



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

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**CAM ÜRÜNLERDEKİ HATALARIN GÖRÜNTÜ İŞLEME VE
DERİN ÖĞRENME YÖNTEMLERİYLE KALİTE KONTROLÜ**

YÜKSEK LİSANS TEZİ

Ali Burak ULAŞ

DANIŞMAN

Dr. Öğretim Üyesi Filiz SARI

AKSARAY, 2022

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 182363405 numaralı Yüksek Lisans öğrencisi Ali Burak ULAŞ tarafından hazırlanan “**CAM ÜRÜNLERDEKİ HATALARIN GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİYLE KALİTE KONTROLÜ**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Elektrik Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğretim Üyesi Filiz SARI

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Prof. Dr. Murat Hüsnü SAZLI

Ankara Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Dr. Öğretim Üyesi Enes EKEN

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Tez Savunma Tarihi: 10/01/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr.

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinalliğini ve her türlü intihalden uzak olduğunu beyan ederim.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

İmza

Ali Burak ULAŞ

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, değerli bilgilerini benimle paylaşan, kendisine ne zaman danışsam bana kıymetli zamanını ayırıp sabırla ve büyük bir ilgiyle faydalı olabilmek için elinden gelenden fazlasını sunan her sorun yaşadığımda yanına çekinmeden gidebildiğim, güler yüzünü ve samimiyetini benden esirgemeyen ve gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden faydalanacağımı düşündüğüm kıymetli ve danışman hoca statüsünü hakkıyla yerine getiren Dr. Öğretim Üyesi Filiz SARI' ya teşekkürü bir borç biliyor ve şükranlarımı sunuyorum. Lisans ve yüksek lisans eğitimim boyunca yardım, bilgi ve tecrübeleri ile bana sürekli destek olan akademiye yönelmemde etkin rol oynayan, araştırmayı bana sevdiren ağabeyim Doç. Dr. Kemal ADEM' e teşekkür ederim. Yine çalışmalarım boyunca maddi manevi destekleriyle beni hiçbir zaman yalnız bırakmayan aileme, çalışmamda numune konusunda destek veren Malatya Baştürk Cam Fabrikasına ve Umut TÜRK' e teşekkür ederim.

Ali Burak ULAŞ
AKSARAY, 2022

İÇİNDEKİLER

TEŞEKKÜR	ii
İÇİNDEKİLER	iii
ÖZET.....	iii
ABSTRACT	iv
ŞEKİLLER DİZİNİ	v
ÇİZELGELER DİZİNİ	vi
SİMGELER VE KISALTMALAR	vii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	3
3. MATERYAL ve YÖNTEM.....	6
3.1 Kullanılan Veri	6
3.1.2 Kırışık hatası.....	9
3.2 Kullanılan Yöntemler	10
3.2.1 Sayısal görüntü işleme	10
3.2.1.1 Sayısal görüntü işlemenin adımları	10
3.2.1.2 Sayısal görüntü işlemede kullanılan bazı teknikler.....	11
3.2.2 Makine öğrenimi.....	13
3.2.2.1 Derin öğrenme-modeller	13
3.2.2.2 Faster R-CNN	14
3.2.2.3 Yolo.....	15
4. ARAŞTIRMA BULGULARI.....	25
4.1 Stüdyo Seçimi.....	26
4.2 Görüntü İşleme Algoritmalarının Kullanımı	32
4.2.1 HSV Renk uzayı uygulaması.....	32
4.2.2 CIE Lab LUV Renk uzayı uygulaması.....	33
4.2.3 Adaptif Histogram Eşitleme uygulaması.....	34
4.3 Faster R-CNN ve YoloV3 Derin Öğrenme Modellerinin Uygulanması	34
5. SONUÇ VE ÖNERİLER.....	41
KAYNAKLAR	43
ÖZGEÇMİŞ.....	46

YÜKSEK LİSANS TEZİ

CAM ÜRÜNLERDEKİ HATALARIN GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİYLE KALİTE KONTROLÜ

Ali Burak ULAŞ

Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğretim Üyesi Filiz SARI

ÖZET

Gıda sektöründe sıklıkla tercih edilen cam ürünlerin imalatında kalite kontrolü geleneksel olarak uzman işçiler tarafından göz ile kontrol edilerek yapılmaktadır. Bu süreç insana dayalı olarak ilerlediği için hata payı kaçınılmaz olmuştur. Üretimin ilk aşamasında yapılacak bir entegrasyonun diğer safhalarındaki kalite kontrol sürecini hafifletmiş ve hata payını indirmiş olacaktır. Bu çalışmada, çeşitli görüntü işleme teknikleri kullanılarak cam ürünlerin kalite kontrolünün bilgisayar destekli bir sistem aracılığı ile yapılması hedeflenmiştir. Piksel bazlı görüntü bölütleme, doğrusal regresyon, çok katmanlı sinir ağı, makine öğrenimi bir arada kullanılmıştır. Baştürk Cam firmasından tez çalışmasına özel deneysel olarak üretilip bize temin edilen cam ürünler üzerindeki hataların ayrıştırma ve test işlemleri gerçekleştirilmiştir. Önerilen yöntemlerin doğru sınıflandırma oranları tatminkâr düzeyde bulunmuş ve gelecek çalışmalar için önerilerde bulunulmuştur.

Anahtar Kelimeler: Cam yüzeyde kalite kontrolü, Görüntü işleme, Makine öğrenimi, Piksel bazlı görüntü bölütleme.

Şubat, 2022; 46 sayfa

M.Sc. THESIS

**QUALITY CONTROL OF FAULTS IN GLASS PRODUCTS BY IMAGE
PROCESSING AND DEEP LEARNING METHODS**

Ali Burak ULAŞ

**Aksaray University
Graduate School of Natural and Applied Sciences
Department of Electrical Electronics Engineering**

Supervisor: Assistant Prof. Dr. Filiz SARI

ABSTRACT

Quality control in the production of glass products, which are frequently preferred in the food sector, is traditionally carried out by expert workers by visual inspection. Since this process progresses based on people, the margin of error has been inevitable. An integration to be made in the first stage of production will ease the quality control process in other stages and reduce the margin of error. In this study, it is aimed to control the quality of glass products by using a computer-aided system using various image processing techniques. Pixel-based image segmentation, linear regression, multi-layer neural network, machine learning are used together. Separation and testing of defects on glass products supplied by Baştürk Cam company were carried out. The correct classification rates of the proposed methods were found to be satisfactory and suggestions were made for future studies.

Keywords: Quality control on glass surface, Image processing, Machine learning, Pixel based image segmentation.

February, 2022; 46 pages

ŞEKİLLER DİZİNİ

Şekil 3.1. Stüdyo ortamı	6
Şekil 3.2. Hatalı ürün araştırması.....	7
Şekil 3.3. Baloncuk hatası (Habbe)	8
Şekil 3.4. Yırtık hatası (Kırışık).....	9
Şekil 3.5. Görüntü işleme akış diyagramı.....	11
Şekil 3.6. Fast R-CNN ve RPN modellemesi	14
Şekil 3.7. Faster R-CNN	15
Şekil 3.8. Faster R-CNN – YoloV3 birim / saniye	16
Şekil 3.9. YoloV3 Mimarisi.....	17
Şekil 3.10. Yolo uygulaması çıktısı	18
Şekil 3.11. YoloV2 örnek görsel	20
Şekil 3.12. Güven skoru uygulama işlemi	21
Şekil 3.13. (a) Izgaralı görüntü, (b) Regresyonlu görüntü (c) Sonuçlandırılmış görüntü	21
Şekil 4.1. Sistem mimarisi	25
Şekil 4.2. Stüdyo seçimi	27
Şekil 4.3. Tepeden aydınlatmalı stüdyo ortamı	28
Şekil 4.4. Tepeden -60° aydınlatmalı stüdyo ortamı	28
Şekil 4.5. HSV ile işleme tabi tutulan cam görüntü.....	32
Şekil 4.6. CIE Lab Luv ile işleme tabi tutulan cam görüntü.....	33
Şekil 4.7. HSV-V ve CIE Luv-V kanalları üzerinde adaptif histogram eşitleme	34

ÇİZELGELER DİZİNİ

Çizelge 3.1. Hatalı ürün yüzdelik dağılımı	7
Çizelge 3.2. Kullanılacak Görüntü Özellikleri	9
Çizelge 4.1. Hatalı ürün yüzdelik dağılımı	26
Çizelge 4.2. Tepe Açısı/Gün Işığı Siyah Parlak Fon	29
Çizelge 4.3. Tepe Açısı/Gün Işığı Beyaz Parlak Fon	29
Çizelge 4.4. Tepe Açısı/Gün Işığı Siyah Mat Fon	30
Çizelge 4.5. Tepe Açısı/Beyaz Işık Beyaz Mat Fon	30
Çizelge 4.6. Tepe Açısı 30°/Gün Işığı Siyah Mat Fon	31
Çizelge 4.7. Tepe Açısı 30°/Beyaz Işık Beyaz Mat Fon	31
Çizelge 4.8. Faster R-CNN ve YoloV3 karışıklık matrisleri	35
Çizelge 4.9. HSV-V ve CIE-LAB LUV -V Faster R-CNN karışıklık Matrisi	35
Çizelge 4.10. Adaptif histogram eşitleme ile HSV-V, CIE LAB LUV-V kanalları için Faster R-CNN karışıklık matrisleri	36
Çizelge 4.11. HSV ve CIE-Lab Luv için V kanalları için YoloV3 sonuçları	37
Çizelge 4.12. Adaptif histogram eşitleme ile HSV-V, CIE LAB LUV-V kanalları için YoloV3 karışıklık matrisleri	37
Çizelge 4.13. Çalışmada önerilen Yolo modelinin başarı değerlendirilmesi	38
Çizelge 4.14. Görüntü işleme ve derin öğrenme algoritmaları uygulama sonuçları .	39
Çizelge 5.1. Görüntü işleme ve derin öğrenme modelleri genel doğruluk oranları...	42

SİMGELER VE KISALTMALAR

CNN	Convolution Neural Network
IS	Yüksek hızlı ayrılabilen parça
LED	Işık yayan diyot (Light Emitting Diode)
MP	Mega piksel
RPN	Region Propasal Network
PNG	Taşınabilir ağ grafiği (Portable Network Graphics) – Resim formatı
<i>f</i>	Fonksiyon
ms	Milisaniye
η	Verim
ρ	Yoğunluk
Δ	Fark
°C	Santigrat



1. GİRİŞ

Gıdalar insan yaşamı için çok önemli bir ihtiyaçtır. Bu ihtiyaçlar için birçok organik/inorganik yiyecek ve içecekler günümüzde temin edilebilir olarak market ve diğer ticari unvana sahip işletmelerin raflarında yer almaktadır. Gıdaların raf ömrünün uzun olması açısından üretimi ve son kullanıcı olan insanların erişimi için üretim sürecinden sonra bozulmaması adına paketlenme aşaması daha kritik öneme sahiptir. Ambalajlanmış gıdalarda, gıda ile temas eden malzemeler, plastikler ağırlıkta olmak üzere, kâğıt, cam ve metal gibi maddelerden oluşur. Ambalajın içindeki atmosferi kontrol ederek gıdanın raf ömrünü uzatabilen aktif ambalaj, gıdanın kalitesini takip edebilen ve bildiren akıllı ambalaj ve nanoteknoloji kullanılarak elde edilen nanoambalajlar da gıda ambalajları olarak bilinir (Doğan, 2009).

Gıdaların saklanması amacıyla üretilen cam ürünler migrasyon seviyesinin düşük olması sebebi ile kâğıt, plastik ve metal saklama kapları ile karşılaştırıldığında daha sağlıklıdır (Çinibulak, 2010). Ancak cam ürünlerin üretiminde daha dikkatli olunması gerekmektedir. Cam ürünlerde üretim esnasında oluşabilecek fazla cam kalıntıları, çizikler ve çatlaklar insan hayatını doğrudan etkileyeceği gibi gıdaların raf ömrünü kısaltabileceği de öngörülmektedir.

Cam şişeler ve kavanozlar; erimiş camın kalıba döküldüğü, küreye kalıbın şekle gelene kadar sıkıştırılmış hava uygulandığı ve sonrasında şişenin çıkarıldığı yüksek hızlı ayrılabilen parçalı (IS) makineler ile üretilir (URL-1). Şekillendirme iki adımda gerçekleştirilebilir, ilk adımda erimiş cam, parison adı verilen bir boş şekil içerisinde üflenir (veya delerek aktarılır), ikinci adımda ise parison son boyut ve şekli vermek üzere bir kalıba üflenir. Kalıplar, parisonu barındırmak için kapalı iki yarıya bölünür ve daha sonra havanın üflenmesini kolaylaştırmak için hızla tahliye edilir. Bu durum, kalıp hacminin bir vakum ağı ile kalıptaki çok küçük deliklerden (0,4 mm) ve döküm kalıbında işlenmiş yollardan sürekli olarak eşitlenmesiyle gerçekleşir. Makinalarda oluşan kalıp ayrılmama durumu, havanın tahliye edilememesi ve sıcaklık değişimlerinin dengesizliği sonucu üretilen üründe hata meydana gelmektedir.

Makinalarda sıcaklık ve soğutma için kullanılan su basınçları ayarlanarak oluşan

hatanın giderilmesi sağlanmaktadır. Hata tespiti için yapılan işlemlerin içerisinde insan faktörü olduğu için gözden kaçabilecek hatalı ürün, bir insan riski demektir.

Cam ürünlerdeki üretim hatalarını ortadan kaldırmak için üretim bandında mevcutta basınçlı ağız taban kontrolü yapılmakta olup, diğer hatalı ürünlerin kalite kontrol işlemi uzman kişiler tarafından belirli periyotlarda gözle kontrol edilerek sağlanmaktadır. Gözle yapılan fiziki kontrolde, cam ürünlerin kalite kontrolü risk oluşturabileceği için tek bir noktada değil, birçok noktada kontrol edilmektedir. Hatalı bulunan cam ürünler uzman kişiler tarafından anlık olarak incelendikten sonra sağlam ise üretim devamına, hatalı ise geri dönüşüme ayrıştırılmaktadır. Hataların belirli bir kotayı aşması halinde üretim durdurulmaktadır. Gözle ve fiziki olarak yapılan bu kalite kontrol işleminde bir süre sonra işçinin yorulması ve yaşanan dikkat kaybı son kullanıcının hayatını riske atabileceği gibi maddi zararlara da sebebiyet verecektir (Agrawal, 2011). Bu tez çalışmasında, insan faktörünün etkin olduğu gözle yapılan hata tespitinin doğurabileceği sonuçları minimize etmek amacıyla bilgisayarla görüntü işleme ve derin öğrenme metotlarından faydalanarak hata tespitinin bilgisayar ortamına taşınması ve kalite kontrolünün anlık olarak gerçekleştirilmesi hedeflenmiştir (Li ve Shu, 2018; Hui vd.,2002).

Çalışmanın ilk bölümü olan “Giriş” bölümünde, cam ambalaj ürünün önemi ve tez çalışmasından kısaca bahsedilmiştir. “Kaynak Özetleri” bölümünde tez konusu ile ilgili kaynak araştırması yapılmış daha önceden yapılmış bilimsel çalışmaların kullandığı yöntemler ve sonuçlar verilmiştir. “Materyal ve Yöntem” bölümünde çalışmada kullanılacak verinin elde edilme aşamaları, elde edilen verinin işlenmesinde kullanılan görüntü işleme teknikleri ve derin öğrenme modellemeleri yöntemler açıklanmıştır. “Bulgular ve Tartışma” bölümünde elde edilen veri kümesi üzerinde uygulanan yöntemlerin sınıflandırma sonuçları verilmiştir. “Sonuç” bölümünde ise elde edilen sonuçlar yorumlanmış, sonraki çalışmalar için önerilerde bulunulmuştur.

2. KAYNAK ÖZETLERİ

Yapılan literatür taramasında üretimde cam kontrolü ile ilgili uluslararası çalışmaların yapıldığı tespit edilmiştir. Yapılan araştırma sonucu, çalışmamızda önerilen bir sistemin benzerine rastlanmamıştır. Çalışmamızda önerilen yöntemde analiz edilecek ürünün şeffaf olmasından dolayı arka plan ve ışıklandırma üzerinden çıkarımlar yapılmıştır. İncelenen çalışmalarda ışıklandırma sisteminin öneminden hemen hemen tüm araştırmacılar bahsetmiş olsa da kimi çalışmada ışıklandırmanın kamera arkasında olması kimi çalışmada dik olması savunulmuştur. Fakat kamera arkasından ve kameraya dik olarak karşı taraftan yapılan aydınlatma sisteminde, toz ve kirler sofraya camı üretiminde en sık karşılaşılan hatalardan birisi olan habbe hatası ile karışmış ve hata tespitinde doğruluk oranını azalttığı tespit edilmiştir (Öztürk ve Akdemir, 2018). Toz ve kirli bölgelerin cam üzerindeki hatalı bölgelerle karışmasının önüne geçilmesi üretim hızı ve kalitesi için oldukça önemlidir. Toz ve kirli bölgenin hatalı olarak algılanması durumunda aslında hatasız olan cam ürünün geri dönüşüme gönderilmesiyle iş gücü ve maliyet açısından firmaya kayıp olarak yansımaktadır. Yapılan tez çalışmasında üretim safhasında yer alan cam ürünlerin kalite kontrolünün sağlıklı olarak yapılabilmesi için, gerekli şartların sağlanması ile mümkün kılınmıştır. Bu şartlar;

- Toz ve kirden arındırılmış ürün kontrolü,
- Kamera açıları,
- Yansıma engelleyici Softbox veya Tas Reflektör,
- Entegre arka plan

olarak belirlenmelidir. Bu şartlar sağlandıktan sonra kalite kontrolü esnasında yaşanacak yansımaların önüne geçilecek, kir ve tozu hata olarak algılamayacak, ağız ve yüzeyde yer alan dolmamış ağız, yırtık ağız, kırışık, çatlak, habbe gibi hataları tespit etmesi hedef kılınacaktır. Literatürde konu üzerine yapılan çalışmalarda,

Imbert (1989) tarafından yapılan çalışmada ışıklandırmanın önemini vurgulayarak cam yüzeyler üzerindeki araştırmalarında lazer destekli hata bulma çalışmaları yürütmüştür. Lazer destekli platformda kamera et kalınlığı üzerindeki hataları 6 sn, üst ve alt tabaka üzerindeki kırık-birleşim hatalarını 14 sn içerisinde tespit etmektedir.

Ma ve Zhang (2002) tarafından yapılan çalışmada uyarlanabilir gri düzeltme görüntü işleme yöntemlerinin kullanıldığı, 6 kameralı sistem ile cam şişe ağzında oluşabilecek kesik, kırık ve dolmamış bölge tespiti için %2 hata ile (%98 doğruluk) yapılabileceği tespit edilmiştir.

Fezani ve Rahmani (2006) tarafından düz camlar üzerinde dalgacık dönüşümü ile hata tespit çalışmalarını yürütmüşlerdir. Dalgacık analizi ile incelenen cam yüzeylerde arka plan gürültülerini bastırmayı başarmışlardır. Düz cam üzerindeki kabarcık, pençe ve küçük boyutlu kusurların tespiti gerçekleştirilmiştir.

Riza ve Anton (2007) tarafından sunulan çalışmada yapay sinir ağlarından faydalanılarak şişeler üzerinde dolum tesisinde kapak kısmında oluşan hatalar görüntü işleme algoritmaları uygulanarak ön işleme tabi tutulmuştur. Üretim bandında gerçek zamanlı çalıştırılması planlanan ürün incelenmiş ve şişeler üzerinde %95 gibi kapak yok/kapak hatalı- sağlam gibi başarılı bir sonuç elde edilmiştir.

Adamo vd. (2008) tarafından önerilen ve birden fazla kamera kullanılan sistemde düz cam formları lazerler ile taranmakta ve çiziklerin içi algoritmalarla tekrar edildiğinden dolayı hatalı kısımlar daha geniş görünmektedir. Bu çalışma ile mevcut kusurdan daha fazla kusur alanı algılanmaktadır.

Adamo vd. (2010) tarafından yapılan çalışmada hata tespitinin yapılabilmesi amacıyla görüntü işleme tekniklerinden faydalanılarak Canny kenar algoritması kullanılmıştır. Işıklandırmanın büyük önem arz ettiğinin savunan ve ispatlayan Adamo ve ark. iki kamera ile ışıklandırma sistemine göre diyafram açıklığını bastırmak için iris ayarı yapmasından kaçınılmış ve hata tespiti başarıyla gerçekleştirilmiştir.

Zhang vd. (2012) tarafından önerilen çalışmada cam yüzeyler üzerinde oluşan kabarcıkların görsel boyutunu koruyarak medyan filtre uygulayarak ön işleme yapılmış ve hatanın tam adresi belirlenmiştir.

Akdemir ve Öztürk (2015) tarafından dalgacık dönüşümü kullanılarak önerilen çalışmada cam yüzeylerin şeffaf ve yansımaya oranının çok olmasından dolayı görüntü aktarımındaki zorluklardan bahsedilerek ışıklandırmanın önemi üzerinde durulmuştur.

Xiaomian ve Yufeng (2018) tarafından yapılan çalışmada ışık kırılmağını göz önünde bulundurarak gri renk uzayı dönüşümü algoritması ile görüntüler üzerinde gürültülerden arındırılarak işlenmiş, tasarlanan makine üzerinde arızalı ürün ayrışımı öngörölmüştür.

Liang vd. (2019) tarafından yapılan çalışmada Resnet 101 evrişimsel sinir ağı kullanarak 1400 görüntü üzerinde sofa camı (şişe ve kavanoz vb.) üzerinde hata tespit çalışmaları ağız taban ve gövde hataları olmak üzere doğruluk oranı %98 e yakın sonuçlandırılmıştır.

Bükücü ve Gökrem (2020) tarafından yapılan çalışmada hata tespitinin yapılabilmesi amacıyla düz cam üzerindeki hatalar, morfolojik görüntü işleme, gauss ve makine öğrenmesi yöntemi olarak da destek vektör makinesi modelinden faydalanılarak 4 floresan lamba ve 1 kameralı tasarlanan konveyör bant prototipinde sistemde hata tespit başarımı %93 olarak gerçekleşmiştir.

Yapılan literatür çalışmalarından da anlaşılacağı üzere cam üzerinde yapılan çalışmalarda görüntü işleme ile farklı algoritmalar kullanarak, ışık sistemi ve kamera sayılarının da değışiklik gösterdiği gözlemlenmiştir (Kumar ve Kaur, 2013). Görüntü işleme ile yapılan çalışmalarda, Canny kenar bulma, dalgacık dönüşümü, medyan filtre, morfolojik görüntü işleme tekniklerinden faydalanılmıştır. Kullanılan yöntemler arasında lazer destekli platformlar, çok kameralı sistemler ve aydınlatma şekillerine göre tasarımlarda literatürde yerini almıştır. Liang vd. (2019) tarafından yapılan çalışmada ise görüntü işleme kullanılmadan derin öğrenme yapılmış, Resnet101 modellemesi kullanılmıştır.

Bu çalışmada ağız, gövde ve taban hataları Resnet101 algoritması ile eğitilerek hata tespitinde önemli yol kat edilmiştir. Bizim çalışmamızda ise üretimde en sık görölen ve hayati risk taşıyan Habbe ve Kırıřık hataları için; cam yüzeyin şeffaf, yansımalarının fazla olması sebebi ile derin öğrenme modeline gönderilmeden görüntü işleme algoritmaları ile ön işlem adımları uygulanmıştır. Ön işlem sonrası görüntüler evrişimsel sinir ağı mimarisinin hızlı çözümler sunan Faster R-CNN ve YoloV3 modeli ile eğitilecektir. Gerçekleştirilecek olan çalışma ile cam kontrol işlemi için karar destek sistemi geliştirilerek ülke sanayisini ve ekonomisini kalkındırmak hedeflenmektedir.

3. MATERİYAL ve YÖNTEM

Bu çalışmada cam üretim tesislerinde hata tespitinin bilgisayar destekli kalite kontrolünü sağlamak amacıyla görüntü işleme tabanlı derin öğrenme destekli bir yazılım geliştirilmiştir. Yazılım için gerekli kılınan cam ürün örnekleri bir kamera vasıtası ile yansımanın minimize edileceği stüdyo üzerinde elde edilmiştir. Alınan görüntüler ile çeşitli görüntü işleme teknikleri kullanılarak özellik çıkartımı yapılmıştır (Hongxi vd., 2012). Oluşturulan veriler üzerinde derin öğrenme modellerinden faydalandırılarak hatalı ve sağlam ürünler tanıtılmıştır. Bu özelliklerden faydalanarak sınıflandırma yapılmıştır. Yapılacak olan çalışmada ilk olarak veriler tanımlanacak, daha sonrasında ise özellik çıkartımı ve sınıflandırma aşamalarında kullanılan tekniklerden bahsedilecektir.

3.1 Kullanılan Veri

Yapılan bu tez çalışmasında kullanılan veriler Baştürk Cam firmasından deneysel amaçlı çalışmada kullanılması adına özel olarak üretilmiştir. Çalışmada kullanılan ham görüntü verisinin toplanması amacıyla 12 MP renkli görüntü alabilen bir fotoğraf makinesi kullanılmıştır. Kullanılan fotoğraf makinasının profesyonel niteliği taşıyabilmesi ve görüntü alınacak verilerde yansımanın minimize edilmesi amacıyla diyafram açıklıkları ve derinlik ayarlamaları yapılmıştır. Maksimum çözünürlükte çekilen fotoğrafların sayısal ortamdaki boyutları yatayda 710 ve dikeyde 1280 piksel olacak şekilde kameradan çıktısı alınmıştır. Çekimin yapıldığı stüdyoya ait görsel Şekil 3.1’de gösterilmektedir.



Şekil 3.1. Stüdyo ortamı.

Kullanılacak veriler üzerinde ayrıştırma işlemi yapılırken cam ürünlerin temin edildiği fabrikadan ilk etapta karşılaşılan hatalı ürünler temin edilmiştir. Temin edilen ürünler üzerinde fabrika proses mühendisi ile yapılan istişareler sonucu en sık karşılaşılan hataların istatistiği toplanmış ve alınan örnekler ile çalışmanın derinliği araştırılmıştır. Alınan veriler incelendiğinde üretimin bir parti serisinde alınan hata sayıları Çizelge 3.1’de belirtilmiştir.

Çizelge 3.1. Hatalı ürün yüzdelik dağılımı.

Sıra No	Hata Çeşidi	Hata Yüzde Endeksi	Hata Sayısı
1	Habbe	4,8	24
2	Kırışik	3,2	16
3	Ağız Taban Yamukluğu	0,4	2
5	Pürüzlü Yüzey	0,6	3
6	Basık Gövde	0,4	2
7	Dolmamış Ağız	0,8	4
8	Oval Gövde	0,2	1
Parti Üretim Ürün Sayısı			500

Fabrika ortamından alınan çeşitli hatalar üzerinde sınıflandırma yapılarak hatalı ürünlerin projelendirilebilirliği tartışılmıştır. Şekil 3.2’de sınıflandırmaya ait görsel paylaşılmıştır.




Şekil 3.2. Hatalı ürün araştırması.

Çıkan sonuca uygun olarak çalışmaya paralel incelenen örnek havuzundan en sık karşılaşılan baloncuk “Habbe” ve yırtık “Kırışık” olmak üzere iki hata grubu seçilmiştir.

Fabrika ortamından tez çalışması için alınan veri sayısının az olması ve eğitim işleminin istenilen seviyede yapılamaması sebebi ile veri artırımı tekniklerinden faydalanılmıştır. Evrişimsel sinir ağları ile yapılan derin öğrenmede, toplanması ve hazırlanması oldukça maliyetli olan çok sayıda etiketli veriye ihtiyaç duyulmaktadır. İhtiyaç duyulan veriyi elde etmek amacıyla MATLAB programlama dili ve data augmentation kütüphanesi kullanılarak veri artırma işlemi gerçekleştirilmiştir. Başlangıçta 360 adet görüntü bulunan veri setine veri artırma işlemleri uygulanarak görüntü sayısı 1180’e çıkarılmıştır. Veri artırma yöntemlerinden aynalama, beyazlatma, döndürme, ölçekleme yöntemleri kullanılmıştır.

3.1.1 Habbe hatası


Üretimde makine emülsiyonundaki cam hammaddesinin az veya kayıplı gelmesi sonucu oluşan hava kabarcıklarının (baloncukların) kalite kontroldeki tanımı Habbe olarak geçmektedir. Habbe boyutunun küçüklüğü ile risk durumu tartışılabilir ancak kalite bakımından büyük kusur sayılmaktadır (URL-2). Habbe çapının ve derinliğinin büyük olması durumunda camın çatlamasına neden olacağından ani ısı değişimlerinde cam ürünün bir anda patlamasına (infilak) neden olur (Şekil 3.3).



Şekil 3.3. Baloncuk hatası (Habbe).

3.1.2 Kırışık hatası

Üretimde kalıp üzerinden ayrılmaması sonucu dalgalanma ile oluşan yırtıkların kalite kontroldeki tanımı “Kırışık” olarak anılmaktadır. Ürünün diğer yüzeylerine göre kırışık olan bölgenin kırılma hassasiyetinin yüksek olması sebebi ile risk grubunda değerlendirilen bu hata türü insan sağlığı ve marka kalitesi için önem arz etmektedir. Şekil 3.4’te gösterilen örnekte kırışık hatası olarak nitelendirilen, kırışık dalgalıklarının boyutu ile kırılma hassasiyeti doğru orantılıdır.



Şekil 3.4. Yırtık hatası (Kırışık).

Buna uygun olarak tez çalışmasında habbe ve kırışık hataları üzerine çalışma yapılması karar kılınmıştır. Habbe ve kırışık teşhis ve sınıflandırması için kullanılan görüntü sayı ve özellikleri Çizelge 3.2’de verilmiştir.

Çizelge 3.2. Kullanılacak görüntü özellikleri.

Hata Türü	Gerçek Görüntü Sayısı	Çoğaltılmış Görüntü Sayısı	Çözünürlük	Görüntü Formatı
Habbe	132	450	710 x 1280	.png
Kırışık	108	401	710 x 1280	.png
Sağlam	90	330	710 x 1280	.png

Çizelge 3.2’de görüldüğü gibi hata türleri ile ilgili bilgiler verilmiştir. Derin öğrenme modellerinin eğitimi için mevcut görüntü verisinin %70’i, test aşamasında ise %30’u kullanılmıştır.

3.2 Kullanılan Yöntemler


3.2.1 Sayısal görüntü işleme

Işık yardımıyla fiziki olarak oluşturulan bir veri kümesinin iki değişkenli olarak aktarılmasına görüntü denir. Bu görüntü fonksiyonu $f(x, y)$ ifade edilirse, f değeri görüntünün oluşmasında büyük pay sahibi ışığa bağlı olarak parlaklık ve karşıtlık iken, fonksiyona giren x ve y değerleri ise görüntünün koordinatları ve içerdiği özel bilgilerdir (Cömert vd., 2017; Gonzalez ve Woods, 2002).

Dijital görüntüyü oluşturan piksel, görselin sayısal ortamda var olan satır ve sütun kesimlerine verilen addır. Bir resmin çözünürlüğü ise resmin matrisinde hesaba katılan satır ve sütunlardan oluşmaktadır. Örnek olarak görsel içerisinde 1936 sütun ve 5184 satırdan oluşan veri kümesinin her satır ve sütun kesimleri piksel, görselin tüm satır ve sütun çarpımı bizlere çözünürlüğü verecektir (URL-3). Bu görüntünün çözünürlük değeri ise 10 Mega pikseldir. Piksel; kırmızı, yeşil ve mavi (Red-Green-Blue) renklerinden oluşmaktadır. Piksel yoğunluğu ile görüntü kalitesi yani çözünürlük doğru orantılıdır (Cömert vd., 2017; Gonzalez ve Woods, 2002).

3.2.1.1 Sayısal görüntü işlemenin adımları

Fotoğraf makinası desteği ile bir nesne görüntüsünün analog ortamdan sayısal ortama aktarılmasının ardından bu nesne üzerinde yapılacak olan analizlere görüntü işleme denir (Gonzalez ve Woods, 2002). Sayısal görüntü işleme sisteminin işlem basamakları Şekil 3.5’de grafiksel olarak gösterilmektedir.



Şekil 3.5. Görüntü işleme akış diyagramı.

Şekil 3.5’de görüldüğü üzere kamera vasıtasıyla gerçek ortamda bulunan nesne üzerindeki ışığın toplanması ve diyaframlar aracılığı ile ayarlanması ile gerçek ortamdaki nesne görüntüsü dijital olarak kaydedilmektedir. Kaydedilen görüntü üzerinde çeşitli görüntü işleme metotlarının kullanılmasıyla, nesne üzerindeki ilgili bölgelerin daha belirgin hale getirilmesi sağlanmıştır.

3.2.1.2 Sayısal görüntü işlemede kullanılan bazı teknikler

Önişleme:

Şekil 3.5’de görüldüğü gibi kamera, fotoğraf makinası veya mercek kullanılarak gerçek dünyadan alınan görüntü ile sayısal görüntü işleme adına ilk adım atılmaktadır. Alınan görüntünün sayısal ortama aktarılmasıyla algılanan resim dönüştürücü birim tarafından sayısal bilgileri ile birlikte hazır hale getirilir. Sayısal ortamdaki görüntü verisinin çözümlenmesinin ardından ön işlemeye tabi tutulur. Burada ön işlemin amacı daha verimli sonuçlar elde etmek adına uygulanır. Ön işleme ile görüntü üzerinde kontrast ayarlaması, gürültülerin azaltılması ve resim üzerindeki bölgelerin tanımı ve birbirinden ayrılması için gerekli işlemler yapılmaktadır.

Bölütleme:

Görsel içerisinde yer alan nesne arka plan veya görsel içerisindeki aranılan bilginin ayrıştırılması ve sade özelliğinin çıkarımı için bölütleme işlemine ihtiyaç duyulmaktadır. Bu işlem ile anlamlı ve anlamsız birimler ayrıştırılarak işlem yapılacak bölümün özgürlüğünü sağlamaktadır. Bölütleme işlemi yapılırken görselin boyut, renk, yumuşaklık-keskinlik ve parlaklık değişkenlerini işleme alınarak oluşturulacak fonksiyon ile pikselden parçaya, parçadan ise bütüne doğru bir zincir yapısı kullanarak bölütleme gerçekleştirilebilir (Rego, 2003). Bölütleme yöntemi görüntü işlemenin merkez noktası olarak anılabilir. Görüntü üzerinde sabit olmamakla birlikte birçok metot kullanılması mümkündür. Sıklıkla kullanılan yöntemlerin başında kümeleme yöntemi, böl/birleştir yöntemi ve histogram tabanlı yöntemler bulunmaktadır. Siyah-beyaz görüntü üretimi için yapılan bölütleme işlemlerinde gri renk ağırlıklı görüntüler üzerinde piksel değerleri üzerinden işlem yapılmaktadır. Gri piksel yoğunluğundan yola çıkarak benzerlik ve süreksizliğinden faydalanan bölgelere ayırma işlemi rahatlıkla yapılabilmektedir (Hongxi vd., 2012).

Eşikleme:

Görüntü üzerindeki nesneyi arka plandan ayırmak için kullanılan en basit tekniklerden biridir. Eşikleme işlemi, bölütleme işleminde yapılan tekniklerin bir ya da birkaçına benzerlik göstermektedir. Görüntü içerisinde oluşturulan veri kümeleri ile elde edilen yeni görüntüde belirlenen eşik değerine bağlı olarak veri kaybı kaçınılmazdır (URL-4). Eşikleme yöntemi olarak genel ve yerel eşikleme gibi iki farklı eşikleme tekniği bulunmaktadır. Kullanım kolaylığı ve hızlı sonuçlar vermesi sebebiyle tercih edilen genel eşiklemede, görüntü üzerindeki nesneyi arka plandan ayırmak için sabit bir eşik değeri seçilmektedir. Düz olmayan şekiller için yerel eşikleme yönteminin kullanılması gerekmektedir.

Eşikleme yöntemi, görüntülerin farklı özelliklerini birlikte kullanan diğer yöntemlere göre daha hızlı sonuç vermektedir. Bunlardan birisi manüel eşikleme, görüntü içerisindeki istenilen nesneleri ön plana taşımak için en çok kullanılan yöntemlerden birisidir. Manüel eşiklemede, görüntü gri seviye formatına dönüştürülerek histogramı çıkarılır. Histogramı incelenerek bir eşik değeri belirlenir. Diğer yöntemlerden birisi olan otsu yöntemi ile eşikleme, gri seviye görüntüler üzerinde uygulanabilen bir eşik

belirleme yöntemidir. Bu yöntem ile her bir gri seviye tonunun görüntü üzerindeki bulunma sayılarına bakılmaktadır. Otsu yöntemi ile yapılan eşiklemede, ilk olarak görüntünün histogramı çıkarılır. Çıkarılan histograma bakılarak belirlenen bir k eşiğiyle görüntü iki sınıfa ayrılır. Oluşturulan sınıfların içerisindeki toplam piksel olasılık yoğunlukları hesaplanmaktadır.

3.2.2 Makine öğrenimi

Makine öğrenimi, tükettikleri verilere göre öğrenen ya da performansı iyileştiren sistemler oluşturmaya odaklanan bir yapay zekâ alt kümesidir.

3.2.2.1 Derin öğrenme-modeller

Makine öğreniminin alt kümesi olan derin öğrenme, soyut verileri modellemek amacıyla, yapay sinir ağları ve insan beyninden ilham alan veri kümesindeki bilgi yığını işlemek için kullanılan algoritmalara denir. İnsanların tecrübelenmesine benzer olarak derin öğrenme algoritmaları da sonucu iyileştirmek adına tecrübe kazanır. Derin öğrenme, düşünce gerektiren her türlü problem için sonuç elde edebilir. Derin öğrenme modellerinin yapay sinir ağlarına göre daha yoğun işlemler yaptığı düşünüldüğünde veriyi eğitecek ve yorumlayacak çiplerin güçlü olması gerekmektedir. Bu alanda en önemli desteğin grafiksel işlem birimleri (GPU) imkanlarıyla sağlandığı gözlemlenmiştir.


Derin öğrenme uygulama metotlarında denetimli ve denetimsiz olarak adlandırılan yapı taşlarından faydalanılır. Denetimli öğrenme, girdilere ve muhtemel çıktılara sahip etiketli veri setlerinden oluşmaktadır. Denetimli öğrenme ile eğitim yapılırken girdiler üzerinde etiketleme yapılarak, beklenen sonuç değerleri tanıtılır. Üretilen çıktının başarı oranının yüksek olması için eğitime alınan verilerin sayısı başarıyı doğrudan etkileyen faktördür. Denetimsiz öğrenmede ise girdi ve çıktılara müdahale edilmeden belirli bir yapıya sahip olmayan veri kümeleri kullanılarak yapılan işlemlerdir. Denetimsiz öğrenmeyi kullanarak yapılan çalışmalarda eğitim boyunca yapay zekaya, verilerin mantıksal sınıflandırmasını yapmasına olanak tanınmaktadır.

Çalışmamızda, derin öğrenmenin denetimli öğrenme modelinden faydalanılarak veriler yapay zekaya tanıtılmaktadır. Bu işlem için eğitim veri kümesindeki görüntülerin etiketlenmesi gerekmektedir. Etiketleme işlemi için MATLAB platformunda Image Labeler uygulaması kullanılmıştır. Etiketleme işlemi sonrasında

hatalı bölgelerin eğitimi için Faster R-CNN ve Yolo derin öğrenme modelleri kullanılmıştır.

3.2.2.2 Faster R-CNN


Faster R-CNN, Region Proposal Network (RPN) bir başka deyişle bölge önerisi ağı, (Ren vd. 2015) ile Fast R-CNN (Girshick, 2015) modellerinin birleşmiş hali olarak anılmaktadır. Region Proposal Network (RPN) ise, ilk aşama olan bölge önermeye yarayan derin, evrişimli bir sinir ağıdır. Burada RPN, herhangi bir boyutta girdiyi alır ve obje skoruna göre bir dizi nesnelere ait olabilecek kare önerimler ortaya çıkarır. Öznitelik haritası üzerinde bu öneri oluşturulurken evrişimli katman tarafından oluşturulan küçük bir ağı kaydırarak yapar (Şekil 3.6).



Şekil 3.6. Fast R-CNN ve RPN modellemesi.

RPN tarafından üretilen bu hesaplamalar Fast R-CNN mimarisine sokulur ve bir sınıflandırıcı yardımıyla objenin sınıfı, regressor ile de sınırlayıcı kutuları tahmin edilir.

Faster R-CNN modelinde ise giriş resmi evrişimsel sinir ağlarından geçirilerek özellik haritası çıkarılır. Daha sonra RPN oluşturulur. Bölge önerileri bu ağ üzerinde yapılır. Ağ bölgeleri belirlendikten sonra belirlenen bölgeler yeniden şekillendirildikten sonra tam bağlı katmanlarından geçirilir ve sınıflandırma yapılır (Şekil 3.7).



Şekil 3.7. Faster R-CNN.

3.2.2.3 Yolo

İnsan görme sistemi, görüntüler üzerinde hangi nesnelerin olduğunu ve buna bağlı olarak renk, konum ve birbirleriyle olan ilişkilerini anlık olarak hızlı bir şekilde tespit etmektedir. Doğruluk oranı yüksek ve hızlı nesne tespiti yapan algoritmalar, bilgisayarların insan gücü olmadan kullanımına, cihazların gerçek zamanlı verileri kullanıcılara sunmalarına imkân tanımaktadır (Redmon vd., 2016).


Geleneksel nesne tespit algoritmalarında tespit edilen nesneyi sınıflandırmak için ayrıca bir sınıflandırma işlemi yapılmaktadır. Algoritmalar görüntü üzerinde nesnelerin bulunabileceği muhtemel olan bölgeleri belirlemektedir. Burada belirlenen bölgeler için evrimsel sinir ağı bölgeler üzerinde özel olarak çalışarak görüntü üzerinde ilgili nesne tespit edilmektedir.

Algoritmanın iyi sonuçlar vermesine karşın görüntü üzerinde iki ayrı yüksek işlem gücü gerçekleştiği için ortaya çıkan varyasyondan dolayı işlem gücü artmaktadır. Mevcuttaki sistemlerin yetersizliği ve mutlak performansa ulaşamayacağı için gerçek zamanlı çalışan sistemlerde kullanmak yetersiz kalmaktadır. Gerçek zamanlı sistemlere alternatif olarak tasarlanan en yeni yaklaşımlardan biri olan R-CNN algoritmasında görüntü üzerinde bulunabilecek sınırlayıcı alanlar oluşturmakta, ardından önerilen alanlar üzerinde bir sınıflandırıcı ile bölge bazlı çalışan metotlar kullanılmaktadır (Ren vd., 2015). Sınıflandırma yapılırken çalışan algoritma,

sınırlandırılan alanların güven değerini yükseltmek ve aynı alanların birden fazla algılanmasını önlemek adına alanları dinamik tutarak sürekli kontrol altında tutar. Bu işlemlerin karmaşık olması başarımın yüksek tutulması adına oldukça yavaştır (Girshick vd., 2014).

YOLO, geleneksel nesne tespit yöntemlerinden ayıran en önemli özelliği gerçek zamanlı nesne tespiti yapabiliyor olmasıdır (URL-5).


R-CNN gibi algoritmalar önce nesne bulunması muhtemel bölgeleri tarayıp belirleyerek ayrı ayrı CNN (Convolutional Neural Network, Evrimsel Sinir Ağları) sınıflandırıcıları işleme alarak yapmaktadırlar. Bu yöntem ile başarılı sonuçlar alınsa da bir resim üzerinde iki ayrı işlem gerçekleştiği için resim üzerindeki işlem sayısı artarak düşük bir FPS (Frames per second, saniye başına kare) alınmasına sebebiyet vermektedir (Şekil 3.8).



Şekil 3.8. Faster R-CNN – YoloV3 birim / saniye.

YOLO ise sınırlayıcı kutuların tespiti, sınıf olasılıklarının çıkarımı ve diğer işlemleri tek bir regresyon problemi olarak ele alarak nesne tespit işlemi yaptığı için diğer CNN modellerinde görülen FPS kayıpları gözlemlenmemektedir. YOLO algoritmasının diğer nesne tespit algoritmalarına göre hızlı olmasının ana sebebi görseli tek bir seferde nöral ağdan geçirerek görsel üzerindeki tüm nesnelerin sınıfını ve koordinatlarının çıkarımını yapabiliyor olmasıdır. Bu işlemi yaparken özellik


piramidi ağı (FPN) yöntemi kullanılması en önemli unsurlardan biridir. FPN yönteminde özellik çıkarımı yapılırken Faster R-CNN özellik çıkarıcılarının yerini alarak veri üzerinde büyükten küçüğe kutular oluşturularak oluşturulan kutular içerisinde tarama yapılır. YOLO ile görüntü üzerinde hangi nesnelerin nerede olduklarını tespit etmek için görüntüye yalnızca bir kez bakılması yeterlidir. Şekil 3.9'da verilen mimaride özellik çıkarımı yapılan verinin Yolo bölgesinde FPN uygulanması ile 52x52, 26x26, 13x13 kutular oluşturularak yapılan öğrenim ile FPN yi piramite benzetecek olursak alttan üste şeklinde olur.



Şekil 3.9. YoloV3 Mimarisi.

Tek bir evrişimsel ağ ile aynı anda birden fazla sınırlayıcı kutu tahmin edilmekte ve her bir sınıf için sınıf olasılıkları tahmin edilmektedir. Bu birleşik model, geleneksel nesne tespit etme yöntemlerine göre çeşitli faydalara sahiptir.

Bu tahmin işleminde ilk önce girdi resmini $S \times S$ 'lik ızgaralara bölerek, her bir ızgara kendi içinde, nesnenin olup olmadığını, varsa orta noktasındaki veri ve buna bağlı olarak yükseklik, uzunluk ve sınıf bilgisini bulmakla sorumludur. $S \times S$ olarak belirtilen ızgara modeli işleme girecek görsel üzerinde enine ve boyuna eşit olarak 5x5, 7x7, 21x21 vs. kullanılmaktadır. Her bir ızgara kendi içerisinde, nesnenin orta noktasında olup olmadığını, orta noktasındaysa uzunluğunu, yüksekliğini ve hangi sınıftan olduğunu bulmakla sorumludur. Şekil 3.10'da bu durum gösterilmektedir.



Şekil 3.10. Yolo uygulaması çıktısı.

Şekil 3.10'de arabanın orta noktası 10. ızgaraya denk geldiği için arabanın tespit edilmesinden, bölge ayırımına yani; etrafına kutucuk çizmesinden o ızgara sorumludur. Burada oluşturulan alan ızgaraları için Yolo, her bir ızgara için ayrı ayrı tahmin vektörü oluşturmaktadır. Çalışan algoritma ile her bir ızgara için aşağıdaki faktörler önem arz etmektedir.

Güven Skoru: Geçerli ızgara içerisinde nesne bulunup bulunmadığının tespiti ve eğer nesne var ise bu nesnenin aranan nesne olup olmadığı çıkarımına bu aşamada karar verilir. Algoritma çıktısı 0 ise kesinlikle yok, 1 ise kesinlikle var anlamı taşımaktadır. Eğer nesne olduğu çıkarımı yapılırsa, nesnenin gerçekten aranan nesne olup olmadığından ve etrafındaki ızgaranın koordinatlarından ne kadar emin olduğunu ise güven skoru belirlemektedir. Güven skoru Eşitlik 1'deki gibi hesaplanmaktadır.

$$\text{Güven skoru} = P(\text{nesne}) \times IoU, P(\text{nesne}) \in (0,1) \quad (1.1)$$

Bölünen ızgaralar içerisinde herhangi bir nesne yoksa o ızgaraların güven skoru 0, var ise 1 olmaktadır. Her bir ızgara aynı zamanda sınıf koşullu olasılıklarını (Bağlı sınıf olasılığı) $P(\frac{\text{Bağlı sınıf Olasılığı}}{\text{Nesne}})$ tahmin etmektedir. İşleme alınan bu olasılıklar, nesne içeren ızgaralar ile bağlantılıdır. Üretilen sınırlayıcı kutu sayısına bakılmaksızın Yolo algoritması için her bir ızgara başına sınıf olasılıklarından

yalnızca biri tahmin edilebilmektedir. Sınıf bazında güven skorları Eşitlik 2’deki gibi bireysel güven skoru tahminleri ve koşullu sınıf olasılıkları çarpılarak hesaplanır.

$$P\left(\frac{\text{Bağlı sınıf Olasılığı}}{\text{Nesne}} i_n\right) \times P(\text{nesne}) \times IoU = P(\text{Bağlı Sınıf Olasılığı } i_n) \times IoU \quad (1.2)$$

YoloV2 algoritması bir ızgarada birden fazla nesne olması durumunda, yani bir ızgara içerisinde iki farklı nesnenin orta noktasının bulunması halinde algoritmaya monte edilen Anchor Box’lar ile mümkün kılınmıştır. Algoritma içerisinde aynı ızgara içerisine gelen nesneler anchor box sayısı kadar tahmin yürüterek algoritmadan başarılı sonuçlar elde edilecektir. Anchor box’ların algoritmaya dahil olması ile birlikte hesaplamada etkin denklem Eşitlik 3’deki gibidir.

$$S, S, ((Bx5) + C) \quad (1.3)$$

Eşitlik 3’de, S ızgara sayısını, B sınır kutusunu ve C ise her hücre için geçerli koşullu sınıf olasılığını tespit etmektedir.

Anchor box sayısı kadar güven, Bx , By , Bw , Bh ve diğer sınıflar için olasılık hesaplanması gerekmektedir.

Bx : İlgili nesne orta noktasının x koordinatı

By : İlgili nesne orta noktasının y koordinatı

Bw : İlgili nesnenin genişliği

Bh : İlgili nesnenin yüksekliği,

$Bağlı Sınıf Olasılığı$: Model üzerinde kaç farklı sınıf için oluşan yaklaşım sayısıdır.


$P(\text{nesne})$: Kutunun nesneyi kapsayıp kapsamadığının, bir başka deyişle “nesne var mı yok mu?” Sorusunun cevabıdır.

IoU : Ground truth ile tahmin edilmiş kutu arasındaki IoU değerini belirleyen faktördür.

$Kutu Güven Skoru$: $P(\text{nesne}) \cdot IoU$

$Güven skoru$: $Kutu Güven Skoru \times Bağlı Sınıf Olasılığı$

Görsel üzerinde iki adet nesnenin tespit edilmesi halinde anchor box ve sınırlar Şekil 3.11’de verilmiştir.



Şekil 3.11. YoloV2 örnek görsel.


Şekil 3.11’de görüldüğü üzere iki tane anchor box ve orta noktası aynı ızgaraya denk gelmiş iki tane nesne tespit edilmiştir. Sarı ile taranmış ızgara içerisinde insan şekli birinci anchor box, sepetteki çiçekler ise ikinci anchor box ile sınırlandırılmıştır.

Algoritmanın tahmini $S, S, ((B \times 5) + C)$ eşitliğinden yola çıkarak Şekil 3.11 üzerinde uygulanacak olursa;

B : $S \times S$ iki sınır bölgesi olduğundan dolayı B sınır kutusu 2 olarak anılacaktır.

C : Her hücre 20 koşullu sınıf olasılığına sahiptir.

$S, S, ((B \times 5) + C) = 7, 7, (10 + 20) = 7, 7, 30$ şeklindedir.



Şekil 3.12. Güven skoru uygulama işlemi.

Şekil 3.12’de algoritma, bir (7, 7, 30) tensörü tahmin etmek üzere CNN ağı oluşturmaktadır. Kullanılan CNN ağı üzerinde uzamsal boyutu her konumda 1024 çıkış kanalıyla 7×7 ’ye düşürülerek, $7 \times 7 \times 2$ sınır kutusu tahminleri yapmak için iki tam bağlı katman ile doğrusal bir regresyon gerçekleştirir (Şekil 3.13.a ve Şekil 3.13.b). Son bir tahminde bulunmak ve bu tahmini güçlendirmek için kutu güven puanı yüksek olanlar (özel koşullu doğruluk) çıktı olarak kabul edilmektedir. Tarif edilen uygulama ile görsel üzerindeki sonuçlandırılmış olan görüntü belirlenmektedir (Şekil 3.13.c).



Şekil 3.13. (a) Izgaralı görüntü, (b) Regresyonlu görüntü (c) Sonuçlandırılmış görüntü.

Kayıp işlevi

YOLO algoritmasının, ızgara başına birden çok sınırlayıcı kutu öngördüğü durumlar olmaktadır. Burada kaybın hesaplanabilmesi için, en yüksek IoU değeri seçilerek, sınırlayıcı kutu tahminleri arasında uzmanlaşmaya yol açar. Yapılan her tahmin ile belirli boyutları ve en boy oranlarını tahmin etmede daha iyi hale gelmektedir. YOLO, oluşan kayıpları hesaplamak için yapılacak olan tahminler ile tespit eder. Kayıp işlevi şunlardan oluşur:

- Sınıflandırma Kaybı
- Yerleştirme Kaybı
- Güven Kaybı

Sınıflandırma Kaybı: Izgara içerisinde bir nesnenin tespit edilmesi halinde, her bir hücredeki sınıflandırma kaybı, her bir sınıf için sınıf koşullu olasılıklarının karesi ile eşdeğer olarak Eşitlik 4'teki gibi hesaplanmaktadır.

$$\sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in classes} (p_i(c) - p'_i(c))^2 \quad (1.4)$$

*Burada c koşulu sınıf olasılık değerini temsil etmektedir.

*Izgara içerisinde bir nesne var ise $\sum_{i=0}^{S^2} 1_i^{obj}$ eşitliği “1”; yoksa “0” olarak kabul edilir.

Yerleştirme Kaybı: Tahmin edilen sınır kutusu konumları ve boyutlarındaki hataları ölçmektedir.

$$\lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - \bar{x}_i)^2 + (y_i - \bar{y}_i)^2] \quad (1.5)$$

$$+ \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(\sqrt{w_i} - \sqrt{w'_i})^2 + (\sqrt{h_i} - \sqrt{h'_i})^2]$$

Eşitlik 5'de ızgara içerisinde bir nesne var ise 1_{ij}^{obj} eşitliği “1”; yoksa “0” olarak kabul edilir.

λ_{coord} Sınır kutusu koordinatlarındaki kaybın ağırlığını artırır.

Büyük kutulardaki ve küçük kutulardaki mutlak hatalar eşit olarak ağırlıklandırılmaz. Büyük bir kutudaki 2 piksellik bir hata, küçük bir kutu için aynıdır. Bunu kısmen ele almak için YOLO, genişlik ve yükseklik yerine sınırlayıcı kutu genişliğinin ve yüksekliğinin karekökünü tahmin eder. Ek olarak, sınır kutusu doğruluğuna daha fazla vurgu yapmak için kayıp λ koordinatıyla çarpılmaktadır.

Güven Kaybı: Kutuda bir nesne tespit edilirse, güven kaybı Eşitlik 6'daki gibi gösterilmektedir.

$$\sum_{i=0}^{s^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 \quad (1.6)$$

Eşitlik 6'da görüldüğü gibi, $\hat{C}_i$, i hücresindeki alan kutusunun güven puanıdır.

$1_{ij}^{obj} = 1$ değeri i hücresindeki j sınır kutusu üzerindeki nesneyi algılamadan sorumludur. Burada veri yoksa 0 olarak belirlenir.

Kutuda bir nesne tespit edilmezse, güven kaybı Eşitlik 7'deki gibi hesaplanır.

$$\lambda_{noobj} \sum_{i=0}^{s^2} \sum_{j=0}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2 \quad (1.7)$$

Eşitlik 7'de 1_{ij}^{noobj} Değeri, 1_{ij}^{obj} 'nin tamamlayıcısı, $\hat{C}_i$ i hücresindeki j kutusunun güven puanı λ_{noobj} ise arka plan tespitindeki kaybı azaltır.

Kutuların çoğu herhangi bir nesne içermez. Bu bir sınıf dengesizliği sorununa neden olur, yani modeli nesneleri tespit etmekten daha sık arka planı tespit etmesi için eğitiyoruz. Bunu düzeltmek için, bu kaybı bir λ noobj faktörü (varsayılan: 0,5) ile ağırlıklandırıyoruz.

Zarar

Nihai kayıp, yerleştirme, güven ve sınıflandırma kayıplarını bir araya getirir.


$$\begin{aligned} & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - \tilde{x}_i)^2 + (y_i - y'_i)^2] \\ & + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(\sqrt{w_i} - \sqrt{w'_i})^2 + (\sqrt{h_i} - \sqrt{h'_i})^2] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ & + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2 \\ & + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in \text{clases}} (p_i(c) - p'_i(c))^2 \end{aligned} \tag{1.8}$$

4. ARAŞTIRMA BULGULARI

Bu bölümde önerilen derin öğrenme metodunu içeren yazılımın çalışması ayrıntılı bir şekilde incelenmiştir. Bunun için, daha önceki bölümde anlatılan ve toplanan sayısal görüntülerden oluşan iki ayrı veri kümesi kullanılmıştır. Birincisi, üretimde hata çeşidinin en fazla görüldüğü habbe görüntüleri ve ikincisi ise risk grubunda yer alan kırışık hata görüntüleridir. Bu veri kümelerindeki görüntülerin işlenmesi amacıyla Matlab yazılım platformu üzerinde önceki bölümlerde bahsedilen geleneksel görüntü işleme teknikleri kullanılarak bir yazılım geliştirilmiştir. En verimli sonucu elde etmek amacıyla ışık açısı, ışık tipi ve arka plana bağlı olarak deneyler yapılmıştır.

Arka-plan ve ışıklandırmanın belirlenmesinin ardından derin öğrenme modellerine gönderilen veriler üzerinde yansımayı minimize etmek ve hata tespit doğruluk oranını güçlendirmek amacı ile görüntü işleme metotlarından faydalanılmıştır. Görüntü işleme tekniklerinden renk uzayı dönüşümü olan HSV ve CIE-Lab Luv fonksiyonları ve adaptif histogram eşitleme tekniği uygulanarak ayrı ayrı derin öğrenme modellerinde (Faster R-CNN ve YoloV3) eğitime tabi tutulmuştur.

Tahmin sonuçları grafikler ve çizelgeler halinde sunulmuş ve yorumlanmıştır. Geliştirilen bu derin öğrenme yazılımına ait sistem mimarisi Şekil 4.1’de gösterilmiştir.



Şekil 4.1. Sistem mimarisi.

Yapılan çalışma, Şekil 4.1’ de görüldüğü gibi temel olarak 3 adımdan oluşmaktadır. Birinci adımda veri setinin hazırlanması ve stüdyo seçimi ile ilgili alt işlemler, ikinci adımda yansıma ve parlamaların minimize edilmesi için görüntü işleme algoritmalarının kullanımı, üçüncü adımda ise derin öğrenme için kullanılacak evrimsel sinir ağının oluşturulması ve sistemin eğitilmesi ile hatalı bölgelerin tespiti gerçekleştirilmiştir.

İlk olarak çalışma için veri tiplerinin belirlenmesi amacıyla fabrikadan alınan veriler karşılaştırılmış, risk taşıyan iki grup üzerinde durulmuştur. Çizelge 4.1 üzerinde fabrika ortamından alınan hatalı ürünlere ait yüzdelik oranlar verilmiştir.

Çizelge 4.1. Hatalı ürün yüzdelik dağılımı.

Sıra No	Hata Çeşidi	Hata Yüzde Endeksi	Hata Sayısı
1	Habbe	4,8	24
2	Kırışik	3,2	16
3	Ağız Taban Yamukluğu	0,4	2
5	Pürüzlü Yüzey	0,6	3
6	Basık Gövde	0,4	2
7	Dolmamış Ağız	0,8	4
8	Oval Gövde	0,2	1
Parti Üretim Ürün Sayısı			500

Çizelge 4.1’den de anlaşılacağı üzere, bir parti üretim sonucu hesaplanan hatalı ürün sayılarından kritik öneme sahip habbe ve kırışık hataları ön plana taşınmıştır.

4.1 Stüdyo Seçimi

Belirlenen veri tipi üzerinde çalışmaların başlatılması için görüntülerin bilgisayar ortamına aktarımı gerekmektedir. Profesyonel olmayan görüntüleme metotları ile kaydedilen görseller bilgisayar ortamında incelendiğinde, hata ile birlikte yansıma, leke ve tozların da kayıt altına alındığı gözlemlenmiştir.

Sağlıksız Arka Plan

Tez için öngörülen Arka plan

Görsel-1
(Kırışik)



Görsel-2
(Habbe)



Görsel-3
(Habbe ve
Kırışik)




Şekil 4.2. Stüdyo seçimi.

Şekil 4.2’de görüldüğü üzere arka planı siyah ve gün ışığı aydınlatma altında çekilen görüntüler üzerinde, ilgili hataların yanı sıra stüdyo çevresindeki yansımalar, leke ve tozlar da olmak üzere sağlıksız veri elde edilmiştir. Verilerin ayrıştırılmasının ardından cam ürünlerin görüntüleri, sabit bir platform üzerinden çevre ışığına dikkat edilerek profesyonel kamera ile stüdyoda çekimleri yapılmıştır. Alınan görüntülerin isabet oranı ortam koşullarına duyarlı olarak incelenmiştir. Kullanılan malzeme cam


(şeffaf) olduğundan dolayı yansıma, parlama gibi sorunları ortadan kaldırmak amacıyla ortam koşullarına duyarlı olarak stüdyoda çekimleri yapılmıştır. Bu amaçla stüdyo arka planı siyah ve beyazda mat/parlak durumlar için ışığın konumuna bağlı olarak incelenmiştir.

Şekil 4.3'deki gibi ilk olarak fotoğraf stüdyosunda çekim işlemi yapılması planlanan cam ürünler için ilk varyant ışık biçimi; Tepeden cam ürün üzerine dik düşecek şekilde gün ışığı, stüdyo arka planı ise siyah parlak fon olarak belirlenmiştir.



Şekil 4.3. Tepeden aydınlatmalı stüdyo ortamı.

Işık açısının görüntüye ve verimliliğe etkisini analiz etmek amacıyla, mevcut arka planlar için ışığın açısı değiştirilerek çekim işlemleri yapılmıştır. Şekil 4.4'de verilen stüdyo tasarımında ışık tepeden -60° açı ile önce stüdyo arka planına ulaşacak, buradan kırılımlar gerçekleşerek kamera merceğine direkt olarak etki etmeden cam yüzeyler üzerindeki hatalar tespit edilecektir.



Şekil 4.4. Tepeden -60° aydınlatmalı stüdyo ortamı.

Yapılan çalışmada iki durumda derin öğrenme modellemesi ile eğitim ve test işlemi gerçekleştirilmiştir.

- Görüntülerin tamamı Faster R-CNN derin öğrenme modeli üzerinde eğitilerek, eğitilmiş görüntüler derin öğrenme modeli üzerinde test edilmiş,
- Görüntülerin %70'i eğitim verisi olarak kullanılmış, %30'u ise test işlemi için kullanılmıştır.

Yukarıda bahsedilen iki durum göz önünde bulundurularak, tepeden dik aydınlatmalı stüdyo ortamı için beyaz ışıktaki siyah parlak, beyaz parlak, siyah mat ve beyaz mat arka-plan için elde edilen sonuçlar sırasıyla Çizelge 4.2, 4.3, 4.4 ve 4.5 'de sunulmuştur. Tepe açısı -60° olarak ayarlanarak siyah mat ve beyaz mat arka-plan aydınlatmalı stüdyo ortamı için elde edilen sonuçlar ise Çizelge 4.6 ve Çizelge 4.7'de verilmiştir.

Çizelge 4.2. Tepe açısı/gün ışığı siyah parlak fon.

Train Verisi %70, Test Verisi %30					
Hata Türü	Görüntü Sayısı	Işık	Stüdyo Arka plan	Sağlıklı Görüntü Sayısı	Doğruluk %
Habbe	135	TEPE AÇISI / BEYAZ IŞIK	SİYAH PARLAK	122	90,37
Kırışık	121			66	54,54
Sağlam	99			80	80,80
			Genel Doğruluk %		75,24

Faster R-CNN modellemesi kullanılarak tepe gün ışığı aydınlatmalı stüdyonun arka-planı siyah parlak üzerindeki sonuçlar Çizelge 4.2'de verilmiştir. Genel doğruluk oranı %75,24 olarak elde edilmiştir, bu sonuç cam ürünler üzerinde arka planın renk ve parlamasından dolayı verim kabul edilebilir seviyenin altında kalmıştır.

Arka plan rengi beyaz parlak fon olarak değiştirilerek sonuçlar gözlemlenmiştir ve Çizelge 4.3'te sunulmuştur.

Çizelge 4.3. Tepe açısı/gün ışığı beyaz parlak fon.

Train Verisi %70, Test Verisi %30					
Hata Türü	Görüntü Sayısı	Işık	Stüdyo Arka plan	Sağlıklı Görüntü Sayısı	Doğruluk %
Habbe	135	TEPE AÇISI / BEYAZ IŞIK	BEYAZ PARLAK	91	67,40
Kırışık	121			97	80,16
Sağlam	99			83	83,83
			Genel Doğruluk %		77,13

Faster R-CNN modellemesi ile beyaz parlak arka-plan stüdyo görselleri üzerinde yapılan işlem ile siyah parlak arka plana göre sonuçlar iyileştirilmiştir, Çizelge 4.3. araştırma kapsamında arka-plan siyah mat fon ile değiştirilerek görüntüler alınmıştır, Faster R-CNN modellemesinde test edilmesi üzere etiketlenmiştir. Çekim işleminin ışığın açısı ve rengi aynı kalacak şekilde arka planı değiştirilmiştir, elde edilen sonuçlar Çizelge 4.4'te sunulmuştur.

Çizelge 4.4. Tepe açısı/gün ışığı siyah mat fon.

Train Verisi %70, Test Verisi %30					
Hata Türü	Görüntü Sayısı	Işık	Stüdyo Arka plan	Sağlıklı Görüntü Sayısı	Doğruluk %
Habbe	135	TEPE AÇISI / BEYAZ IŞIK	SİYAH MAT	112	82,96
Kırışık	121			81	66,94
Sağlam	99			82	82,82
			Genel Doğruluk %		77,57

Faster R-CNN modellemesi ile Siyah mat arka-plan kullanılarak alınan görsellerin doğruluk tahmin sonucu, beyaz parlağa göre habbe (baloncuk) hatasında benzerlik göstermiş, kırışık ve sağlam görüntü üzerinde ise başarı oranı düşmüştür.

Çizelge 4.5'te, beyaz mat fon için alınan görüntülerin sonuçları sunulmaktadır.

Çizelge 4.5. Tepe açısı/beyaz ışık beyaz mat fon.

Train Verisi %70, Test Verisi %30					
Hata Türü	Görüntü Sayısı	Işık	Stüdyo Arka plan	Sağlıklı Görüntü Sayısı	Doğruluk %
Habbe	135	TEPE AÇISI / BEYAZ IŞIK	BEYAZ MAT	101	74,81
Kırışık	121			96	79,33
Sağlam	99			86	86,86
			Genel Doğruluk %		80,33

Faster R-CNN modellemesi ile beyaz mat arka plan kullanılarak alınan görsellerin doğruluk tahmin sonucu, siyah parlak; siyah mat ve beyaz parlağa göre yüksek çıkmıştır (Çizelge 4.5).

Işık açısının görüntüye ve verimliliğe etkisini analiz etmek amacıyla, mevcut arka planlar için ışığın açısı değiştirilerek çekim işlemleri yapılmıştır. Çizelge4.6 ve

Çizelge 4.7’de ışık açısı -60° seçilerek parlamanın minimum olduğu siyah ve beyaz mat fonlar için analizler yapılmıştır.

Arka plan siyah mat fon ile değiştirilmiş, ışıklandırma tepe açısı -60° ile ürün üstüne gelecek şekilde ayarlanmıştır. (Stüdyo tasarımı Şekil 4.4’de gösterilmiştir.) Alınan görüntüler, Faster R-CNN modellemesinde test edilmesi üzere etiketlenmiştir.

Çizelge 4.6. Tepe açısı -60° /gün ışığı siyah mat fon.

Train Verisi %70, Test Verisi %30					
Hata Türü	Görüntü Sayısı	Işık	Stüdyo Arka plan	Sağlıklı Görüntü Sayısı	Doğruluk %
Habbe	135	TEPE AÇISI - 60°/ BEYAZ IŞIK	SİYAH MAT	113	83,70
Kırışık	121			95	78,51
Sağlam	99			78	78,79
			Genel Doğruluk %		80,33

Arka planın siyah mat, ışık açısının değiştirilmesi ile birlikte ürün üzerinde stüdyo kaynaklı yansımalar minimize edilirken, ışık yönünde yapılan değişiklikler ile ürün üzerinde oluşan ışık LED yansıması çaprazlanmış, ürünler üzerindeki gözle görülmeyen hataların da meydana çıktığı görülmüştür.

Çizelge 4.7’de, arka-plan beyaz mat fon ile değiştirilmiş, ışıklandırma tepe açısı -60° ile ürün üstüne gelecek şekilde ayarlanmıştır. Alınan görüntüler, Faster R-CNN modellemesinde test edilmesi üzere etiketlenmiştir.

Çizelge 4.7. Tepe açısı -60° /beyaz ışık beyaz mat fon.

Train Verisi %70, Test Verisi %30					
Hata Türü	Görüntü Sayısı	Işık	Stüdyo Arka plan	Sağlıklı Görüntü Sayısı	Doğruluk %
Habbe	135	TEPE AÇISI - 60°/ BEYAZ IŞIK	BEYAZ MAT	109	80,74
Kırışık	121			98	81,03
Sağlam	99			87	87,88
			Genel Doğruluk %		83,22

Arka planın beyaz mat, ışık açısının değiştirilmesi ile birlikte ürün üzerinde stüdyo kaynaklı yansımalar minimize edilirken, ışık yönünde yapılan değişiklikler ile ürün üzerinde oluşan ışık LED yansıması çaprazlanmış, doğruluk sonuçları tatmin edici


düzeye erişmiştir. Son durumda en sağlıklı ortam koşulu olarak -60° beyaz ışık altında ve beyaz mat arka plan üzerinde görüntülerin alınması kararlaştırılmıştır.

4.2 Görüntü İşleme Algoritmalarının Kullanımı

Çalışmanın ikinci aşamasında görüntünün renk bilgisinden yola çıkarak bir bölütleme algoritması geliştirilmiştir. Bu algoritmanın oluşturulması sırasında HSV ve CIE Lab-Luv kullanılarak renk uzaylarının renk kanalları üzerinde analizler yapılmıştır. Buradaki amaç cam ürün görüntüleri üzerindeki hataları en iyi şekilde çevresel etkilerden (yansıma, leke, toz vb.) ayırmaktır. Görüntüdeki cam nesnelerinin üzerinden çevresel etkilerin ayrıştırılması öznitelik olarak belirlenmiştir. Bu şekilde doğru olarak elde edilecek cam ürün görüntüleri üzerindeki hatalar bir sonraki aşamada tahmin sisteminin eğitiminde giriş özelliği olarak kullanılacaktır. Bu nedenle cam üzerindeki hataların en doğru şekilde tespit edilmesi tahmin sisteminin başarısını yükseltecektir. Geliştirilen bölütleme algoritmasının cam ürün üzerindeki hata-çevresel etkiler ayrışımının ne kadar sağlıklı çalıştığını anlamak için veri kümesindeki görüntülerden bazıları Matlab üzerinde işleme tabi tutulmuştur.

4.2.1 HSV Renk uzayı uygulaması

Şekil 4.5’de cam görüntüsü üzerinde HSV renk uzayı algoritmasının H, S ve V kanalları uygulanmıştır.




Şekil 4.5. HSV ile işleme tabi tutulan cam görüntü.

Şekil 4.5 üzerinde görüldüğü üzere HSV- H kanalının uygulanması ile renk değişimi görüntü üzerindeki yansımayı tamamen kaldırmış fakat derin öğrenme modellemesi için etiketleme yapılmasına elverişli bir ortam sağlanamamıştır. HSV-S kanalını uygulaması ile yoğunluk değeri üzerinde yapılan değişiklik cam ürün olmasından kaynaklı, görsel üzerinde yüksek derecede değişiklik gözlemlenmiş, etiketleme yapılmasına elverişli bir ortam sağlanamamıştır. HSV-V kanalının uygulanmasıyla birlikte yansımalar indirgenmiş, derin öğrenme modellemesinde işlenmesi üzere etiketleme işlemi yapılmıştır (Nishu ve Agrawal, 2012).

4.2.2 CIE Lab LUV Renk uzayı uygulaması

Şekil 4.6 üzerinde görüldüğü üzere CIE-Lab Luv - L kanalını uygulaması ile renk değişimi üzerinde yapılan değişiklik cam ürün olmasından kaynaklı, görsel üzerinde yüksek derecede değişiklik gözlemlenmiş, etiketleme yapılmasına elverişli bir ortam sağlanamamıştır. CIE-Lab Luv-U kanalını uygulaması ile yoğunluk değeri üzerinde yapılan değişiklik yansımayı kırmadığı gibi, hata tespitini zorlaştırmış, görsel üzerinde yüksek derecede değişiklik gözlemlenmiştir. CIE-Lab Luv-V kanalının uygulanmasıyla birlikte yansımalar indirgenmiş ve derin öğrenme modellerinin eğitim aşamasını gerçekleştirmek için etiketleme işlemi yapılmıştır.



Şekil 4.6. CIE Lab Luv ile işleme tabi tutulan cam görüntü.

4.2.3 Adaptif Histogram Eşitleme uygulaması

Yansıma ve parlamanın minimize edilmesi amacıyla renk uzayı dönüşümü sonrası adaptif histogram eşitleme işlemi de uygulanmıştır. Sırasıyla başarılı olarak kabul edilen HSV-V kanalı ve CIE Luv-V kanalı üzerinde adaptif histogram eşitleme işlemi uygulanmıştır.

**HSV-V üzerinde Adaptif
Histogram Eşitleme**



**CIE Luv-V üzerinde Adaptif
Histogram Eşitleme**



Şekil 4.7. HSV-V ve CIE Luv-V kanalları üzerinde adaptif histogram eşitleme.

Şekil 4.7 üzerinde örnek olarak alınan veri üzerinde HSV-V, CIE Lab Luv-V renk uzayı algoritmaları ile birlikte uygulanan adaptif histogram eşitleme algoritmasıyla yansıma üzerinde ciddi değişiklik olduğu tespit edilmiştir. Derin öğrenme modelleri üzerinde adaptif histogram eşitleme algoritması kullanılarak ayrı ayrı işlem yapılması gerekmektedir.

4.3 Faster R-CNN ve YoloV3 Derin Öğrenme Modellerinin Uygulanması

Görüntü işleme yöntemlerinden; HSV-V, CIE Lab LUV-V ve Adaptif Histogram eşitleme (HSV-V ve CIE LUV-V için ayrı ayrı işleme tabi tutularak) üzerinden görüntüler derin öğrenme modellemesinde eğitmek üzere etiketlenmiştir. Eğitim sonucu oluşturulan karışıklık matrisleri aşağıdaki tablolarda verilmiştir.

Çizelge 4.8. Faster R-CNN ve YoloV3 karışıklık matrisleri.

Faster R-CNN modelinin karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	87	11	1
	1 (Habbe)	21	109	5
	2 (Kırışık)	12	11	98
YoloV3 modelinin karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	95	2	2
	1 (Habbe)	3	130	2
	2 (Kırışık)	5	5	111

Çizelge 4.8’de görüldüğü gibi, Faster R-CNN modellemeli önerilen yaklaşım ile hata içeren 256 cam görüntüsünden 207 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 12 yanlış sınıflandırma gerçekleştirilmiştir. YoloV3 derin öğrenme modeli ile önerilen yaklaşımda hata içeren 256 cam görüntüsünden 241 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 4 yanlış sınıflandırma gerçekleştirilmiştir. YoloV3 modellemesinden alınan sonuçların Faster R-CNN modellemesinden daha başarılı sonuçlar verdiği gözlemlenmiştir. Faster R-CNN ve YoloV3 modellemelerinden daha sağlıklı sonuçlar alabilmek, parlamayı minimize etmek amacıyla HSV-V ve CIE LAB- LUV-V renk uzayı dönüşümleri ile Adaptif histogram eşitleme işlemlerine tabi tutulmuştur. Uygulanan işlemler iki derin öğrenme modeli üzerinde de uygulanarak karışıklık matrisleri aşağıda verilmiştir.

Çizelge 4.9. HSV-V ve CIE-LAB LUV -V Faster R-CNN karışıklık Matrisi.

HSV-V Kanalı için Faster R-CNN modelinin karışıklık Matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	89	6	4
	1 (Habbe)	15	112	8
	2 (Kırışık)	6	7	108
CIE Lab LUV-V kanalı için Faster R-CNN modelinin karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	92	4	3
	1 (Habbe)	9	119	7
	2 (Kırışık)	9	5	107

Çizelge 4.9’da önerilen HSV-V renk uzayı dönüşümü Faster R-CNN derin öğrenme modeli yaklaşımı ile hata içeren 256 cam görüntüsünden 220 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 10 yanlış sınıflandırma gerçekleştirilmiştir.

Önerilen CIE LAB LUV – V renk uzayı dönüşümü Faster R-CNN derin öğrenme modeli yaklaşımında ise hata içeren 256 cam görüntüsünden 226 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 7 yanlış sınıflandırma gerçekleştirilmiştir.

Çizelge 4.10. Adaptif histogram eşitleme ile HSV-V, CIE LAB LUV-V kanalları için Faster R-CNN karışıklık matrisleri.

HSV-V Kanalı ve adaptif histogram eşitlemeli Faster R-CNN karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	91	5	3
	1 (Habbe)	9	119	7
	2 (Kırışık)	6	7	108
CIE Lab LUV-V Kanalı ve Adaptif histogram eşitlemeli Faster R-CNN karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	92	3	4
	1 (Habbe)	7	123	5
	2 (Kırışık)	11	4	106

Çizelge 4.10’da önerilen Adaptif Histogram eşitleme ve HSV-V renk uzayı Faster R-CNN derin öğrenme modeli uygulanmış yaklaşım ile hata içeren 256 cam görüntüsünden 227 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 8 yanlış sınıflandırma gerçekleştirilmiştir.

Önerilen Adaptif Histogram eşitleme ve CIE LAB LUV-V renk uzayı Faster R-CNN derin öğrenme modeli uygulanmış yaklaşımında ise hata içeren 256 cam görüntüsünden 229 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 7 yanlış sınıflandırma gerçekleştirilmiştir.

Çizelge 4.11. HSV ve CIE-Lab Luv için V kanalları için YoloV3 sonuçları.

HSV-V Kanalı için YoloV3 modelinin karışıklık Matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	95	3	1
	1 (Habbe)	8	126	1
	2 (Kırışık)	6	5	110
CIE-Lab LUV-V kanalı için YoloV3 modelinin karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	98	2	1
	1 (Habbe)	3	128	4
	2 (Kırışık)	3	6	112

Çizelge 4.11’de önerilen HSV-V renk uzayı uygulanmış YoloV3 derin öğrenme modeli yaklaşım ile hata içeren 256 cam görüntüsünden 236 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 4 yanlış sınıflandırma gerçekleştirilmiştir. CIE LAB LUV-V renk uzayı uygulanmış YoloV3 derin öğrenme modelinde önerilen yaklaşımla ise hata içeren 256 cam görüntüsünden 240 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 3 yanlış sınıflandırma gerçekleştirilmiştir.

Çizelge 4.12. Adaptif histogram eşitleme ile HSV-V, CIE LAB LUV-V kanalları için YoloV3 karışıklık matrisleri.

HSV-V Kanalı ve Adaptif histogram eşitleme YoloV3 karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	95	3	1
	1 (Habbe)	6	126	3
	2 (Kırışık)	7	5	109
CIE Lab LUV-V Kanalı ve Adaptif histogram eşitleme YoloV3 karışıklık matrisi		Tahmin		
		0 (Sağlam)	1 (Habbe)	2 (Kırışık)
Gerçek	0 (Sağlam)	97	1	1
	1 (Habbe)	3	130	2
	2 (Kırışık)	1	2	118

Çizelge 4.12’de önerilen Adaptif Histogram eşitleme ve HSV-V renk uzayı uygulanmış YoloV3 derin öğrenme modeli yaklaşım ile hata içeren 256 cam görüntüsünden 235 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 4 yanlış sınıflandırma gerçekleştirilmiştir. Adaptif Histogram eşitleme ve CIE LAB LUV-V renk uzayı uygulanmış YoloV3 derin öğrenme modelinde önerilen yaklaşımda ise hata içeren 256 cam görüntüsünden 248 tanesi doğru sınıflandırılmıştır. Hata içermeyen toplam 99 cam görüntüde ise 2 yanlış sınıflandırma gerçekleştirilmiştir.

Ortalama doğruluk değeri, derin öğrenme algoritmalarının doğruluğunu ölçmek için kullanılan bir değerlendirme kriteridir. Duyarlılık, Özgüllük ve F1 skoru denklemleri sırasıyla (9), (10) ve (11)’de verilmiştir.

Doğru Pozitif (DP):Doğru sınıflandırılan hatalı cam ürünlerin sayısı

Doğru Negatif (DN):Doğru sınıflandırılan hatalı olmayan cam ürünlerin sayısı

Yanlış Pozitif (YP):Yanlış olarak hatalı olarak tespit edilen ama hatalı olmayan ürünlerin sayısı

Yanlış Negatif (YN):Yanlış olarak tespit edilen fakat mevcutta hatalı olan cam ürünlerin sayısı

$$Duyarlılık = \frac{DP}{DP + YP} \quad (1.9)$$

$$Özgüllük = \frac{DP}{DP + YN} \quad (1.10)$$

$$F1 Skor = \frac{2xDuyarlılıkxÖzgüllük}{Duyarlılık + Özgüllük} \quad (1.11)$$

Bu ölçütler kullanılarak duyarlılık, özgüllük ve F1 skoru Adaptif Histogram eşitlemeli CIE LAB LUV-V algoritması ile YoloV3 derin öğrenme modeli üzerinde hesaplanmış ve Çizelge 4.13 üzerinde verilmiştir.

Çizelge 4.13. Adaptif Histogram eşitlemeli CIE LAB LUV-V Yolov3 modelinin başarı değerlendirme.

	Duyarlılık	Özgüllük	F1 Skor
0 (Sağlam)	96,04	97,98	97,18
1 (Habbe)	97,74	96,30	97,18
2 (Kırıık)	97,52	97,52	97,18
Tümü	97,44	97,27	97,18

Bu durum, Çizelge 4.13’ te görüldüğü gibi önerilen yaklaşımın özgüllük değerlerinin duyarlılık değerlerinden daha yüksek çıktığını göstermektedir. Başarı değerlendirme yapılan görüntü işleme ve derin öğrenme algoritmalarından Faster R-CNN modelinde oluşturulan kutular üzerinde eş zamanlı olarak çalıştırılan CNN mimarileri ile eğitim süresi ortalama 8,75 saat iken test süresi yaklaşık 0,4 ms olarak tespit edilmiştir. YoloV3 derin öğrenme modelinde ise ortalama eğitim süresi 6,50 saat iken test süresi yaklaşık 0,27 ms olarak tespit edilmiştir. Tez çalışmasında uygulanan tüm deneysel çalışmaların sonuçları karşılaştırmalı olarak duyarlılık, özgüllük ve F1 skoru hesaplamalarıyla Çizelge 4.14’te verilmektedir.

Çizelge 4.14. Görüntü işleme ve derin öğrenme modellerinin başarı değerlendirmeleri.

Başarı Değerlendirmesi (%)	Duyarlılık	Özgüllük	F1 Skor
Faster R-CNN	83,31	83,20	83,25
HSV-V Faster R-CNN	86,83	87,37	87,10
CIE Lab LUV-V Faster R-CNN	89,35	89,83	89,59
YoloV3	94,55	94,66	94,60
HSV-v YoloV3	93,13	93,40	93,26
CIE Lab LUV-V YoloV3	94,69	94,80	94,74
Adaptif Histogram Eşitleme HSV-V Faster R-CNN	89,40	89,77	89,58
Adaptif Histogram Eşitleme CIE Lab LUV-V Faster R-CNN	90,14	90,54	90,34
Adaptif Histogram Eşitleme HSV-V YoloV3	97,10	93,13	95,07
Adaptif Histogram Eşitleme CIE Lab LUV-V YoloV3	97,44	97,27	97,35

Çizelge 4.14'e göre sınıf üzerinde yapılan çalışmalar sonucunda adaptif histogram eşitleme ve renk uzay dönüşümlerinden CIE-Lab LUV-V algoritması ile ön işleme tabi tutulan görüntüler üzerinde YoloV3 derin öğrenme modellemesinin doğruluk oranı, diğer görüntü işleme ve derin öğrenme modellemelerine göre daha başarılı çıkmıştır.



5. SONUÇ VE ÖNERİLER

Cam üretiminde hata olarak nitelendirilen, habbe ve kırışık üzerinde yapılan bu çalışmada, üretim tesislerinde kalite kontrol aşamasında yaşanan olumsuzlukların aşılması amaçlanmıştır. Bunun için gerçek zamanlı bilgisayar görmesi kullanılarak kalite kontrol yapılması sağlanmıştır.

Öncelikle cam üretim tesisinden bir parti üretim hattından çıkan hatalı ürünler alınmıştır. Alınan numuneler üzerinde ayırıştırma yaparak hata endeksleri kontrol edilmiş, sık hata alınan habbe ve kırışık hataları öncelikli olarak ayırıştırılmıştır. Ürünlerin şeffaf olması, yansıma ve arka plandaki istenmeyen nesnelerin görsel üzerinde çıkacağından dolayı stüdyo ortamında çekim işleminin yapılması karar kılınmıştır.

Cam ürünler stüdyo ortamında siyah arka plan (mat ve parlak), beyaz arka plan (mat ve parlak) olmak üzere görüntü kayıtları profesyonel kamera ile 12 MP mercek çözünürlüğü 710x1280 “png” formatında kayıt altına alınmıştır. Alınan görüntüler stüdyo arka plan seçimi için Faster R-CNN derin öğrenme modellemesi için eğitilmiştir. Alınan sonuçlar neticesinde beyaz arka plan, -60° açılı iç büyüklükte ışıklandırma altında alınan görüntülerde diğerlerine göre parlamanın az olduğu, doğruluk oranlarının yüksek çıktığı gözlemlenmiştir.

Alınan doğruluk oranları göz önünde bulundurularak seçilen beyaz mat arka plan üzerinde alınan görüntüler, Faster R-CNN ve YoloV3 modellemesi üzerinde eğitime tabi tutulmuştur. Test için ayrılan görüntüler Faster R-CNN ve YoloV3 modellemesinde ayrı ayrı incelenerek doğruluk oranları karşılaştırılmıştır. Burada YoloV3 modellemesinin Faster R-CNN modellemesine göre başarılı olduğu ancak yansıma/parlamadan dolayı doğruluk oranının tatmin edici düzeyde olmadığı gözlemlenmiştir.

Yansıma/parlamayı minimize etmek adına görüntü işlemeden faydalanılarak renk uzayı algoritmalarından HSV'nin H, S ve V kanalları ve CIE Lab LUV'un L, U ve V kanalları üzerinde ön işleme tabi tutularak Faster R-CNN ve YoloV3 derin öğrenme modellemelerinde ayrı ayrı etiketleme işlemi yapılmıştır. Alınan sonuçlarda CIE LAB LUV – V ön işlemeli YoloV3 derin öğrenme modellemesi ile yansıma/

parlamayı minimize ettiği ve doğruluk oranını yükselttiği gözlemlenmiştir. Son olarak gözle görülür parlamayı yok etmek için kullanılan Adaptif Histogram Eşitleme ile Sağlam ve Habbe üzerinde çok etkili olmasa da kırışık hatası üzerinde kayda değer hata tespitini artırdığı gözlemlenmiştir (Çizelge 5.1).

Çizelge 5.1. Görüntü işleme ve derin öğrenme modeli genel doğruluk oranları.

Uygulanan Görüntü İşleme Algoritmaları ve Derin Öğrenme Modelleri	Faster R-CNN (%)	YoloV3 (%)
İşlenmemiş Veri	82,82	94,65
HSV-V Kanalı	87,042	93,24
CIE Lab LUV-V Kanalı	89,57	94,68
Adaptif Histogram Eşitleme HSV-V Kanalı	89,58	92,96
Adaptif Histogram Eşitleme CIE Lab LUV-V Kanalı	90,41	97,18

Çizelge 5.1’de görüldüğü üzere Adaptif histogram eşitleme ve CIE LAB LUV-V ön işlemeli, YoloV3 Derin öğrenme modellemesi kullanılarak kalite kontrolü, gerçek zamanlı olarak başarılı bir şekilde test edilmiş, sınıflandırma yöntemlerinden elde edilen sonuçlar gerçek hatalı ürünlerle karşılaştırılarak yazılımın başarısı test edilmiştir.

Test sonuçları incelendiğinde özellik çıkartım yöntemi olarak adaptif histogram eşitleme ve CIE Lab LUV-V renk uzayında yapılan bölütleme ile YoloV3 derin öğrenme modellemesi ile yapılan sınıflandırmanın diğer yöntemlere göre daha başarılı olduğu görülmüştür.

Önerilen yazılımın oldukça küçük sapma değerleriyle kalite kontrolü yapabildiği, bu sebeple derin öğrenme kullanılan gerçek zamanlı bilgisayar sistemlerinin insanlara yardımcı olabileceği tekrar gösterilmiştir. Farklı derin öğrenme modelleri ile başarı oranlarını artırılması ve minimum hata ile gerçek zamanlı karar destek sistemi oluşturulması hedeflenmektedir.

KAYNAKLAR

- Adamo, F., Attivissimo, F., Di Nisio, A. ve Savino, M., 2008. An automated visual inspection system for the glass industry, In Proc. of 16th IMEKO TC4 Symposium, Florence Italy, 9, 1, 22-24.
- Adamo, F., Attivissimo, F. ve Di Nisio, A., 2010. Calibration of an inspection system for online quality control of satin glass. IEEE Transactions on Instrumentation and Measurement, 59, 5, 1035-1046.
- Agrawal, S., 2011. Glass defect detection techniques using digital image processing—a review. IP Multimedia Communications, 65-67.
- Akdemir, B. ve Öztürk S., 2015. Glass surface defects detection with wavelet transforms, International Journal of Materials, Mechanics and Manufacturing, 3, 3, 170-173.
- Bükücü, C. ve Görkem, L., 2020. Cam ürünlerde gerçek zamanlı hata tespiti gerçekleştiren yeni bir prototip, Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 12, 2, 510-519.
- Cömert, O., Hekim, M. ve Adem, K., 2017. Weight and diameter estimation using image processing and machine learning techniques on apple images, International Journal of Engineering Research and Development, 9, 3, 147-154.
- Çinibulak, P., 2010. Gıda ambalajlarında migrasyon, Yüksek Lisans Tezi, NKÜ., Fen Bilimleri Enstitüsü, Hatay.
- Doğan C., 2009. Gıda ile temas eden malzemeler, ambalajlar, TÜBİTAK Bilim ve Teknik Dergisi, 501, 1, 56-61.
- Fezani, F. Ve Rahmani, A., 2006. Wavelets analysis for defects detection in flat glass, In Proceedings of the IEEE Multiconference on, Computational Engineering in Systems Applications, 1109, 10, 132-139.
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J., 2014. Rich feature hierarchies for accurate object detection and semantic segmentation, In Proceedings of the IEEE conference on computer vision and pattern recognition, 1109, 10, 580-587.
- Girshick, R., 2015. Fast r-cnn. In Proceedings of the IEEE international conference on computer vision, 1440-1448.
- Gonzalez, R. ve Woods, R. E., 1981. Real-time digital image enhancement, in Proceedings of the IEEE, 69, 5, 643-654.
- Hui M., Guang S. ve Jun W. and Zheng N., 2002. A glass bottle defect detection system without touching, International Conference on Machine Learning and Cybernetics, Beijing, Chin, 2, 628-632.

- Hongxi Z., Zhenduo G., Zegang Q. ve Jiuge W., 2012. Research of glass defects detection based on DFT and optimal threshold method, International Conference on Computer Science and Information Processing (CSIP), 1044-1047.
- Imbert, G., 1989. Automatic inspection systems for the flat glass industry, In Conference Record of the IEEE Industry Applications Society Annual Meeting, 1370-1374.
- Kumar, N. ve Kaur, N., 2013. Detection of defects in glass using edge detection with adaptive histogram equalization, Int. J. Innov. Res. Comput. Commun. Eng, 1, 6, 1321-1327.
- Li, X. ve Shu, Y., 2018. Research on glass surface quality inspection based on machine vision, Australian Journal of Mechanical Engineering, 16, 1, 98-104.
- Liang, Q., Xiang, S., Long, J., Sun, W., Wang, Y. ve Zhang, D., 2019. Real-time comprehensive glass container inspection system based on deep learning framework. Electronics Letters, 55, 3, 131-132.
- Ma, H. ve Zhang, B., 2002. Comparison among families of Mutong, Zhongguo Zhong yao za zhi= Zhongguo Zhongyao Zazhi, China Journal of Chinese Materia Medica, 27, 6, 412-418.
- Nishu ve Agrawal, S., 2012. Automated inspection of defects in glass by proper color space selection and segmentation technique of digital image processing, Int.J.Computer Technology & Applications, 3,3, 1058-1063.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A., 2016. You only look once: unified, real-time object detection, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition, 779-781.
- Rego, FL., 2003. Automatic land-cover classification devired from high-resulation ikonos satellite image in the urban Atlantic forest in Rio de Janerio, Brasil by means of object oriented approach, PhD dissertation, Department of Remote Sensing and Landspace Information System, University of Freiburg Germany, 172-176.
- Ren, S., He, K., Girshick, R. ve Sun, J., 2015. Faster r-cnn: Towards real-time object detection with region proposal networks, Paper presented at the Advances in neural information processing systems.
- Riza, S. ve Anton, S. P., 2007. Intelligent visual inspection of bottling production line through Neural Network, TENCON 2006 IEEE Region 10 Conference, 1-4.
- Öztürk, Ş. ve Akdemir, B., 2018. Fuzzy logic-based segmentation of manufacturing defects on reflective surfaces, Neural Computing and Applications, 29, 8, 107-116.

Zhang, H., Guo, Z., Qi, Z. ve Wang, J., 2012. Research of glass defects detection based on DFT and optimal threshold method, International Conference on Computer Science and Information Processing (IEEE), 1044-1047.

Xiaomian L. ve Yufeng S., 2018. Research on glass surface quality inspection based on machine vision, Australian Journal of Mechanical Engineering, 16, 1, 98-104.

URL-1<<https://www.atlascopco.com/tr-tr/vacuum-solutions/applications/glass-bottle-manufacturing> >, Eriřim tarihi: 10.06.2021

URL-2<<https://docplayer.biz.tr/137177499-Ergimis-camda-habbe-davranislarinin-gorsel-simulasyonu.html>>, Eriřim tarihi: 08.04.2019

URL-3<http://www.ece.mcmaster.ca/~xwu/lecture7_segmentation.pdf>, Eriřim tarihi: 04.04.2020

URL-4 <http://akizilkaya.pamukkale.edu.tr/B%C3%B6l%C3%BCm4_goruntu_isleme.pdf>, Eriřim tarihi: 04.12.2020.

URL-5<<https://teknoloji.org/nesne-tanima-algoritmaları-r-cnn-fast-r-cnn-ve-faster-r-cnn-nedir/>>, Eriřim tarihi: 15.10.2020

ÖZGEÇMİŞ

Adı ve Soyadı : Ali Burak ULAŞ

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans :Aksaray Üniversitesi, Elektrik Elektronik Mühendisliği, 2013-2018

Yüksek Lisans :Aksaray Üniversitesi, Elektrik Elektronik Mühendisliği Anabilim Dalı, 2018-2022

MESLEKİ DENEYİM VE ÖDÜLLERİ

1. Aytemiz Makelsan Kesintisiz Güç Kaynakları/Teknik Servis Mühendisi/Tuzla-İstanbul, Türkiye
2. Aselsan-Net Başaran İleri Teknoloji/Saha Mühendisi- Kontrolör/Çukurca-Hakkâri, Türkiye
3. Bor Holding – Borlease-Sixt Rent a Car / Yazılım Uzmanı / Ataşehir-İstanbul, Türkiye
4. Schneider Electric / Stajyer / Manisa, Türkiye
5. İnönü Üniversitesi Yapı İşleri Daire Başkanlığı / Stajyer / Malatya, Türkiye
6. Kaya Alarm ve Güvenlik Sistemleri / Operasyon Sorumlusu / Aksaray, Türkiye

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Kongrelerde Sunulan Makaleler

1. ULAŞ, A. ve SARI F. (2021). Detection of errors in glass products in studio environment with image processing and deep learning methods, ICENTE 2021, November 18-20, pp.198 - 204 Konya, Türkiye