to produce suitable textile or steel materials for the tire. In the calendering process, the rubber is coated with rubber by special rolling method by using textile or steel materials that have suitable physical properties such as thickness and durability according to performance groups. Errors that may occur in the main materials, the character of the coating rubber, the variability in the process parameters, from time-to-time cause defects defined as faulty products in production. These faulty products should be detected and sorted out to produce high performance and safe tires, and they should be prevented from being a finished tire. Detecting the materials defined as faulty after the tire firing process causes loss of efficiency, energy, and raw material. In this study, the focus is on the machine vision detection of errors or defects that may occur during the production of rubber-coated textile materials produced in the calendering process on a conveyor belt. The defects observed within the scope of the study are the phenomena that can be detected physically such as missing rubber coating, wrinkles on the existing cloths, inappropriate opening in the cloth component joints. While traditionally object detection can be beneficial in fault detection, a different method has been proposed in this study. The image taken as input is first given to an unsupervised anomaly detection model. When an anomaly is detected in this stage, the input image enters the classification model, and the fault type is detected. In anomaly detection, the accuracy of the autoencoder model is 94.1%, and the accuracy of the classifier model is 93.2%. An accuracy of 95.3% was obtained when the autoencoder and classifier model was used as a hybrid model. In classification of fault types, the accuracy of the classifier model is 91.5%, and the accuracy of the hybrid model is 91.9%.

Keywords: Anomaly Detection, Supervised Learning, Unsupervised Learning, Object Detection, Classification.

1.GİRİŞ

Gelişen teknoloji ve otomasyon teknikleri ile birçok endüstri yüksek üretim adetlerine ulaşabilmiştir. Bu adetlerin artmasındaki bir başka etken ise malzeme taşıma ve ara mamul stok teknikleridir.


Özellikle belirli bir kalınlık ve genişlikte olan ve rulo halinde sarılabilen malzemelerin efektif olarak saklanması için döndürme prosesi (winding process) kullanılmaktadır. Şekil 1.1’de bir rulo saklama yöntemi gösterilmiştir. Bu sayede kilometrelerce uzunluktaki malzemeler depo ve saklama alanlarında az yer kaplayarak saklanabilmektedir.



Şekil 1.1. Örnek Rulo Makinesi (Suntech Machine)

Geometrik ve makine yapabilirliğinin sınırları nedeniyle bu döndürme prosesi hiçbir zaman yekpare şekilde olamamaktadır. Prosesin bu aşamasında ara mamul oluşturmak adına bir uç uca ekleme işlemi gerçekleştirilir. Metal plakalar, tekstil kumaşları, fiber kablolar, kâğıt, karton, köpük ve kauçuk gibi malzemeler bu yaklaşımla etkin şekilde saklanabilmektedir.

Bu ekleme işlemi istenilen performans kriterine göre farklı şekillerde yapılabilmektedir. Malzeme uç uca bindirme olmadan eklenebileceği gibi, belirli bir miktarda ekleme yapılarak da bindirme yapılabilmektedir. Özellikle kâğıt ve PVC bant sektöründe ise bir üçüncü tarz olan V şeklinde ekleme yapılmaktadır. Şekil 1.2’de bu ekleme yöntemlerine dair görsellere yer verilmiştir.



Şekil 1.2. Ek ekleme yöntemleri. Uç uca ekleme (sol), üst üste bindirerek ekleme (orta), V şeklinde ekleme (sağ) (Splicing Applications)

Bu teknikler her ne kadar birçok avantaj sağlasa da beraberinde birtakım riskler de getirmektedir. Özellikle bu ekleme proseslerinde mekanik ve otomasyon olarak, baskı rulosunun baskı kuvvetinde oluşabilecek varyasyon ve akım düşmesinden kaynaklı tam performans gösterememesi gibi farklı durumların oluşmasından ötürü çeşitli anomaliler meydana gelmektedir. Ekleme bölgesinin tam kapanmaması, düzlemsel olarak merkezlerinin kesişmemesi, kırışma, katlanma, bölgesel açıklık bu anomalilere örnek olarak verilebilir. Oluşan bu anomaliler tespit edilemezlerse son üründe kalite problemlerine yol açmaktadırlar.

Bu kalite problemlerini önlemek için ise üreticilerin ekleme prosesini iyileştirecek teknikler kullanmaktadır. Bunlara ekleme prosesine ilave baskı adımı eklemek, el merdanesi ile ek yerinin üzerinden geçmek, ekleme adımındaki hat akış hızı, baskı kuvveti gibi parametrelerin optimize edilmesi örnek olarak verilebilir. Ne yazık ki bu ilave adımlar eklenmiş olsa dahi anomalilerin oluşması kaçınılmazdır.

Bu anomalilerin kontrol edilmesi adına üreticilerin eklenme bölgesinde herhangi bir anomali barındırmadığını kontrol etmeleri gerekmektedir. İşte bu durum karşısında, gelişen teknoloji ile yapay zekâ destekli tespit algoritmaları sahneye çıkmaktadır. Kamera veya başka sensörler ile toplanan ham verilerin çeşitli görüntü işleme, makine görüşü ve yapay zekâ temelli algoritmaları ile işlenmesi sayesinde anomali tespiti yapılması mümkündür.

2. PROBLEM TANIMI

Endüstriyel imalat proseslerinde yaşanan uygunsuzluklar ve hatalar ile hammadde ve malzeme kayıpları oluşmaktadır. Bu kayıplar döngüsel yapıyı kalite, iş gücü, zaman ve para olarak etkilemektedir.

İdeal bir üretim hattında işin niteliği ve sınıfına göre hammadde ve ara işlemler kaynaklı hataların asgari seviyede olması istenir. Bu şekilde oluşacak son üründe veya ara bileşenlerde hurdalama yani kullanım dışı kalma durumunu en aza indirilmesi hedeflenmektedir.

Lastik imalat yapısı incelendiğinde birbirinden farklı ve birbirinden bağımsız devam eden proses çıktılarının lastik imal aşamasında bir araya getirilmesi ile yarı bileşen gruplarından ham lastik denilen yapılar oluşur.

Ham lastikler pişirme işlemine tabi tutularak, son kullanıcılara ulaşan lastik formunu alır. Kaliteli ve performans gereklerini yerine getiren bir lastik tüm bu özelliklerini ara proseslerdeki alt bileşenlerinin kalitesinden oluşur.

Lastik imalatının önemli bileşenlerinden biri de kalenderleme aşamasıdır. Üreticilerin kendi tecrübe ve teknolojilerine uygun olarak oluşturduğu kauçuk karışımlar, çeşitli uygulamalar ile kat denilen tekstil yapılar ile bir araya getirilir. Tekstil malzeme istenilen kalınlıkta ve homojenlikte reçete edilmiş kauçuk ile kaplanır. İdeal bir kaplanmış tekstil malzemesinde homojeniteyi bozan yapılar ve bez üzerinde fiziksel bozukluklar olmamalıdır. Bu aşamada oluşabilecek kusurlar lastik performansını doğrudan etkileyebilir.

Bu tez çalışmasına konu olan incelemede kat ekleme makinesinde kesilmiş kat (kauçuk kaplı tekstil bileşen) bileşen parçalarının birbirine eklenmesi esnasında ekleme tipi ve prosesine göre birçok anomali meydana gelmektedir. Özürler ek ekleme anında tespit edilerek, ilgili makinada çalışan operatörün uygun zaman ve bölgede bilgilendirilerek/uyararak operatörün önlem alabilmesi sağlanmalıdır. Bu noktada üzerinde çalışılan sistem ile hata ve özür olarak tanımlanmış anomaliler kameradan alınan görüntülerin işlenmesi ve analizi yardımı ile tespit edilecek ve uyarı sistemleri ile kendinden bir sonraki sahaya gitmesinin önüne geçilecek.

Bu çalışmanın önemli bir sonuçlarından biri de kat kesme ekleme işlemi sonrasında lastik imalat aşamalarında üretim esnasında meydana gelen kusur ve hataları ayırt ederek süre kaybını ve ortaya çıkan hurda malzeme oranını azaltmasıdır.


Geliştirilen yapı kamera ile sahayı gözlemler, sistem anomali tespitlerini yapar ve etkileşimli olarak operatörü bilgilendirilir. Böylelikle çağımızın en büyük gerekliliklerinden biri olan makine- insan iş birliği fırsatı yaratılır.

2.1. Anomali Türleri

Kat ekleme makinesinde kat bileşen parçalarının birbirine eklenme anında ek yerinde 5 farklı anomaliye rastlanmaktadır.

2.1.1. Ek Yeri Açıklık

Uç uca birleştirilerek eklenen kat bileşen parçalarının birbiri ile tam olarak buluşamaması, dolayısıyla tam olarak eklenememesi ve açık kalması durumudur. Şekil 2.1’de ek yeri açıklık örneği gösterilmektedir.



Şekil 2.1. Ek Yeri Açıklık Örneği

2.1.2. Hatalı Ek Yeri

Bindirilerek eklenen kat bileşen parçalarının belirlenen tanımların dışında bindirilmiş olması veya eklenen kat bileşenlerin kenarlardan tam olarak hizalanamaması durumudur. Şekil 2.2’de hatalı ek yeri örneği gösterilmektedir.



Şekil 2.2. Hatalı Ek Yeri Örneği

2.1.3. Dağılım Bozukluğu

Kat bileşenini oluşturan kord ipliklerinin düzgün aralıklarla dağılmamış olması durumudur. Şekil 2.3'te dağılım bozukluğu örneği gösterilmektedir.



Şekil 2.3. Dağılım Bozukluğu Örneği

2.1.4. Eksik Kaplama

Kesilmiş kat bileşeni parçalarının muhtelif yerlerinde, önceki kalenderleme proseslerinde meydana gelen eksik kaplanma sonucunda çıplak kord ipliklerinin görülmesi durumudur. Şekil 2.4'te eksik kaplama örneği gösterilmektedir.



Şekil 2.4. Eksik Kaplama Örneği

2.1.5. Uygunsuz Kenar Alma

Kat bileşeni parçalarının kesimi esnasında uygunsuz kenar alma ya da kenar bıçağının dalması sonucunda ek yerinde çıplak kord ipliklerinin görülmesi durumudur. Şekil 2.5'te uygunsuz kenar alma örneği gösterilmektedir.



Şekil 2.5. Uygunsuz Kenar Alma Örneği

2.2. Literatür Araştırması

Bilgisayar donanım ve yazılım teknolojilerindeki son gelişmelerle beraber yapay zekâ veya makine öğrenmesi metotları hemen hemen her alanda karşımıza çıkmaya başlamıştır. Özellikle “Endüstri 4.0” kavramı ile ortaya çıkan karanlık fabrika konsepti ile üretim teknolojilerinde insana olan bağlılığın azaltılması hedeflenmiştir. Böylelikle hem insan gücüne olan bağlılığın azalması ve otonomi sağlanacak hem de aynı işin tekrarı ve gerçekleşme hızına bağlı olarak insan gözünün kaçırdığı hataların önüne geçilmesi amaçlanmaktadır.

Endüstriyel üretim sahalarında genellikle üretim veya proses kalite kontrol adımları için sıklıkla denetimli ya da denetimsiz öğrenme yaklaşımlarına başvurulmaktadır. Denetimsiz öğrenmenin üretim ve kalite sektöründe anomali tespiti için kullanıldığı birçok çalışma literatürde mevcuttur (Yang ve ark.,2022, Ulger ve ark., 2021, Ofir ve ark., 2022, Cui ve ark., 2022, Perez ve ark., 2022, Abdallah ve ark., 2022).

Anomali, norm olarak kabul edilen referanstan sapan durumlardır. Anomali tespiti kapsamında kalan kusur algılama ve tespit etme algoritmaları üretim sahalarında işlerimizi kolaylaştırmaktadır. İnsanlar, anomali kontrollerini geçmişten öğrendikleri anomali olmayan yani özür içermeyen durumlardan elde ettikleri çıkarımlar ile yapmaktadır.

Bunu yapar iken norm olarak kabul edilen öge üzerinden farklılıkları, kusurları tespit etme, doku ve arka fon uyumu, yüzey algılama gibi karşılaştırmaları kullanır. Temelde insan gözü bir görsel farklılık araması yapar.

Yaş, görme keskinliği, tarama stratejisi, taraflılık, deneyim ve eğitim gibi bireysel faktörler, manuel inceleme işlemi sırasında oluşan başlıca hata kaynaklarıdır (See ve ark., 2017).

İnsanlar tarafından yapılan manuel muayenede karşılaşılan bu zorlukların bir sonucu olarak, hata ve kusur tespiti otomasyonu, dünya çapında bir araştırma konusu olmuştur. Yapılan çalışmalar incelendiğinde bu çalışmaların daha çok çelik yüzeyler (Sun ve ark., 2018), raylar (Yu ve ark., 2019) ve kumaş (Kumar, 2008) gibi alanlarda olduğu görülmektedir.

Bauer yapmış olduđu çalışmada ahşap ve kumaş yüzeyleri üzerinden otokodlayıcı denetimsiz öğrenme metodu ile anormali tespitine odaklanmıştır (Bauer,2022).

Yao, H. ve arkadaşları ise yapmış oldukları çalışmanın performansını kumaş, deri, ahşap vb. yüzeyler üzerinden test etmiş ve akıllı üretim sistemleri için bir kalite kontrol sistemi inşa etmişlerdir. Geliştirdikleri sistemde işlemlerin bir kısmı uçta (edge) gerçekleştirilirken tespit algoritmasını bulutta çalıştırmışlardır. Böylelikle geliştirdikleri sistemde uçtaki işlem yükünü azaltarak uçta düşük özellikli donanımlar kullanabilmişlerdir. Yapılan bu çalışma endüstriyel dönüşümü güçlendirecek niteliktedir (Yao ve ark.,2022).

Tailanian, M. ve arkadaşları benzer sistemler üzerinde çalışmış olup, çalışmalarını literatürde kolaylıkla bulunabilecek veri seti olan ‘MVTec AD’ üzerinden yapmışlardır. Geliştirdikleri algoritmalarını canlı olarak deri üretim hattında test etme imkânı bulduklarını ve sadece sayısal verilerle açıklanan çalışmalarının yanı sıra üretim sahası gözlemlerini de özetlemişlerdir. Ardından operatörleri destekleyen bir sistem kurup, deri üretim prosesindeki kusurlu yerlerin daha hızlı ve kolay bir şekilde bulunduğunu rapor etmişlerdir (Tailanian ve ark., 2022).

Bu çalışmayı literatürdeki birçok örneğinden ayıran 2 farklı yön vardır. Birincisi, lastik imalatı ve bileşenleri gibi oldukça az verinin bulunduğu bir sektörde; probleme yönelik veri toplama işlemi gerçekleştirilmiştir. Lastik bileşenlerinin önemli bir malzemesi olan kauçuk kaplanmış polyester malzemeler üzerinde çalışmalar yapılmıştır. İkincisi ise Tailanian, M. ve arkadaşlarının (Tailanian ve ark., 2022) çalışmasında olduğu gibi gerçek üretim şartlarında test edilme imkânı bulmuştur. Çalışmanın operatörler üzerindeki etkisi ve üretim hattına olan yansımaları ölçülmüştür.


3. TEORİK ARKA PLAN

Bu bölümde kullanılan yöntemlerin kısa teknik arka planı verilmektedir. İlk olarak makine öğrenmesi kavramı açıklanmaktadır. İkinci olarak derin öğrenme yöntemleri olan denetimli ve denetimsiz öğrenme kavramları açıklanmaktadır.

3.1. Makine Öğrenmesi

Makine öğrenmesi, makineleri farklı algoritma veya modeller kullanarak eğiten, makinelerin açıkça programlamak yerine deneyimlerinden öğrenmesine olanak sağlayan bir yapay zekâ sınıfıdır (Jordan & Mitchell,2015). Başka bir deyişle belirli bir sonucu üretmek için girdi verileri ile çıktı arasında bağlantı kuran bir yapıdır (El Naqa ve ark., 2015). Makine öğrenmesi algoritmaları oldukça karmaşık problemleri iyi bir şekilde çözmesi nedeniyle çok çeşitli gerçek dünya uygulamalarında kullanılmaktadır.

Makine öğrenmesi, veriden bilgi öğrenebilen, öğrendiği bilgiyi kullanarak bir tahminde bulunabilen algoritmik yapılar olarak ele alınabilir. Şekil 3.1’de makine öğrenmesi için örnek bir akış şeması verilmiştir.




Şekil 3.1. Makine Öğrenmesi Akış Şeması

Makine öğrenmesinde ilk olarak hazırlanan veri seti eğitim ve test olarak parçalanır. Bu işlemin ardından eğitim verisi kullanılarak öğrenme işlemi gerçekleştirilir. Model başarımını tespit etmek için test verisi ile model çalıştırılır ve performans testi gerçekleştirilir.

3.1.1. Makine Öğrenmesi Yöntemleri

Makine öğrenmesi algoritmaları öğrenim yöntemi olarak iki ana başlıkta incelenebilir; denetimli öğrenme ve denetimsiz öğrenme. Bunun yanında literatürde birçok farklı öğrenme yöntemi de bulunmaktadır. Bu yöntemlere örnek olarak; yarı denetimli öğrenme, pekiştirmeli öğrenme verilebilir. Şekil 3.2’de derin öğrenme yöntemleri verilmiştir. Bu tez çalışmasında denetimli ve denetimsiz öğrenme yöntemleri anlatılmaktadır.



Şekil 3.2. Makine Öğrenmesi Yöntemleri

3.1.1.1. Denetimli Öğrenme

Denetimli öğrenmede algoritmalara uygulayabilmek için eğitim setinde etiketli veriler kullanılır. Bu öğrenme yönteminin amacı, bir veya birden fazla bağımsız değişkenden çıktıyı tahmin veya tespit etmektir (Pulat ve ark.,2021). Temel mantık, girdi verisi ile çıktı arasındaki ilişkiyi yakalayacak bir karar mekanizması gerçekleştirmektir (Ali ve ark.,2021).

3.1.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenmede algoritmalara uygulayabilmek için eğitim setinde etiketsiz veriler kullanılmakta ve algoritmanın veri noktalarını kümelenmesi beklenmektedir. Temel kurgu, verilerde bulunan ortak veya aykırı özellikleri tespit ederek verileri gruplamak olarak söylenebilir (Ekhlaf,2020).

3.2. Derin Öğrenme

Derin öğrenme, çok sayıda gizli katmandan oluşan ve insan sinir sistemi yapısından esinlenilerek geliştirilen yapay sinir ağları üzerine inşa edilmiş bir makine öğrenmesi yöntemidir (Deng ve ark.,2013).


Derin öğrenme metin, veri sınıflandırma, nesne algılama, konuşma tanıma, görsel veri tanıma gibi birçok alanda kullanılmaktadır (Cengil ve Çınar,2016).

3.2.1. Derin Öğrenme Mimarileri

Literatürde birçok derin öğrenme mimarisi bulunmaktadır. Bu bölümde yapay sinir ağları, evrişimli sinir ağları ve otokodlayıcılar anlatılmaktadır.

3.2.1.1. Yapay Sinir Ağları


Yapay sinir ağları (YSA), insan sinir sisteminden esinlenerek geliştirilmiş olan hesaplama modelleridir. Bu sinir ağları insan sinir ağındaki gibi sinaps benzeri yapılara ve nöronlar oluşmaktadır. Veriyi alan nöron yapmakla sorumlu olduğu görevi yaparak, işlenmiş veriyi bir sonraki nörona aktarır (Alan,2020). Şekil 3.3'te bir sinir hücresinin matematiksel modeli gösterilmektedir.



Şekil 3.3. Sinir Hücresinin Matematiksel Modeli

Şekil 3.3 incelendiğinde nöron girişine bir önceki hücreden veya dentritten gelen x_i değeri, dentrit kısmında bulunan ve ağırlık değeri olan w_i ile çarpılmaktadır. Dentritlerden gelen tüm verilerin x ve w çarpımları toplanmakta ve toplama b değeri eklenmektedir. Buradan elde edilen sonuç ise bir fonksiyondan geçirilir ve sonuç aksona gönderilir. Gönderilen değer direkt sonuç ya da sıradaki nöronun girdisi olmaktadır (Smolen ve ark., 2000).

Rosenblatt 1958 yılında organizmaların öğrenme mekanizmasından esinlenerek perseptonu tanımlanmıştır. Persepton modeli Şekil 3.4'te gösterilmektedir. Persepton, verilere göre eğitilebilen tek bir nöronun oluşur.




Şekil 3.4. Persepton Modeli (Rosenblatt,1958)

Persepton modelinde sinir hücresi çok sayıda aldığı girdiden bir çıktı üretilmesine dayanmaktadır. Girdilerin ağırlık toplamaları bir eşik değeri ile karşılaştırılmakta ve çıktı değeri elde edilmektedir. Ağın çıktısı belirlenen eşik değerinden büyük eşitse çıktı değeri 1, diğer durumda ise çıktı değeri 0 olmaktadır (Freeman ve ark., 1991). Persepton modelinin, çözmekte başarısız olduğu birçok problemin olması nedeniyle 1980 yıllara doğru çok katmanlı persepton modeli geliştirilmiştir.

Doğrusal olmayan gerçek dünya problemlerin çözümünde yetersiz ve başarısız olması nedeniyle çok katmanlı algılayıcılar geliştirilmiştir. Çok katmanlı algılayıcılar, girdi, çıktı ve bir veya birden fazla gizli katmandan oluşmaktadır. Şekil 3.5'te örnek çok katmanlı algılayıcı ağ mimarisi gösterilmektedir.

İlk katman aynı zamanda giriş katmanı olarak isimlendirilir. Giriş değerleri için alıcı katman görevi görmektedir. Son katman çıktı katmanı olarak bilinir ve nihai karar çıktı katmanından alınır. Bu iki katman arasında gizli katman adı verilen katmanlar bulunmaktadır. Gizli katman sayısı arttıkça modelin derinliği artmaktadır.



Şekil 3.5. Çok Katmanlı Algılayıcı Örneği

Yapay sinir ağlarında, eğitimi hızlandırmak, genelleme probleminin üstesinden gelmek ve gerçek dünya problemlerini çözebilmek için doğrusal olmayan aktivasyon fonksiyonları kullanılır. Aşağıda aktivasyon fonksiyonlarından örnek olarak sigmoid, hiperbolik tanjant, ReLU aktivasyon fonksiyonlarının formülleri verilmiştir. Denklem 3.1’de sigmoid aktivasyon fonksiyonunu, Denklem 3.2’de hiperbolik tanjant aktivasyon fonksiyonunu, Denklem 3.3’te ReLU (Rectified Linear Unit) aktivasyon fonksiyonu gösterilmektedir.

Sigmoid aktivasyon fonksiyonu,

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (3.1)$$

Hiperbolik tanjant aktivasyon fonksiyonu,

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.2)$$

ReLU aktivasyon fonksiyonu,

$$ReLU(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.3)$$

Yapay sinir ağlarında temel amaç gerçek ile tahmin arasındaki farkı en aza indirmektir. Kayıp fonksiyonu, gerçek ile tahminin arasındaki farkı ölçümlemektedir. Kayıp fonksiyonun sonucu, gradyenleri hesaplamak için kullanılır. Bu gradyen değerlerine göre algoritmalarla kullanılarak, eğitimde geriye yayılım adımında sinir ağındaki ağırlık değerleri güncellenmektedir.

Çoğunlukla sınıflandırma problemlerinde kullanılan ve iki olasılık dağılımı arasındaki farkı kullanan çapraz entropi tabanlı kayıp fonksiyonları bulunur. Çıktı katmanında iki sınıf varsa, ikili çapraz entropi kayıp fonksiyonu kullanılabilir. Sınıf sayısı ikiden fazla olduğu durumda kategorik çapraz entropi kayıp fonksiyonu kullanılabilir. Ana amaç sınıflandırma yerine bir regresyon işlemi ise kayıp fonksiyonu olarak ortalama karesel hata kaybı veya karesel hata kaybı kullanılabilir.

Bazı kayıp fonksiyon formülleri aşağıda verilmektedir.

İkili Çapraz Entropi kayıp fonksiyonu,

$$L = -(y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (3.4)$$

Kategorik çapraz entropi kayıp fonksiyonu,


$$L = \sum_{i=1}^M y_i \log(\hat{y}_i) \quad (3.5)$$

Ortalama karesel hata kayıp fonksiyonu,

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.6)$$

3.2.1.2. Evrişimli Sinir Ağları

Evrişimli sinir ağları (ESA), insan görme sisteminden esinlenerek geliştirilmiş bilgisayarlı görü gibi problemlerde kullanılmakta olan bir yapıdır. Evrişimli sinir ağları genellikle evrişim, ortaklama ve tam bağlantı gibi katmanlardan oluşmaktadır. Şekil 3.6’da basit bir evrişimsel sinir ağı verilmiştir.




Şekil 3.6. Basit Bir Evrişimsel Sinir Ağı Mimarisi

Şekil 3.6 incelendiğinde girdi ilk olarak evrişimsel katmana verilmektedir. Evrişimsel katmanın öncelikli amacı, veriyi en iyi tanımlayan öznitelikleri çıkarmaktır. Evrişim katmanında, pikseller arasındaki uzamsal bilgiyi korumaktadır. Havuzlama katmanı ise hesaplama yükünü azaltmak ve ezberlemenin önüne geçmek için alt örnekleme yaparak girdi boyutunu azaltmaktır (Cengil,2021).

Genellikle evrişimli sinir ağlarında evrişim ve havuzlama katmanından sonra tam bağlantılı katman gelir. Tam bağlantılı katman kendinden önce gelen katmandaki tüm alanlarına bağlanmaktadır. Bu katmanın ardından sınıflandırma katmanı gelmektedir. İsminden de anlaşılacağı gibi bu katmanda sınıflandırma işlemi gerçekleştirilmektedir. Bu katmandaki çıkış değeri, sınıflandırılacak veri türünün sayısına eşittir. (İnik ve Ulker,2017)

İlk evrişimli sinir ağı 1988 yılında Yann LeCun tarafından ortaya çıkarılan LeNet'tir. LeNet evrişimli sinir ağında, art arda yerleştirilmiş konvolüsyon ve maksimum havuzlama katmanlarından oluşmaktadır. (LeCun ve ark.,1988) Şekil 3.7’de LeNet ağ yapısı gösterilmektedir.



Şekil 3.7. LeNet Mimarisi (Dive Into Deep Learning)


2012 yılında, Krizhevsky ve arkadaşları AlexNet isimli bir model önermiştir. AlexNet modeli ReLu aktivasyon fonksiyonuna ve sekizden fazla sayıda katmana sahiptir. Bu katmanların ilk 5'i evrişimli katman ve son 3'ü tamamen bağlı katmanlardır (Krizhevsky ve ark.,2012).

AlexNet, araştırma dünyasına büyük bir ilham olmuş ve insanlığın derin evrişimli sinir ağlarına yönetmesine sağlamıştır. Bu dönemden sonra birçok derin evrişimli sinir ağları geliştirilmiş ve önerilmiştir. Örneğin GoogleNet (Szegedy ve ark.,2015), doğruluğu artırarak başlangıç modülünü tanıttı. Daha sonra 2015 yılında ResNet (He ve ark., 2015) artık bağlantı mimarisi ile rakiplerini geride bıraktı. ResNet mimarisi, ReLu aktivasyon fonksiyonu ve atlamalı bağlantı mekanizması ile derin ağlarda türev tabanlı optimizasyon algoritmaları nedeniyle oluşan kaybolan gradyen gibi problemlere çözüm getirmiştir.

Nesne Tespit Algoritmaları

Nesne tespiti, görüntü veya videolarda belirli anlamsal nesnelerin bilgisayarlı görü ve görüntü işleme gibi teknolojiler kullanılarak tespit edilmesi işlemidir

Genellikle nesnenin fiziksel özellikleri (boyutları, temel şekil vb.) özellikleri nesne tespitinin temeli olarak kullanılır ve nesne tespit algoritmaları, sınırlayıcı bir kutu içindeki nesnelerin varlığını bulmaya çalışır. AlexNet'in büyük başarısının ardından görüntü işleme tabanlı yöntemler yerini derin öğrenme tabanlı nesne algılama yöntemlerine bırakmıştır. Derin öğrenme tabanlı nesne algılama, geleneksel görüntü işleme tabanlı yöntemlerden daha kesin sonuçlar vermektedir. Şekil 3.8'de derin öğrenme tabanlı nesne tespit algoritmalarının kategorileri verilmiştir.




Şekil 3.8. Derin Öğrenme Tabanlı Nesne Tespit Algoritmaları (Khan ve ark.,2021)

İki aşamalı nesne algılama algoritmaları, öncelikle aranan nesne için bölge önerisi yapar ve ikinci aşamada sınıflandırmayı gerçekleştirir. Bunun yanında, tek aşamalı algılama algoritmaları yerelleştirmeyi ve sınıflandırmayı aynı anda gerçekleştirir.

Son olarak ileri seviye algılayıcılarda, nesneleri aramak için kullanılan belirli bir yükseklik ve genişliğe sahip olan çapa kutusunu (anchor box) kullanmazlar (Khan ve ark.,2021). Derin öğrenme tabanlı nesne tespit algoritmalarının kıyaslanmak için Pascal Voc veri seti (Everingham ve ark.,2010) yayın olarak kullanılmaktadır. Her yıl gerçekleştirilen yarışmalar ile yeni geliştirilen derin öğrenme tabanlı nesne tespit algoritmaları karşılaştırılmaktadır.

Redmon ve ark. 2016 yılında açıkladığı YOLO algoritması, görüntü üzerinden tek seferde tüm nesneleri algılar. Bu mekanizma hesaplama süresinde azalmasına imkân sunmaktadır. Algoritma görüntüyü ilk olarak $N*N$ 'lik ızgaralara böler ve herhangi bir nesnesin merkez noktası algılanırsa, o belirli ızgara, nesne tespiti için karar veren ızgaradır. (Redmon ve ark.,2016)

YOLO9000 veya YOLOV2, Redmon ve ark. tarafından geliştirmiştir. YOLOV2'in çıkarsama süresi (inference time), farklı veri kümelerinde de belirli bir süre için diğer derin öğrenme tabanlı nesne tespit algoritmalarından daha kısaydı. Gerçek zamanlı olarak 9000'den fazla sınıfı tespit edebilmektedir (Redmon ve ark., 2016). YOLOV3, geleneksel lojistik regresyonun yardımıyla, her sınırlayıcı kutu için bir nesnelik puanı tahmin etmektedir. Softmax'ın performans kısmında yetersiz olduğu iddiası nedeniyle, lojistik sınıflandırıcılar kullanılmaktadır. Eğitim aşamasında, geliştiriciler sınıf tahminleri için ikili çapraz entropi kaybını tercih ettiler. Şekil 3.9'da YOLOV3 mimarisi gösterilmektedir.




Şekil 3.9. YOLOV3 Mimarisi (Redmon ve ark., 2018)

YOLOV4 mimarisi ise 2020 yılında Bochkovskiy ve arkadaşları tarafından tanıtılmıştır. Bu mimaride yazarlar, yeni bir veri artırma yöntemi ve öz çekişmeli eğitim (self-adversarial training) önermişlerdir. Genetik algoritmalar ile optimum hiper parametreler seçilmektedir (Bochkovskiy ve ark.,2020).

YOLOV5 ise Ultralytics tarafından açık kaynak olarak 2020 yılında tanıtılmış ve Coco veri kümesi üzerinde eğitilmiştir (Ultralytics,2020). YOLOV5 temel olarak üç bölümden oluşmaktadır. Diğer derin öğrenme tabanlı nesne tespit algoritmalarında olduğu gibi omurga algoritması kullanılır. YOLOV5 omurga olarak CSPDarknet kullanır.

Özellik çıkarımı için girdi verileri bu omurgadan geçmekte ve boyun için kullanılan PANet (Wang ve ark.,2019) yapısına geçmekte ve özellik birleştirme gerçekleşmektedir. Sınıflandırma katmanında ise nesne sınıf, nesne konumu ve algılama puanı hesaplanmaktadır. YOLOV5 mimarisi Şekil 3.10'da gösterilmektedir.




Şekil 3.10. YOLOV5 Mimarisi (Xu ve ark., 2021)

3.2.1.3. Otokodlayıcılar


Oto kodlayıcılar, fazla boyutlu veri setini sıkıştırarak daha sonrasında sıkıştırılmış halinden yeniden elde edilmesini gerçekleştiren denetimsiz öğrenme metodudur. Veri setinin yüksek verimli olarak nasıl sıkıştırılıp ve yeniden yapılandıracağını öğrenerek girdi görüntüsünün tekrardan üretmeye çalışmaktadır (Rumelhart ve ark., 1986).

Ana amacı, veri setini küçülterek veriyi en iyi temsil eden özellikleri çıkarmaktır. Oto kodlayıcılar, kodlayıcı ve kod çözücü katmanlarından oluşmaktadırlar. Şekil 3.11’de basit bir otokodlayıcı verilmiştir. Şekil 3.11 incelendiğinde basit otokodlayıcıların 2 temel katman olduğu gözlemlenebilir.



Şekil 3.11. Basit Otokodlayıcı Örneği

Basit otokodlayıcılarda bulunan gizli katman sayısı birden fazla olduğu durumda derin otokodlayıcı olarak isimlendirilmektedir. Derin otokodlayıcı, sıralı kodlayıcı ve kod çözücü katmanlarından oluşmaktadır. Eğitilen alt katman elde ettiği kodu, girdi olarak kullanacak olan diğer bir katmana verir. Kod çözücü katmanları giriş verisi ile değil, kod katmanlarının akışındaki sırayı koruyarak bir önceki katmandan almış olduğu kodu boyutları simetrik olacak şekilde yeniden oluşturmaya çalışmaktadır (Doğan,2019). Şekil 3.12’de derin otokodlayıcı yapısı verilmiştir.



Şekil 3.12. Derin Otokodlayıcı Örneği

3.3. Performans Metrikleri

Doğruluk (accuracy), kesinlik (precision), hatırlama (recall) ve F1 puanı performans değerlendirmesinde kullanılmaktadır. Bu metriklerin hesaplanması için gerçek pozitif (TP), gerçek negatif (TN), yanlış negatif (FN) ve yanlış pozitif (FP) parametrelerini tanımlamak gerekmektedir.

Gerçek pozitif, gerçekte bulunan ve nesnenin algoritma tarafından doğru olarak tespit edilme durumu; yanlış pozitif, gerçekte nesnenin bulunmadığı ve algoritmanın da nesne tespiti yapmadığı durumu; yanlış negatif, gerçekte bulunan nesnenin algoritma tarafından tespit edilmeme durumu; yanlış pozitif, gerçekte nesnenin olmadığı fakat algoritmanın nesne olarak gördüğü durumu ifade etmektedir. Denklem 3.1’de doğruluk formülü, denklem 3.2’de kesinlik, denklem 3.3’te hatırlama ve denklem 3.4’te F1 puanı denklemi verilmiştir.

Doğruluk aşağıdaki denklemdeki gibi hesaplanabilir:

$$\text{Doğruluk} = \frac{TP+T}{TP+TN+FP+F} \quad (3.7)$$

Kesinlik, pozitif olarak tespit edilen durumların kaçının doğru olarak tespit edildiğini belirtir. Hatırlama ise gerçekte olumlu olan durumlardan kaç tanesinin olumlu olarak tahmin edildiğini belirtir. Kesinlik ve hatırlama şu şekilde hesaplanabilir:

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.8)$$

$$\text{Hatırlama} = \frac{TP}{TP+FN} \quad (3.9)$$


F1 puanı ise aşağıdaki şekilde ifade edilebilen kesinlik ve hatırlamanın harmonik ortalamasıdır:

$$\text{F1 Puanı} = \frac{2*TP}{2*TP+FP+FN} \quad (3.10)$$

4. DENEYSEL KURULUM

Kat ekleme makinesinin ek yeri proseslerinde ek yeri açıklık, eksik kaplama gibi birçok anomali durum meydana gelmektedir. Bu anomalilerin yakalanmaması durumunda son üründe kalite problemleri meydana gelmekte ve bu durum hurda miktarının artmasına neden olmaktadır.

Anomali durumların ekleme anında olması ve olduğu anda yakalanması gerekmesinden dolayı bu tez kapsamında kamera sistemi kat ekleme makinesine kurulmuştur. Sistemin uygulandığı Brisa firmasının gizliliği nedeniyle tasarlanan sistemin gerçek görüntülerine yer verilememektedir. Şekil 4.1’de tasarlanan sistem yapısal ve kurgusal olarak gösterilmektedir.



Şekil 4.1. Tasarlanan Sistem

Sistem tasarımının en önemli noktalarından biri ise çalışmanın deneysel kısmının bir laboratuvar ortamı yerine canlı üretim hattı üzerinde çalışıyor olmasıdır. Literatürdeki çalışmalarda genellikle deneysel ortam hazırlığı laboratuvar ortamında yapılır. Saha koşulları ideal ve stabil koşullar ile yapay olarak oluşturulur.

Bu ve benzeri çalışmalar çoğu zaman çevresel değişkenliklerden yoksun ve değişen şartlara adaptasyon özelliği düşük olur. Bu sebeple bu tez çalışmasında ideal bir test ortamını yapay olarak kurmak yerine canlı üretim yapan bir ortamda sistem geliştirmeleri ve testleri tamamlanmıştır. Çalışma laboratuvar ortamında yapılmış olsaydı özellikle çevresel etki olan ışıklandırma ve çalışma titreşimi simüle edilemeyecek, simüle ortamda deneysel başarımlar yüksek iken akan banttaki gerçek uygulamanın başarımları düşük olabilecekti. Bu sebeple bu tez çalışmasında üretimi devam eden bir endüstriyel çevreye uyum sağlayabilecek bir sistem tasarımının gerçekleştirilmesi ele alınmıştır.

Kat işleme makinasının çalışma metodu incelendiğinde, rulo halinde istiflenmiş kaplanmış kat malzemesi en geniş hali ile imalat makinesine beslenir. Makine bileşen tanımlarından gelen uygun genişlik ve uzunluğa göre ham kat malzemesi kesme ünitesinde kesilir ve konveyör beslemesine aktarılır. Devam eden konveyör hattında kesilen malzemeler genişlikler yönünde birbirine eklenerek ham lastik üretimini besleyecek uzunlukta kat malzemeleri elde edilir. Ekleme çekli kullanım koşullarına göre değişmektedir. Tanımlardan gelen bilgiye göre uçların üst üste izin verilen kalınlık ve genişlikte bindirilmesi ya da uç uca tam teğet ekleme olarak gerçekleştirilir. Özellikle uç uca ekleme durumunda ek bölgesi boyunca bir açıklık veya düzensizlik olmaması kritiktir.

Değişen çevresel yapı, proses parametreleri ve malzeme geçişleri ile bu ek yerlerinde kusurlar (hata, özür, düzensizlik) oluşabilmektedir. Sistemin bu kusurları yakalayabilmesi için deneysel tasarım kurulumu ekleme işleminin yapıldığı makine fazına kurulmuştur. Şekil 4.1’de gösterilen yapıda olduğu gibi aydınlatma, kamera ve bilgisayar ünitesi sistem karakterini ve kararlılığını belirlemektedir.

Yapılan tasarımda özellikle aydınlatma, kamera ve bilgisayar gibi bileşenlerin endüstriyel ortama uygun olmasına özen gösterilmiştir. Özellikle üretim çevresel koşulları düşünüldüğünde bölgede gece ve gündüz arasında aydınlık şiddeti açısından farklılıklar gözlemlenmektedir.

Deneysel çalışmada kullanılan kamera 12 megapiksel çözünürlüktedir ve otomatik odaklama özelliği bulunmaktadır. Kamera kullanılan 8 mm lens ile 96×54 cm’lik bir alan görmekte olup “rolling shutter” bir sensöre sahip olması sebebiyle yakalanan görüntünün net olması için görüntü alma anında hareketli konveyörün durması gerekmektedir.

Veri toplama işlemi için Şekil 4.1’de gösterilen endüstriyel bilgisayar olarak NVIDIA Jetson Nano kullanılmaktadır. Sistemin canlıda kullanılması aşamasında yüksek performanslı bir ekran kartına ve işlemciye sahip bir endüstriyel bilgisayarın kullanılması planlanmaktadır.

Seçilmiş olan aydınlatma çevresel değişkenlikten gelen farklılıkları çözebilecek nitelikte olmalıdır. Benzer yaklaşım ile seçilen kamera ve bilgisayar endüstriyel ortamlarda çalışabilecek özelliklerdedir. Çalışma şartları altında sınırları belirlenmiş çevresel değişkenliklerden etkilenmemeleri önemlidir.

Yapılan sistem tasarımına göre besleme tarafındaki kesici devreye girdiğinde konveyör hızı değişir ve ekleme işlemi sistem durduğu an gerçekleşir. Sistem ek yeri eklenme bölgesini işleyerek anomali tespitlerine odaklanır.

Geliştirilen algoritma sistem bilgisayarında çalışır ve sınıflandırıcının verdiği karar bir uyarı ile operatöre gösterilir. Mevcut sonuçlar makine ile eşleştirilerek bulut sunucular üzerinde arşivlenmektedir.

5. GELİŞTİRİLEN YÖNTEM

Bu bölümde tez kapsamında oluşturulan veri seti ve geliştirilen melez yöntem açıklanmaktadır. Veri seti alt bölümünde oluşturulan veri seti detaylı şekilde açıklanmıştır. Sistem mimarisi bölümünde, geliştirilen, sınıflandırma ve anomali tespit modelinin yekpare olarak kullanıldığı melez bir yöntem anlatılmaktadır.

5.1. Veri Seti

Modellerin başarımını artırabilmek için örnek çeşitliliğinin sağlamasını adına kapsamlı bir veri seti oluşturulmuştur. Veri seti oluşturulurken kat bileşen parçalarının eklenme anında oluşan anomaliler elle müdahale ile manuel şekilde oluşturulmuştur. Bunun yanında makineyi kullanan operatörlerden gelen geri dönütler ile anomali yaşanan anlardaki görüntüler ile veri seti büyütülmüştür.

Veri setinde 1880 tanesi anomali (özür) içeren ve 2150 tanesi anomali içermeyen olmak üzere toplamda 4030 adet görüntü bulunmaktadır. Tablo 5.1’de veri seti dağılımı gösterilmektedir.

Tablo 5.1. Veri Seti Dağılımı

Sınıf	Veri Sayısı
Anomali İçeren	1880
Anomali İçermeyen	2150


Bunun yanında anomali içeren görüntülerde anomali tipinin tespit edilmesi için görüntülerin etiketleme işlemi gerçekleştirilmiştir. Anomali olarak nitelendirilen görüntüler eksik kaplama, uygunsuz kenar alma, hatalı ek yeri, dağılım bozukluğu ve ek yeri açıklık olmak üzere toplamda 5 sınıftan oluşmaktadır. Tablo 5.2’de anomali içeren görüntülerin anomali tipine göre veri setindeki dağılımı gösterilmiştir.

Tablo 5.2. Anomali İçeren Görüntülerin Sınıf Bazlı Dağılımı

Anomali Tipi	Veri Sayısı
Ek Yeri Açıklık	1187
Hatalı Ek Yeri	1264
Uygunsuz Kenar Alma	551
Eksik Kaplama	1009
Dağılım Bozukluğu	104

5.2. Sistem Mimarisi

Bu çalışmada otokodlayıcı sistemi ve sınıflandırma modeli içeren melez bir model geliştirilmiştir. Şekil 5.1’de geliştirilen sistem mimarisi gösterilmektedir.



Şekil 5.1. Geliştirilen Melez Sistem Mimarisi


Bu çalışmanın akan bir konveyör hattı üzerinde gerçekleştirilmesinden dolayı öncelikle kat bileşen parçalarının hareketli halden hareketsiz hale gelmesi gerekmektedir. Konveyörün hareketsiz olduğu anı yakalamak için bir arka plan çıkarıcı kullanılmıştır. Arka plan çıkarıcı genel itibarıyla ardışık iki çerçeve (frame) arasındaki değişime bakmaktadır. Eğer iki çerçeve arasındaki değişim büyükse konveyörün hareketinin devam etmekte olduğu, değilse konveyörün durduğu kararı verilmektedir. Şekil 5.2’de konveyör dururken ve hareket halindeyken hesaplanan ardışık çerçevelerinin farklarının eşiklenmiş ($T=35$ ile) hali görselleştirilmiştir. Hareketsiz anın tespit edilmesinin ardından alınan çerçeve Şekil 5.1’de gösterilen melez sistemin diğer adımlarına geçmektedir. Melez sistem sonucunu dönmesinin ardından sistem hareketli durumun oluşmasını beklemektedir.



Şekil 5.2. Hareketsiz Durum Tespiti, (a) Hareketsiz durumdayken ardışık çerçeve farkı, (b) hareketli durumda ardışık çerçeve farkı


Kat bileşen parçaların genişliklerinin sabit olmaması nedeniyle parçaların genişliklerinin tespit edilmesi gerekmektedir. Bu nedenle girdi olarak alınan görüntü üzerine ilk olarak kat malzeme genişliği tespit edilmektedir.

Bu işlem yapılırken ilk olarak tüm görüntü kullanmaktansa küçük bir ilgi alanı kullanılarak işlem yükü azaltılmıştır. Elde edilen görüntünün ilk olarak renk formatı BGR'dan gri tonlu seviyeye dönüştürülmektedir. Sonrasında görüntüdeki gürültüleri temizlemek için çekirdek boyutu 5 olan ortanca süzgeci (median filter) uygulanmaktadır. Kenarların belirginleştirilmesi için Prewitt operatörü kullanılmıştır. Bu işlemin ardından sabit bir eşikleme ile görüntü ikili (binary- siyah-beyaz) hale dönüştürülmektedir. Daha sonra siyah-beyaz görüntü üzerinde çevrit (contour) tespiti yapılmaktadır. Tespit edilen her bir çevritin alanı hesaplanmaktadır, hesaplanan çevrit alanları belirlenen sabit eşik değerinin altındaysa ($T = 20 \text{ px}^2$) görüntüden silinmiştir. Böylelikle siyah-beyaz görüntü üzerinde iki adet çevrit kalmaktadır. Bu çevritler kat bileşen parçalarının sınırlarını göstermektedir. Sonrasında, elde edilen iki çevritin merkez noktaları tespit edildikten sonra bu noktalar kullanılarak kat bileşen parçalarının genişliği tespit edilmektedir. Bu kısımda hatalı durum oluşabilme durumundan dolayı tespit edilen genişliğe güven payı verilmiştir. Şekil 5.3'te kat genişlik parçalarının genişliklerinin tespiti gösterilmektedir.




Şekil 5.3. Kat Bileşen Parçalarının Genişlik Tespiti

Kat bileşen parçaların genişliğinin tespit edilmesin ardından, her zaman kameranın aynı noktasına gelen ek yeri ekleme bölgesi tüm görüntüden kesilerek elde edilmektedir. Ekleme bölgesinin elde edilmesi Şekil 5.4'te gösterilmektedir.



Şekil 5.4. Ek Yeri Ekleme Bölgesinin Tespit Edilmesi

Girdi görüntüsünden ek yeri ilgi alanının çekilmesinin ardından otokodlayıcı sistemine verilmektedir. Otokodlayıcı sistemi Şekil 5.5'te verilmiştir. Şekil 5.5 incelendiğinde otokodlayıcı sistem 2 otokodlayıcı ve otokodlayıcıların çıkışlarını bağlayan bir karar mekanizmasından oluşmaktadır.



Şekil 5.5. Otokodlayıcı Sistem

Otokodlayıcı sistemde bulunan otokodlayıcılar, otokodlayıcı-1 ve otokodlayıcı-2 olarak isimlendirilmiştir. Her iki otokodlayıcının ağ yapısı birbirinin aynısıdır. Şekil 5.6'te otokodlayıcıların ağ yapısı verilmektedir. Geliştirilen otokodlayıcı modellerinde farklı sayıda ve boyutta katmanlar, farklı optimizasyon fonksiyonları, girdi görüntüsünün boyutu gibi parametreler değiştirilerek en optimum model elde edilmiştir. Şekil 5.6 incelendiğinde modelde 7 evrimsel katmandan oluştuğu gözlemlenebilir.

Otokodlayıcılar arasındaki fark, otokodlayıcı -1 modeli anomali içermeyen veriler ile, otokodlayıcı-2 modeli ise anomali içeren veriler ile eğitilmiştir.

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 256, 256, 128)	3584
max_pooling2d_1 (MaxPooling2)	(None, 128, 128, 128)	0
conv2d_2 (Conv2D)	(None, 128, 128, 64)	73792
max_pooling2d_2 (MaxPooling2)	(None, 64, 64, 64)	0
conv2d_3 (Conv2D)	(None, 64, 64, 32)	18464
max_pooling2d_3 (MaxPooling2)	(None, 32, 32, 32)	0
conv2d_4 (Conv2D)	(None, 32, 32, 32)	9248
up_sampling2d_1 (UpSampling2)	(None, 64, 64, 32)	0
conv2d_5 (Conv2D)	(None, 64, 64, 64)	18496
up_sampling2d_2 (UpSampling2)	(None, 128, 128, 64)	0
conv2d_6 (Conv2D)	(None, 128, 128, 128)	73856
up_sampling2d_3 (UpSampling2)	(None, 256, 256, 128)	0
conv2d_7 (Conv2D)	(None, 256, 256, 3)	3459

Şekil 5.6. Otokodlayıcıların Ağ Yapısı

Otokodlayıcıların çıkışı bir karar mekanizması ile birbirine bağlanmıştır. Her iki otokodlayıcıdan gelen çıkışa bakarak bir karar verilmektedir. Tablo 5.3'te otokodlayıcı sistemin karar mekanizması verilmiştir.

Tablo 5.3. Otokodlayıcı Sistemin Karar Mekanizması

Otokodlayıcı-1 Çıktısı	Otokodlayıcı-2 Çıktısı	Karar
Anomali Yok	Anomali Yok	Anomali Yok
Anomali Yok	Anomali Var	Anomali Yok
Anomali Var	Anomali Yok	Anomali Yok
Anomali Var	Anomali Var	Anomali Var

Tablo 5.3 incelendiğinde, herhangi bir otokodlayıcıdan “Anomali Durum” tespit edilmemesi durumunda otokodlayıcı sistem “Anomali Yok” bilgisi dönmektedir. Her iki otokodlayıcıdan “Anomali Durum” bilgisi geldiği takdirde girdi görüntüsü sınıflandırma modeline verilmektedir. Sınıflandırma kısmında YOLOV5 ve Faster R-CNN modelleri kullanılmış ve karşılaştırılmıştır. Sınıflandırma modelleri 5 sınıflı olarak eğitilmiştir.


6. DENEYSEL SONUÇLAR

Bu bölümde ilk olarak otokodlayıcı sistem sonuçları, daha sonrasında sınıflandırıcı model sonuçları anlatılmaktadır. Bölümün en sonunda ise geliştirilen melez sistemin sınıflandırıcı model ve otokodlayıcı sistem ile karşılaştırılması anlatılmaktadır.

6.1. Otokodlayıcı Sistem Sonuçları

Bölüm 5.2’de anlatıldığı gibi otokodlayıcı sistem, iki adet aynı mimari ağ yapısına sahip otokodlayıcıdan ve bir adet karar mekanizmasından oluşmaktadır. Otokodlayıcılar arasında bulunan tek fark eğitildikleri veri setidir.

Şekil 5.4’te de görülebileceği üzere otokodlayıcı-1 olarak isimlendirilen model anomali içermeyen görüntüler ile otokodlayıcı-2 olarak isimlendirilen model ise anomali içeren görüntüler ile eğitilmiştir. Her iki otokodlayıcı model eğitiminde, 100 döngü süresince 64 batch boyutunda eğitim işlemi gerçekleştirilmiştir. Her iki modelinde kayıp grafiği Şekil 6.1’de gösterilmektedir.



Şekil 6.1. Otokodlayıcı Modellerin Kayıp Grafiği

Eğitim işleminin ardından eğitimde kullanılmayan 188 adet anomali içeren ve 150 adet anomali içermeyen görüntü ile performans testi gerçekleştirilmiştir. Tablo 6.1’de otokodlayıcıların ayrı ayrı ve otokodlayıcı sistemin karmaşıklık matrisi gösterilmektedir. Tablo 6.1’de bulunan 0, anomali durum olmadığını belirtirken; 1, anomali durumu ifade etmektedir.

Tablo 6.1. Otokodlayıcıların Karmaşıklık Matrisi


		Tahmin					
		Otokodlayıcı-1		Otokodlayıcı-2		Otokodlayıcı Sistem	
		0	1	0	1	0	1
G e r ç e k	0	133	17	137	13	141	9
	1	9	179	21	167	11	177

Tablo 6.2’de otokodlayıcıların ayrı ayrı performans sonuçlarını ve otokodlayıcı sistemin performans sonuçları doğruluk bazlı karşılaştırılması gösterilmektedir. Tablo 6.2 incelendiğinde anomali içermeyen görüntüler ile eğitilen otokodlayıcı-1 modelinin, anomali içeren görüntüler içeren görüntüler ile eğitilen otokodlayıcı-2 modelinden daha yüksek başarımlar elde ettiği gözlemlenebilir, fakat bunun tam tersine olacak şekilde çıkarım zamanını arttırdığı gözlemlenebilir.

Bunun yanında otokodlayıcıların ayrı ayrı kullanılmaktansa, ikisinin aynı anda bir sistem olarak kullanıldığında başarımların artmış olduğu gözlemlenebilir. Şekil 6.2’de anomali tespit sonuçlarına ait örnek görüntüler verilmiştir.

Tablo 6.2. Otokodlayıcı Sistemin Performans Değerleri

Performans Metrikleri		Otokodlayıcı-1	Otokodlayıcı-2	Otokodlayıcı Sistem
TP		133	137	141
FP		9	21	11
FN		17	13	9
TN		179	167	177
Doğruluk		0.923	0.899	0.941
Çıkarım Zamanı (ms)	Jetson Nano	621.21	621.11	1239.34
	A6000	15.43	15.51	29.45



Şekil 6.2. Anomali Tespit Sonuçlarına Ait Örnek Görüntüler

6.2. Sınıflandırma Model Sonuçları

Sınıflandırma modelinde YOLOV5 ve Faster-RCNN algoritmaları kullanılarak karşılaştırma yapılmıştır. Eğitimlerde kullanmak üzere bölüm 5.1’de anlatılan veri setinden anomali içeren görüntüler kullanılmıştır. Eğitimlerde kullanılan veri seti Tablo 6.3’te verilmiştir. Ayrıca eğitimde doğruluğu artırabilmek için TN örnekler yani anomali içermeyen özürsüz örneklerde eklenmiştir.

Tablo 6.3. Sınıflandırma Eğitiminde Kullanılan Veri Seti

Anomali Tipi	Anomali Veri Sayısı	
	Eğitim	Doğrulama
Ek Yeri Açıklık	901	167
Hatalı Ek Yeri	951	178
Uygunsuz Kenar Alma	403	85
Eksik Kaplama	771	143
Dağılım Bozukluğu	78	14

Tablo 6.3’te verilen veri seti ile hem YOLOV5 hem de Faster-RCNN algoritmaları eğitilmiştir. Eğitim işleminin ardından eğitimde kullanılmayan 188 adet anomali içeren ve 150 adet anomali içermeyen görüntü ile performans testi gerçekleştirilmiştir. Performans testinde kullanılacak anomali içeren görüntülerin anomali tipi bazlı dağılımı Tablo 6.4’te gösterilmektedir.

Tablo 6.4. Performans Testinde Kullanılan Anomali Tipi Bazlı Veri Sayısı

Anomali Tipi	Anomali Veri Sayısı
	Test
Ek Yeri Açıklık	119
Hatalı Ek Yeri	135
Uygunsuz Kenar Alma	63
Eksik Kaplama	95
Dağılım Bozukluğu	12

Bölüm 5.2’de anlatıldığı üzere sınıflandırma modeline girdi olarak alınan görüntü de herhangi bir tespit olmazsa “Anomali Yok” bilgisi, tersi bir durumda ise “Anomali Durum” bilgisi dönmektedir. Sınıflandırma modellerinin anomali tespitindeki karmaşıklık matrisi Tablo 6.5’te gösterilmektedir. Tablo 6.5 incelendiğinde YOLOV5 modelinin doğruluğu 0.932, Faster R-CNN modelinin doğruluğu ise 0.88 seviyelerindedir.

Tablo 6.5. Sınıflandırma Modellerinin Anomali Tespitindeki Karmaşıklık Matrisi

		Tahmin			
		YOLOV5		Faster R-CNN	
		0	1	0	1
Gerçek	0	138	12	130	20
	1	11	177	23	172

Faster R-CNN modelinin anomali tipi bazlı karmaşıklık matrisi Tablo 6.6’da gösterilmektedir. Tablo 6.6 incelendiğinde Faster R-CNN modelinin, eksik kaplama özrü ile dağılım bozukluğu özrünü ve hatalı ek yeri özrü ile ek yeri açıklık ve hatalı kenar alma özürleriyle karıştırdığı gözlemlenebilir. Tablo 6.7’de Faster R-CNN modelinin anomali tiplerinin performans metrik sonuçları gösterilmektedir.

Tablo 6.6. Faster R-CNN Modeli Anomali Tipi Bazlı Karmaşıklık Matrisi

Gerçek \ Tahmin	Ek Yeri Açıklık	Hatalı Ek Yeri	Hatalı Kenar Alma	Eksik Kaplama	Dağılım Bozukluğu	FN
Ek Yeri Açıklık	95	9	0	0	0	15
Hatalı Ek Yeri	8	109	7	0	0	11
Hatalı Kenar Alma	0	6	51	0	0	6
Eksik Kaplama	0	0	5	67	7	16
Dağılım Bozukluğu	0	0	0	2	8	2

Tablo 6.7. Faster R-CNN Modeli Performans Sonuçları

Performans Metrikleri	Ek Yeri Açıklık	Hatalı Ek Yeri	Hatalı Kenar Alma	Eksik Kaplama	Dağılım Bozukluğu	Ortalama
Kesinlik	0.880	0.826	0.850	0.807	0.727	0.838
Hatırlama	0.864	0.908	0.895	0.807	0.800	0.868
F1 Puanı	0.872	0.865	0.872	0.807	0.762	0.853

YOLOV5 modelinin anomali tipi bazlı karmaşık matrisi Tablo 6.8’de gösterilmektedir. Tablo 6.8 incelendiğinde sınıflandırma modelinin, ek yeri açıklık özü ile hatalı ek yeri özünün karıştığı gözlemlenebilir. Bunun yanında eksik kaplama özüne ait bazı verilerin gözle bile ayırt etmekte zorlanması dolayısıyla sınıflandırma modeli bu verileri tespit edememiştir. Tablo 6.9’da ise anomali tiplerinin performans metrik sonuçları gösterilmektedir.


Tablo 6.8. YOLOV5 Modeli Anomali Tipi Bazlı Karmaşıklık Matrisi

Gerçek \ Tahmin	Ek Yeri Açıklık	Hatalı Ek Yeri	Hatalı Kenar Alma	Eksik Kaplama	Dağılım Bozukluğu	FN
Ek Yeri Açıklık	111	5	0	0	0	3
Hatalı Ek Yeri	7	120	3	0	0	5
Hatalı Kenar Alma	0	4	57	0	0	2
Eksik Kaplama	0	0	2	78	3	12
Dağılım Bozukluğu	0	0	0	0	11	1

Tablo 6.9. YOLOV5 Modeli Performans Sonuçları

Performans Metrikleri	Açıklık	Hatalı Ek Yeri	Hatalı Kenar Alma	Eksik Kaplama	Dağılım Bozukluğu	Ortalama
Kesinlik	0.949	0.896	0.919	0.918	0.786	0.915
Hatırlama	0.974	0.960	0.966	0.867	0.917	0.943
F1 Puanı	0.961	0.927	0.942	0.891	0.846	0.929

YOLOV5 ve Faster R-CNN model sonuçları incelendiğinde YOLOV5 modelinin başarımının daha yüksek olduğu gözlemlenebilir. Yüksek başarımla elde edilmesi sebebiyle sınıflandırma modeli olarak YOLOV5 modeli seçilmiştir. Melez sistem sonuçlarında sınıflandırma modeli olarak YOLOV5 sonuçları verilmiştir. Şekil 6.3’te sınıflandırma model sonuçlarına ait örnek görseller verilmiştir.



Şekil 6.3. Sınıflandırma Model Sonuçlarına Ait Görseller, (a) Orijinal görüntüler, (b) YOLOV5 tespit sonuçları, (c) Faster-RCNN tespit sonuçları

6.3. Melez Model Sonuçları

Otokodlayıcı sistemin ve sınıflandırma modelinin yekpare olarak kullanıldığı melez modelin anomali tespit sonucu YOLOV5 için Tablo 6.10’da verilmiştir. Tablo 6.10 incelendiğinde melez sistemin başarımının daha da arttırdığı gözlemlenebilir.

Bu başarımların birçoğu nedeni bulunmaktadır. Bu nedenlerden birincisi; otokodlayıcı sistem tarafından anomali olarak tespit edilen fakat gerçekte anomali içermeyen bazı girdiler için sınıflandırıcı modelinde “Anomali yok” bilgisinin dönmesidir. Böylelikle girdi anomali yok olarak algılanmış ve girdi için doğru tespit sağlanmıştır ve bu durum başarımları arttırmıştır.

Diğer bir neden ise; sınıflandırıcı modelin anomali tespitinde bulunduğu fakat gerçekte anomali olmayan girdilerin ilk olarak otokodlayıcı sistem girerek “Anomali Yok” olarak tespitinin gerçekleşmesidir. Böylece girdi sınıflandırıcı modele girmesine gerek kalmadan doğru olarak tespiti edilmiş olur ve bu durum başarımları arttırmıştır.

Tablo 6.10. Anomali Tespit Sonuçları Karşılaştırması

Performans Metrikleri	Otokodlayıcı Sistem	Sınıflandırma Modeli	Melez Sistem
TP	141	138	141
FP	11	11	7
FN	9	12	9
TN	177	177	182
Doğruluk	0.941	0.932	0.953

Diğer yandan melez sistemin anomali tipi tespitindeki başarımı YOLOV5 için Tablo 6.11’de verilmiştir. Tablo 6.11 incelendiğinde melez modelin kesinlik değerinde bir artış olduğu gözlemlenmiştir. Bu durumun temel nedeni sınıflandırma modelinin bazı anomali olmayan durumlarda anomali var sonucun vermesinin otokodlayıcı sistem ile önüne geçilmesidir.

Tablo 6.11. Anomali Tipi Sınıflandırma Başarım Sonuçları

Performans Metrikleri	Sınıflandırma Modeli	Melez Sistem
Kesinlik	0.915	0.919
Hatırlama	0.943	0.942
F1 Puanı	0.929	0.93

7. SONUÇLAR

Teknolojik gelişmelerle birlikte endüstri de yüksek üretim adetlerine ulaşılmıştır. Üretilen mamullerin efektif olarak az yer kaplayarak saklanabilmesi önem sarf etmektedir. Özellikle rulo haline getirilebilen mamullerin saklanması döndürme prosesi kullanılmaktadır. Bu proses gerçekleştirilirken uç uca ekleme yöntemleri kullanılmakta fakat bu yöntemler kullanıldığında kimi zaman anomaliler meydana gelmektedir. Anomalilerin yakalanamaması durumunda ise son üründe kalite problemleri meydana gelmektedir. Kalite problemlerinin önüne geçebilmek için anomalilerin kat ekleme makinesinde ek ekleme anında yakalanması gerekmektedir.

Bu çalışmada kat ekleme makinesinde ek ekleme prosesinde yaşanan anomalilerin tespit edilmesi için denetimsiz öğrenme yapısı olan otokodlayıcı modeller geliştirilmiş ve anomali durumlar için bir sınıflandırma modeli kullanılarak da anomali tipi tespit edilmiştir. Ayrıca çalışmada otokodlayıcı ve sınıflandırma modellerinin beraber kullanıldığı melez bir model önerilmiştir. Önerilen modelde, anomali tespitindeki doğruluğu %95.3, anomalilerin sınıflandırılmasındaki doğruluk ise %91.9 seviyelerine ulaşılmıştır.

Tablo 5.2 incelendiğinde anomalilerin sınıf bazlı düzgün dağılmadığı gözlemlenebilir. Bu durumun önüne geçebilmek için az örneğe sahip olan sınıflara ait veri toplama işlemlerine devam edilecek olup, veri setinin daha düzgün dağılımlı olması hedeflenmektedir. Bunun yanında gelecek çalışmalarda, farklı sınıflandırma algoritmaları kullanılarak sınıflandırma doğruluğunun artırılması, diğer makinelere yayılımı planlanmaktadır. Yapılacak çalışmalarla anomali ve anomali sınıflarının tespiti doğruluklarının artacağı beklenmektedir. Ayrıca çalışmada ortaya çıkan bilgi farklı sahalarda da kullanıma alınabilecek niteliktedir. Diğer üretim sahalarında yaşanan benzer problemler denetimli, denetimsiz ve yarı denetimli yaklaşımlar ile incelenebilir.

KAYNAKLAR

- Abdallah, M., Joung, B., Lee, W., Mousoulis, C., Raghunathan, N., Shakouri, A., Sutherland, J., Bagchi, S. (2023). Anomaly Detection and Inter-Sensor Transfer Learning on Smart Manufacturing Datasets. *MDPI Sensor Journal*, 23(486), 311-333. DOI: 10.339/g23015
- Alan, M. (2020). Derin öğrenme ile biyosinyal sınıflandırma ve hastalık tahmini. Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 651655.
- Ali, M., Paul, B., Ahmet, K., Bui, F., Quinn, J., Moni, M. (2021), Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison. *Computers in Biology and Medicine*, 136(12), 21-45. DOI: 10.1016/1046721
- Baure, A. (2022). Self-Supervised Training with Autoencoders for Visual Anomaly Detection. *Computer Vision and Pattern Recognition*, 10(11), 38-59. DOI: 10.2206/11723
- Cao, S., Yang, N., Liu, Z. (2017), Online news recommender based on stacked auto-encoder. *International Conference on Computer and Information Science (ICIS)*, 16(9), 721-726. DOI: 10.1109/2017.7960088
- Cui, Y., Liu, Z., Lian, S. (2022), A Survey on Unsupervised Visual Industrial Anomaly Detection Algorithms. *Computer Vision and Pattern Recognition*, 21(31), 345-314. DOI: 10.2204/11161
- Deng L., Yu D. (2013), Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*, 7(4), 197-387. DOI: 10.1561/200000039
- Doğan, F., Türkoğlu, İ. (2019), Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 409-445.
- Ekhlayef, O. (2020), Intrusion detection and classification in internet of things networks using machine learning. Yüksek lisans tezi, Altınbaş Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 3456262.
- Elnaqa, I., Murphy, M. (2015), What Is Machine Learning. *In machine learning in radiation Oncology*, 3(11), 41-59. DOI: 10.1007/978-3-319-18305-3_1
- Everingham, M., Van Gool, L., Williams, C. K., Winn, J., Zisserman, A. (2010). The pascal visual object classes (voc) challenge. *International journal of computer vision*, 88(2), 303-338. DOI: 10.1007/s11263-009-0275-4
- Freeman, J. A., Skapura, D. (1991) *Neural Networks Algorithms* (4th ed.). Applications and Programming Techniques. New York, USA: Addison-Wesley Publishing Company.

- He, K., Zhang, X., Ren, S., Sun, J. (2016), Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 13(3), 770-778.
- Jordan, M., & Mitchell, T. (2015). Machine learning: trends, perspectives, and prospects. *Science* 349, 62(45), 255–260.
- Khan, A., Sohail, A., Zahoor, C. (2020), A survey of the recent architectures of deep convolutional neural network. *Artif Intell Rev. Journal*, 4(3), 5455–5516.
- Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., Shah, M. (2021), Transformers in vision: A survey. *ACM Computing Surveys (CSUR)*, 6(9), 467-480.
- Kumar, A., (2008), Computer-vision-based fabric defect detection: A survey. *IEEE Transactions on Industrial Electronics*, 55(1), 348–363.
- Krizhevsky, A., Sutskever, I., Hinton, G. (2012), Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 4(1), 251-268.
- LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W., & Jackel, L. (1988), Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541–551.
- Minhas, M., Zelek, J. (2020). Semi-supervised Anomaly Detection using AutoEncoders, *JCVIS* 5(1), 3-21. DOI: 10.48550/arXiv.2001.03674
- Ofir, N., Yacobi, R., Granoviter, O., Levant, B., Shtalrid, O., (2022), Automatic Defect Segmentation by Unsupervised Anomaly Learning, *IEEE International Conference on Image Processing (ICIP)*, 5(1), 306-310, DOI: 10.1109/ICIP46576.2022.9898035.
- Perez, P., Silva, A., Hueso, E., Escalera A., (2022), Automated Defect Recognition of Castings Defects Using Neural Networks. *Journal of Nondestructive Evaluation*, 9(4), 311-333. DOI: 10.1007/s10921-021-00842-1
- Pulat, M., & Kocakoç, İ. D. (2021), Türkiye’de Makine Öğrenmesi ve Karar Ağaçları Alanında Yayınlanmış Tezlerin Bibliyometrik Analizi. *Manisa Celal Bayar Üniversitesi İ.İ.B.F Yönetim ve Ekonomi Dergisi*, 28(2), 287–308.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 4(3), 356-381.
- Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 31(3) 779-788, DOI: 10.1109/CVPR.2016.91
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. DOI:10.1037/h0042519

- See, J. E., Drury, C. G., Speed, A., Williams, A., Khalandi, N. (2017), The role of visual inspection in the 21st century, *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 1(61), 262–266, <https://doi.org/10.1177/1541931213601548>
- Smolen, P., Baxter, D. A., & Byrne, J. H. (2000). Mathematical modeling of gene networks. *Neuron Journal*, 26(3), 567-580.
- Sun, X., Gu, J., Tang, S., Li, J. (2018), Research progress of visual inspection technology of steel products a review. *Applied Sciences*, 8(11), 41-67.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 1(9), 1011-1021.
- Tailanian, M., Muse, P., Pardo, A., (2022). A Contrario multi-scale anomaly detection method for industrial quality inspection, *Computer Vision Journal*, 11(3), 11-18. DOI: 10.48550/ 2205.11611
- Tan, F. G., Yüksel, A. S., Aydemir, E., Ersoy, M. (2021), Derin Öğrenme Teknikleri ile Nesne Tespiti ve Takibi Üzerine Bir İnceleme. *Avrupa Bilim ve Teknoloji Dergisi*, 1(25), 159-171, DOI: 10.31590/ejosat.878552
- Ulger, F., Yuksel, E., Yilmaz A. (2021). Anomaly Detection for Solder Joints Using β -VAE. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 11(12), 2214-2221, Dec. 2021, doi: 10.1109/TCPMT.2021.3121265
- Wang, K., Liew, J. H., Zou, Y., Zhou, D., & Feng, J. (2019). Panet: Few-shot image semantic segmentation with prototype alignment. *IEEE/CVF International Conference on Computer Vision*, 4(31), 9197-9206.
- Xu, R., Lin, H., Lu, K., Cao, L., & Liu, Y. (2021). A forest fire detection system based on ensemble learning. *Forests Journal*, 12(2), 217-228.
- Yang, Y., Sun, M. (2022), Semiconductor Defect Pattern Classification by Self-Proliferation-and-Attention Neural Network. *IEEE Transactions on Semiconductor Manufacturing*, 1(35),16-23, DOI: 10.1109/TSM.2021.3131597
- Yao, H., Yu, W., Wang, X. (2022), A Feature Memory Rearrangement Network for Visual Inspection of Textured Surface Defects Toward Edge Intelligent Manufacturing Meth. *Computer Vision Journal*, 3(7), 132-156. DOI: 10.48550/2206.10830
- Yu, H., Li, Q., Tan, Y., Gan, J., Wang, J., Geng, Y., Jia, L. (2019). A coarse-to-fine model for rail surface defect detection. *IEEE Transactions on Instrumentation and Measurement*, 3(68),656–666.

KİŞİSEL YAYIN VE ESERLER

- Baytürk, E.**, Agca A. E., Balamur, H., Kutlucan, L., Vural, U. (2021), Recyclable Material Detection in Video Streams using Neural Networks. *International Conference on Computing and Machine Intelligence*, 3(1), 134-143.
- Baytürk, E.**, Urhan, O., Çalışkan A., Özdemir, V., İnmez, C. A., (2022), Anomaly Detection of The Splice Adding Process with Unsupervised Learning. 9. *Uluslararası Marmara Fen Bilimleri Kongresi* 22(1), 273-280.
- Çalışkan, A., Özdemir, V., **Baytürk, E.**, Öztürk, M., Kefeli, D., Üzengi, A. (2022), Real Time Retail Analytics with Computer Vision, *Innovations in Intelligent Systems and Applications Conference*, 17(1), 1-4, DOI: 10.1109/ASYU56188.2022.9925538.
- Ozdemir, V., Çalışkan, A., Özgen, M., **Baytürk, E.**, Özen, S. (2021), The performance comparison of optical character recognition and object detection methods on rubber products. *International Journal of Current Innovations in Interdisciplinary Scientific Studies*, 5(1), 01-15.

ÖZGEÇMİŞ

Enes Baytürk lise eğitimini İzmit Atılım Anadolu Lisesi'nde tamamladı. 2019 yılında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünden mezun olmuştur. Daha sonra 2019 yılında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünde yüksek lisans eğitimine başlamıştır. Yüksek lisans derecesinde sinyal işleme, görüntü işleme ve makine öğrenmesi okudu. Halen BRISA BRIDGESTONE SABANCI Lastik İmalat A.Ş.'de akıllı ürün ve üretim çözümleri geliştirme mühendisi olarak çalışmaktadır.

