



CAM ELYAF ÜRETİMİNDE SENTETİK VERİ DESTEKLİ DERİN ÖĞRENME TABANLI KALİTE KONTROL: OTONOM BİR KARAR DESTEK SİSTEMİ YAKLAŞIMI

Aydın ERDEN¹ , Damla AKTAŞ¹ 

¹Yönetim Bilişim Sistemleri Bölümü, İşletme Fakültesi, Marmara Üniversitesi, İstanbul, Türkiye

ÖZET

Bu çalışma, Endüstri 4.0 ve Kalite 4.0 paradigmaları kapsamında, cam elyaf üretimindeki kalite kontrol süreçlerini otomatize eden derin öğrenme tabanlı Cam Elyaf Kalite Otomasyon Sistemi (CEKOS) adlı bir karar destek sistemi prototipini sunmaktadır. Geleneksel manuel kontrol yöntemlerinin getirdiği iş yükünü ve insan hatası riskini minimize etmek hedeflenmiştir. Sistem, düşük maliyetli otomasyon yaklaşımıyla uyumlu olarak Raspberry Pi 4 tabanlı gömülü bir mimari üzerinde geliştirilmiştir. Veri kıtlığı sorununu aşmak için, gerçek hasarlı ürün verisinin yerine üretilen sentetik görüntülerden yararlanılmış ve model eğitimi transfer öğrenme ile optimize edilmiş VGG16 mimarisi üzerinde gerçekleştirilmiştir. CEKOS modeli, testlerde %89,08 genel doğruluk oranına ulaşmıştır. Yönetim Bilişim Sistemleri açısından en önemli katkı, sistemin tespit ettiği güncel hasar sınıflandırma verilerini, kurumsal kaynak planlama sistemlerine entegre edilebilir bir kalite skoru olarak API aracılığıyla sunmasıdır. Geliştirilen sistem, işletme yöneticilerine eyleme dönüştürülebilir içgörüler sağlayan, reaktif değil proaktif bir karar destek mekanizması sunarak süreç iyileştirmeyi ve veriye dayalı karar verme süreçlerini desteklemektedir.

Anahtar Kelimeler: Derin Öğrenme, Kalite Kontrol, Karar Destek Sistemi, Yönetim Bilişim Sistemleri, Sentetik Veri, Endüstri 4.0

SYNTHETIC DATA-AIDED DEEP LEARNING-BASED QUALITY CONTROL IN GLASS FIBER PRODUCTION: AN AUTONOMOUS DECISION SUPPORT SYSTEM APPROACH

ABSTRACT

This study presents a deep learning-based decision support system prototype, named Glass Fiber Quality Automation System (CEKOS) designed to automate quality control processes within the paradigms of Industry 4.0 and Quality 4.0, specifically in glass fiber production. The primary objective is to minimize the labor intensity and human error risk associated with traditional manual inspection methods. The system was developed on an embedded architecture utilizing a Raspberry Pi 4, aligning with a low-cost automation approach. To overcome the challenge of data scarcity, the model was trained using synthetic images generated to replace real damaged product data. Model optimization was achieved via transfer learning on an optimized VGG16 architecture. The CEKOS model attained an overall test accuracy of 89.08%. From a Management Information Systems perspective, the most significant contribution lies in the system's ability to provide current detected defect classification data as an enterprise resource planning integrable quality score through an API interface. This feature equips

business managers with actionable insights, establishing a proactive, rather than reactive, decision support mechanism that drives process improvement and supports data-driven decision-making.

Keywords: Deep Learning, Quality Control, Decision Support System, Management Information Systems, Synthetic Data, Industry 4.0

1. GİRİŞ

Cam elyafı hafif ve sağlam yapısı nedeni ile havacılık, otomotiv, savunma sanayi ve spor ekipmanları gibi çeşitli endüstrilerde yaygın olarak kullanılmaktadır. Üretim sürecinde cam elyaf malzemesinin yüzeyinde meydana gelebilecek hatalar, malzemenin yapısal bütünlüğünü ve ömrünü olumsuz yönde etkilemektedir. Günümüzde geleneksel kalite kontrol yöntemleri çoğunlukla kalite kontrol çalışanlarının incelemelere dayanmakta olup, bu yöntemler emek yoğun ve zaman alıcı bir süreç gerektirmekte ek olarak insan hatasına açık bir yapı sergilemektedir.

Endüstri 4.0 ile birlikte üretim süreçlerinin dijitalleşmesi, kalite yönetiminde de köklü bir değişimi beraberinde getirmiş ve Kalite 4.0 kavramının literatüre girmesinde vesile olmuştur (Carvalho vd., 2021, Sader vd., 2022). Kalite 4.0, geleneksel kalite kontrol yöntemlerinin yapay zekâ, büyük veri analitiği ve nesnelerin interneti gibi teknolojilerle desteklenerek, hata bulunduğu tepki veren reaktif bir yapıdan hatayı tahmin eden ve önleyen proaktif bir yapıya dönüşümü ifade etmektedir (Dogru & Keskin, 2020; Plathottam vd., 2023; Sader vd., 2022). Bu dönüşüm sürecinde geliştirilen yapay zekâ tabanlı sistemler, yalnızca hatalı ürünü ayırt eden teknik bir araç olarak değil aynı zamanda üretim bandından akan veriyi stratejik bilgiye dönüştüren bir karar destek sistemi olarak konumlandırılmaktadır. İşletme yöneticileri açısından ise elde edilen katma değer, numunelere ait kalite kontrol verilerinin yapay zekâ algoritmaları ile işlenerek hızlı kalite skorlarına dönüştürülmesi ve kurumsal kaynak planlama (ERP) sistemlerine entegre edilebilir bir veri akışı sağlanmasıdır. Böylece, operatör inisiyatifine dayalı geleneksel süreçlerden, veriye dayalı karar verme süreçlerine geçiş mümkün hale gelmektedir.

Bu çalışmanın temel amacı, cam elyaf üretimindeki kalite kontrol süreçlerini otomatikleştirmek, böylece üretim verimliliğini artırmak ve insan faktörlerinden kaynaklanan hataları asgari düzeye indirmektir. Çalışma kapsamında geliştirilen Cam Elyaf Kalite Otomasyon Sistemi (CEKOS) için Raspberry Pi 4 Model B donanımı yüksek işlem kapasitesi ve düşük güç tüketimi avantajları nedeniyle tercih edilmiştir. Geliştirilen sistem, üretim hattından periyodik olarak alınan numunelerin analiz edildiği, istatistiksel proses kontrol süreçlerini destekleyen “üretim hattı kenarı” bir karar destek mekanizması olarak tasarlanmıştır. Bu istasyon, numuneyi tarayarak görüntüleri yakalamakta ve derin öğrenme teknikleri ile analiz ederek sonuçları operatöre sunmaktadır. Model geliştirme sürecinde, mevcut mimarilerin başarısından yararlanmak adına transfer öğrenme tekniği uygulanmış ve ImageNet veri seti üzerinde önceden eğitilmiş VGG16 mimarisi temel alınmıştır. Eğitim veri seti oluşturulurken, gerçek dünyadaki hatalı ürün verilerinin azlığı sorununu aşmak ve modelin farklı hasar seviyelerini ayırt edebilmesini sağlamak amacıyla, Figma ve Roboflow gibi araçlarla üretilen sentetik görüntülerden yararlanılmıştır.

2. LİTERATÜR TARAMASI

Yönetim Bilişim Sistemleri (YBS) literatüründe yapay zekâ uygulamaları, genellikle işletmelerin operasyonel verimliliğini artıran ve yönetsel belirsizlikleri azaltan stratejik araçlar olarak incelenmektedir. Özellikle üretim sektöründe kullanılan görüntü işleme tabanlı sistemler, süreç madenciliği ve akıllı üretim başlıkları altında, insan hatasını minimize eden otonom denetçiler olarak konumlandırılmaktadır (Arora, M., 2023). Literatürdeki güncel çalışmalar, kalite kontrol süreçlerinde elde edilen verilerin ERP sistemlerine entegrasyonunun, işletmelerin maliyet yönetimi ve stok optimizasyonu kararlarında kritik bir rol oynadığını vurgulamaktadır (Sader vd., 2022).

Ultrasonik test ve termografik görüntüleme gibi geleneksel test yöntemlerinin sınırlılıkları nedeniyle, hata tespitinde daha verimli ve otomatik çözümler sunan derin öğrenme teknikleri giderek önem kazanmaktadır. Kompozit malzemelerdeki iç hataların tespiti üzerine yapılan çalışmalarda çeşitli görüntüleme ve öğrenme yöntemleri kullanılmıştır. Wu vd. (2025), kayma görüntülerinde hata boyutunu ve konumunu belirlemek için U-Net tabanlı derin öğrenme teknikleri kullanmış; %5'ten az hata oranına

ek olarak %95,84 piksel doğruluğu ve %96,17 ortalama piksel doğruluğu ile yüksek hassasiyetli bir segmentasyon performansı raporlamıştır. Gao vd. (2025), yüksek silika fenolik kompozitlerdeki iç kusurları mikrodalga yansıma sinyalleriyle incelemiş, özellikle faz bilgisinin genliğe kıyasla hataya daha duyarlı olduğunu belirterek, geliştirdikleri dikkat mekanizmalı model ile 6 mm'ye kadar inen kusurları geleneksel yöntemlere kıyasla %50'nin üzerinde bir artışla tespit etmiştir. LeMay ve Boldsaikhan (2025) ise fiber takviyeli kompozitlerde akustik empedans benzerliği nedeniyle tespit edilmesi güç olan ayırıcı kumaş kalıntılarını belirlemek için eko modu kullanmayan bir ultrasonik iletim yöntemi önermiş, geliştirdikleri RMS tabanlı özgün eşik sınıflandırıcısı ile standart genlik yöntemlerine kıyasla tespit hassasiyetini %21,34 oranında artırarak %98,76 doğruluk değerine ulaşmıştır.

Yüzey hata tespiti konusunda farklı endüstriyel malzemeler üzerinde de derin öğrenme uygulamaları yaygın olarak kullanılmaktadır. Literatürde metal (Duman ve Özsoy, 2021), çelik (Aşçı vd., 2025), tekstil (Hanbay, 2023), ahşap (Kılıç vd., 2019; Kılıç ve Özcan, 2023) ve kaynak hataları (Örs ve Özçelik, 2025) gibi çeşitli alanlarda VGG16, U-Net, ResNet ve InceptionV3 (Üzen vd., 2021; Üzen vd., 2022) tabanlı mimarilerin başarılı sonuçlar verdiği görülmektedir.

Donanım tabanlı uygulamalar ve veri ön işleme süreçleri de literatürde önemli bir yer tutmaktadır. Sağlam vd. (2020), atıkların sınıflandırılması için Raspberry Pi ve OpenCV tabanlı bir donanım geliştirmiş, TensorFlow ile eğitilen modelin atıkları başarıyla ayırttığını göstermiştir. Veri analizinde başarının veri kalitesine bağlı olduğunu vurgulayan Çetin ve Yıldız (2022), son beş yıldaki çalışmaları inceleyerek veri temizleme, dönüştürme ve indirgeme gibi ön işleme tekniklerinin algoritmaların etkinliği üzerindeki kritik rolünü ortaya koymuştur.

Literatürdeki çalışmaların genel görünümü, derin öğrenme algoritmalarının yüzey hata tespitinde geleneksel görüntü işleme tekniklerine kıyasla daha yüksek başarı sağladığını, ancak bu başarının büyük ölçüde etiketlenmiş, yüksek kaliteli ve geniş hacimli veri setlerine bağımlı olduğunu göstermektedir (Çetin ve Yıldız, 2022). Ancak endüstriyel üretim ortamlarında, özellikle cam elyaf gibi spesifik malzemelerde, model eğitimi için yeterli sayıda "hatalı" ürün görüntüsü elde etmek, üretim sürekliliği ve maliyet kısıtları nedeniyle önemli bir zorluk teşkil etmektedir. Mevcut literatürde algoritmik performansa odaklanan çok sayıda çalışma bulunmakla birlikte veri azlığı problemini sentetik veri üretimiyle aşan, aynı zamanda düşük maliyetli donanımlar üzerinde uçtan uca çalışan ve YBS perspektifiyle bir karar destek mekanizması olarak kurgulanan bütünleşik sistemlerin sayısı sınırlıdır (Sader vd., 2022).

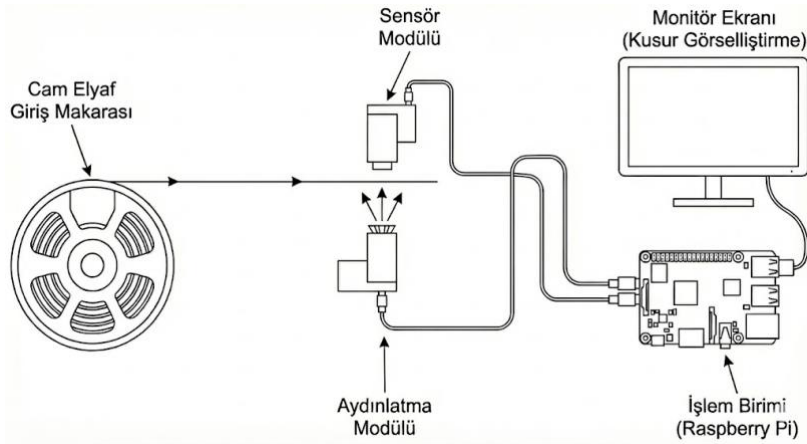
Bu çalışma, sadece teknik bir sınıflandırma başarısı hedeflememekte aynı zamanda Raspberry Pi tabanlı gömülü sistem mimarisi ile KOBİ'ler için erişilebilir, düşük maliyetli ve ERP sistemlerine entegre edilebilir bir akıllı kalite kontrol istasyonu prototipi sunarak literatürdeki uygulama boşluğunu doldurmayı amaçlamaktadır.

3. MATERYAL VE YÖNTEM

3.1 Sistem Tasarımı ve Donanım Bileşenleri

Bu çalışma kapsamında geliştirilen kalite kontrol sistemi, görüntü yakalama ve analiz yeteneklerine sahip modüler bir yapı üzerine inşa edilmiştir. Kontrol merkezi olarak, yüksek işlem kapasitesi ve düşük güç tüketimi avantajları nedeniyle Raspberry Pi 4 Model B tercih edilmiştir. Görüntü edinimi için düşük gürültü oranına sahip yüksek çözünürlüklü bir kamera modülü kullanılmış ve görüntü kalitesini artırmak amacıyla sisteme, kararlı aydınlatma sağlayan bir ışıklandırma modülü entegre edilmiştir. Ayrıca sistem step motor kontrolü için Tinkerforge Stepper Brick, kullanıcı etkileşimleri için Rotary Encoder V2 ve RGB LED buton ile sistem durumunu görselleştirmek için 128x64 OLED ekrandan oluşan bir mekanik hareket kontrol ünitesini de içermektedir (Şekil 1). Tüm bileşenler, endüstriyel üretim ortamlarına uygun dayanıklı bir muhafaza içerisine yerleştirilmiştir.

Şekil 1. Geliştirilen Cam Elyaf Kalite Kontrol Sisteminin Donanım Mimarisi ve Bileşenlerinin Şematik Gösterimi.




3.2 Veri Setinin Hazırlanması ve Ön İşleme

Modelin başarısı için çeşitliliğe sahip ve doğru etiketlenmiş bir veri seti oluşturulmuştur. Veri seti, eğitim, doğrulama ve test olmak üzere üç ana gruba ayrılmıştır. Veri setinin oluşturulmasında hibrit bir yaklaşım benimsenmiştir: "Hasarsız" sınıfı prototipin kamerasından elde edilen gerçek cam elyaf görüntülerinden oluşurken, diğer hasar sınıflarına ait görüntüler bu gerçek dokular üzerine Figma yazılımı kullanılarak endüstriyel hasar karakteristiklerine uygun simülasyonların işlenmesiyle üretilmiştir (Şekil 2). Bu yaklaşımın tercih edilmesindeki temel nedenler; üretim hattında kusurlu ürünlerin toplanmasındaki operasyonel zorluklar, ticari gizlilik kısıtlamaları ve aşırı öğrenme riskini azaltmak adına dengeli bir sınıf dağılımı (kontrollü varyasyon) oluşturma ihtiyacıdır. Sentetik veri kullanımının modelin genelleme kapasitesi üzerinde yaratabileceği sınırlılıklar Kısıtlar (Bölüm 5.3) başlığı altında ayrıca detaylandırılmıştır.

Üretilen bu sentetik hasar sınıflarının ayırımında, endüstriyel görsel kalite kontrol süreçlerindeki genel kabul görmüş alan toleranslarından ilham alınan nicel ölçütler kullanılmıştır. Yüze bütünlüğünün korunduğu durumlar "Hasarsız", yüze alanının %1–5'inin etkilendiği durumlar "Düşük Hasar", %5–15 yüze deformasyonu "Orta Hasar", %15'ten fazla yüze deformasyonu "Yüksek Hasar" ve yapısal sürekliliğin tamamen kaybolduğu durumlar ise "Hasarlı" olarak tanımlanmıştır. Sistemin temel amacı kesin matematiksel alan hesabı yapmak değil, üretim bandındaki kalite uzmanlarının göz kararıyla başvurduğu bu kavramsal tolerans eşiklerini modelin ne ölçüde ayırt edebildiğini test etmektir.

Şekil 2. Veri Setinde Kullanılan Hasarsız (Soldaki Örnek) ve Sentetik Olarak Üretilmiş Hasarlı (Sağdaki Örnek) Cam Elyaf Örnekleri



Veri seti Roboflow platformu kullanılarak optimize edilmiştir. Nihai model eğitimi için veri seti, ek sentetik görüntülerin eklenmesiyle toplam 1248 görüntü (1032 eğitim, 97 doğrulama ve 119 test) olacak şekilde tamamlanmıştır. Sınıf bazında veri dağılımının dengeli yapısını göstermek amacıyla, veri setinin eğitim, doğrulama ve test kümelerine göre detaylı dağılımı Tablo 1'de sunulmuştur.

Tablo 1. Veri Setinin Sınıf Bazında Eğitim, Doğrulama ve Test Kümelerine Göre Dağılımı

Sınıf	Eğitim	Doğrulama	Test	Toplam
Hasarsız	207	19	24	250
Düşük Hasar	206	19	24	249
Orta Hasar	207	20	23	250
Yüksek Hasar	206	20	24	250
Hasarlı	206	19	24	249
Toplam	1032	97	119	1248

Modelin ışık, açı ve yüzey varyasyonlarına karşı dayanıklılığını artırmak amacıyla Roboflow platformu üzerinden veri artırma işlemleri gerçekleştirilmiştir. İlk aşamada ön işleme adımı olarak görüntülerin yönelimleri otomatik olarak düzeltilmiş ve eğitim verimliliği için tüm görüntüler 640x640 piksel boyutuna yeniden ölçeklendirilmiştir.

Veri artırma aşamasında, RGB format standardizasyonu ve sınıf etiketleri korunarak her bir eğitim görüntüsünden 3 farklı varyasyon üretilmiştir. Eğitim veri setindeki çeşitliliği maksimize etmek için uygulanan dönüşümler şunlardır:

- Yatay çevirme
- $\pm 90^\circ$ saat yönü ve tersine rotasyon
- Görüntülerin %15'ine gri tonlama dönüşümü
- Renk tonu ($\pm 15^\circ$), doygunluk ($\pm 25\%$) ve parlaklık ($\pm 15\%$) varyasyonları
- Pozlama ($\pm 10\%$) ayarı
- Piksellerin %0.1'ine kadar hafif Gauss gürültüsü eklenmesi
- Uygulanan bu veri artırma adımlarına ait parametreler Şekil 3'te sunulmuştur.

Şekil 3. Roboflow Platformu Üzerinde Uygulanan Veri Artırma Parametreleri



Bu yaklaşım, Aşçı vd. (2025) tarafından da belirtildiği üzere, sınırlı veri setlerinde modelin eğitim sürecini benzer görüntüler oluşturarak desteklemek ve doğruluk oranlarını artırmak amacıyla literatürde geçerliliği kanıtlanmış bir yöntemdir. Ayrıca, işlem verimliliğini artırmak için tüm görüntülerin piksel değerleri 0-255 aralığından 0-1 aralığına ölçeklendirilmiştir.

3.3 Derin Öğrenme Modeli ve Eğitim Süreci

Model geliştirme sürecinde, daha az veri ile daha hızlı ve etkili öğrenme sağlayan transfer öğrenme tekniği kullanılmıştır. Sağlam vd. (2020) da belirttiği üzere, gömülü sistemlerin CPU kapasitesinin derin öğrenme eğitimi için yetersiz kalması nedeniyle, eğitim süreci harici GPU desteği ile gerçekleştirilmiş ve elde edilen ağırlıklar çıkarım için Raspberry Pi üzerine aktarılmıştır. Literatürde Duman ve Özsoy (2021) tarafından yürütülen karşılaştırmalı analizde, VGG16 mimarisinin InceptionV3 ve DenseNet gibi daha karmaşık yapılara kıyasla endüstriyel yüzey kusurlarının sınıflandırılmasında daha yüksek başarı gösterdiği kanıtlanmış olup, bu bulgu çalışmada temel mimari olarak VGG16'nın tercih edilmesinde belirleyici bir faktör olmuştur. Literatürde MobileNet veya EfficientNet gibi uç cihazlar için özelleştirilmiş daha hafif mimariler bulunmakla birlikte bu çalışmada öncelik işlem hızından ziyade doku ayırt etme hassasiyetine verilmiştir. Cam elyaf yüzeyindeki kusurların (özellikle orta ve düşük hasar sınıflarının) arka plan ile gösterdiği yüksek görsel benzerlik ve düşük kontrast, daha derin özellik çıkarma kapasitesine sahip VGG16 mimarisinin tercih edilmesini zorunlu kılmıştır. Sistem, hat üstü anlık izlemeden ziyade, periyodik numune analizi için kurgulandığından, hız kaybı sınıflandırma doğruluğundaki artış lehine tolere edilmiştir.

VGG16 modelinin önceden eğitilmiş katmanları dondurularak özellik çıkarıcı olarak kullanılmış, modelin son sınıflandırma katmanları çıkarılarak yerine projeye özgü katmanlar eklenmiştir. Bu yaklaşım, Hanbay'ın (2023) çalışmasında da vurgulandığı üzere, temel modellerin yüzeylerdeki ayırt edici hata özneliklerini aşırı soyutlama nedeniyle kaybetmesini önlemek ve modele göreve özgü bir öznelik çıkarma yeteneği kazandırmak amacıyla benimsenmiştir. Eklenen bu katmanlar özellik haritalarını tek bir vektöre indirgemek için GlobalAveragePooling2D, doğrusal olmayan özellikleri öğrenmek için 512 nöronlu ve ReLU aktivasyonlu bir Dense katmanı, aşırı öğrenmeyi önlemek için %50 oranında Dropout katmanı ve son olarak 5 sınıflı olasılıksal olarak çıktılmak için Softmax aktivasyonlu bir Dense katmanından oluşmaktadır.

Eğitim sürecinde optimizasyon algoritması olarak Adam, çok sınıflı sınıflandırma problemi için uygun olan kategorik çapraz entropi ve sınıf dengesizliğini yönetmek adına Odak Kaybı fonksiyonları kullanılmıştır. Eğitimin verimliliğini artırmak amacıyla doğrulama kaybı 8 eğitim döngüsü boyunca iyileşmezse eğitimi durduran EarlyStopping, en iyi modeli kaydeden ModelCheckpoint ve öğrenme oranını dinamik olarak düşüren ReduceLRonPlateau geri çağırma fonksiyonları sisteme entegre edilmiştir. Modelin hiperparametreleri ve yapılandırma detayları aşağıdaki tabloda özetlenmiştir (Tablo 2).

Tablo 2. Geliştirilen Modelin Eğitiminde Kullanılan Hiperparametreler ve Değerleri

HİPERPARAMETRE	DEĞER
Temel Model	VGG16
Dondurulmuş Katmanlar	Tümü (include_top=False)
Giriş Boyutu	224x224
Yığın Boyutu	32
Eğitim Döngüsü Sayısı	20
Optimizasyon	Adam
Kayıp Fonksiyonu	Odak Kaybı ($\gamma=2,0$, $\alpha=0,25$)
Öğrenme Oranı Azaltma	doğrulama kaybı üzerinde (factor=0,2, patience=5)
Erken Durdurma	doğrulama kaybı üzerinde (patience=8)

Seçilen hiperparametrelerin temel gerekçeleri sistemin donanım kısıtlarına ve veri setinin yapısına dayanmaktadır. Yığın boyutu 32 olarak belirlenerek Raspberry Pi'nin bellek optimizasyonu ile eğitim kararlılığı arasında bir denge sağlanmıştır. Eğitim döngüsü 20 olarak ayarlanmış olup, bu süreçte doğrulama kaybının stabilizasyonu ve erken durdurma mekanizmasının işleyişi gözlemlenmiştir. Optimizasyon algoritması olarak adaptif öğrenme oranı sunan ve küçük veri setlerinde hızlı yakınsama sağlayan Adam tercih edilmiştir. Kayıp fonksiyonu olarak odak kaybı kullanılarak sınıf dengesizliğinin olumsuz etkisi azaltılmış ve ayrıştırılması zor olan örneklere ağırlık verilmiştir. Son olarak, küçük veri

setinden kaynaklanabilecek aşırı öğrenme riskini minimize etmek amacıyla temel VGG16 mimarisinin önceden eğitilmiş katmanları dondurulmuştur.

3.4 Yazılım Altyapısı ve Ölçüm Algoritması

Sistemin yazılım altyapısı Python programlama dili üzerine kurulmuştur. Görüntü edinimi, ön işleme ve kontur tespiti işlemleri için OpenCV kütüphanesi, derin öğrenme modelinin oluşturulması, eğitimi ve tahmini için TensorFlow ve Keras kütüphaneleri kullanılmıştır. Kullanıcı arayüzü, operatörlerin analiz sonuçlarını hızlıca inceleyebilmesi için Tkinter kütüphanesi ile geliştirilmiştir.

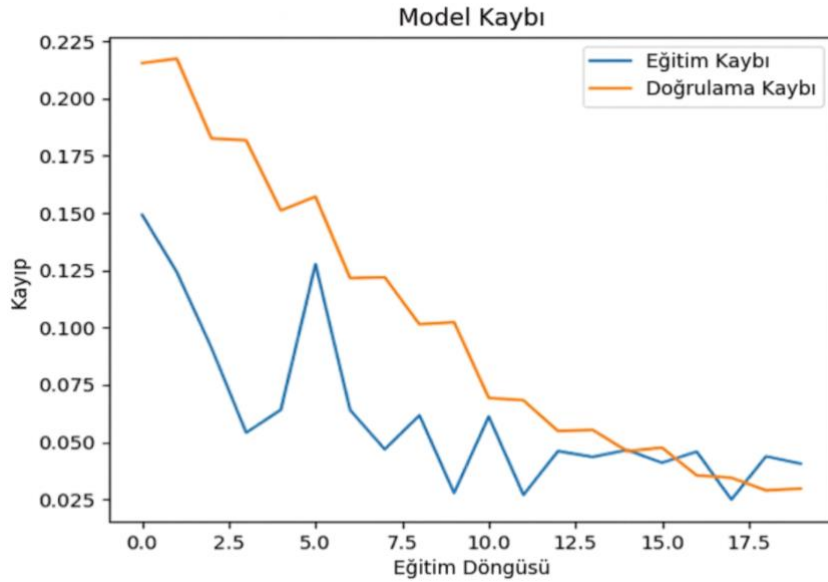
Sistem, tespit edilen hasar seviyesine göre arayüzde renk kodlu çerçeveler (Yüksek Hasar/Hasarlı için Kırmızı, Orta Hasar için Turuncu, Düşük Hasar için Sarı, Hasarsız için Yeşil) oluşturarak görsel geri bildirim sağlamaktadır. Ayrıca, kalibrasyon sonucu elde edilen piksel/mm oranı (0,0250 mm/piksel) kullanılarak, tespit edilen fiberin genişliği milimetre cinsinden ölçülmekte ve kullanıcıya sunulmaktadır.

4. BULGULAR

4.1 Model Eğitimi ve Analizi

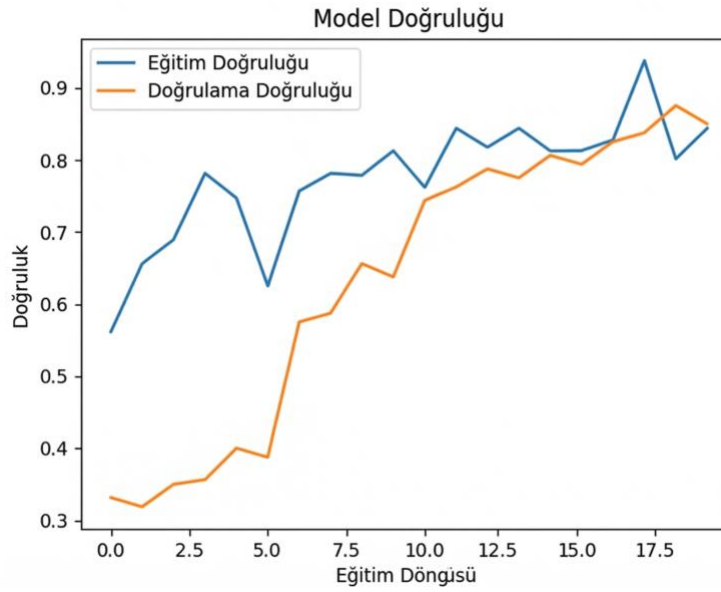
Kayıp grafiği analiz edildiğinde (Şekil 4), hem eğitim hem de doğrulama kaybının eğitim döngüsü sayısı ilerledikçe genel olarak düşüş eğilimi gösterdiği görülmüştür. Eğitim kaybı yaklaşık 0,15 seviyesinden başlayıp 0,03-0,045 seviyelerine kadar gerilerken, doğrulama kaybı 0,215 seviyesinden başlayıp 16-18 eğitim döngüsü aralığında minimum seviyesine (yaklaşık 0,03) ulaşmıştır. Doğrulama kaybının bu noktadan sonra plato çizmesi veya hafifçe yükselmesi, modelin genelleme yeteneğinin en üst noktaya ulaştığına ve aşırı öğrenme riskinin başladığına işaret etmektedir. Eğitim sürecinde gözlemlenen bu durum, Kılıç ve Özcan'ın (2023) veri artırma uygulanmayan modellerde eğitim döngüsü sayısı artırılrsa dahi performansın doygunluğa ulaştığı ve sabit kaldığı yönündeki tespitleriyle örtüşmekte olup, çalışmamızda uygulanan veri çeşitlendirme stratejilerinin ve erken durdurma mekanizmasının gerekliliğini doğrulamaktadır.

Şekil 4. Modelin Eğitim Süreci Boyunca Eğitim ve Doğrulama Veri Setlerine Ait Kayıp Değişim Grafiği



Doğrulama doğruluğu grafiği incelendiğinde ise (Şekil 5), modelin başlangıçta %33 seviyelerinde olduğu, ancak eğitim ilerledikçe kararlı bir artış göstererek 18. eğitim döngüsü civarında %88 ile en yüksek değerine ulaştığı gözlemlenmiştir. Eğitim ve doğrulama eğrileri arasındaki farkın eğitimin sonlarına doğru kapanması, modelin veri setindeki örüntüleri başarıyla öğrendiğini ve tutarlı bir performans sergilediğini göstermektedir.

Şekil 5. Modelin Eğitim Süresince Eğitim ve Doğrulama Veri Setleri Üzerindeki Doğruluk Performansının Değişimi



4.2 Model Karşılaştırması ve Sınıflandırma Başarısı

Çalışma kapsamında geliştirilen CEKOS, fiziksel operasyonları ve donanım entegrasyonunu yöneten bütünlük bir karar destek sistemidir. Bu sistemin görüntü sınıflandırma motoru olarak görev yapan ve görev spesifik katmanlarla özelleştirilmiş VGG16 mimarisi ile standart VGG16 mimarisinin performansları test verileri üzerinde karşılaştırılmıştır. Genel doğruluk oranları incelendiğinde, CEKOS modelinin %89,08 doğruluk oranı ile %88,24 doğruluk oranına sahip VGG16 modelinden daha başarılı olduğu tespit edilmiştir.

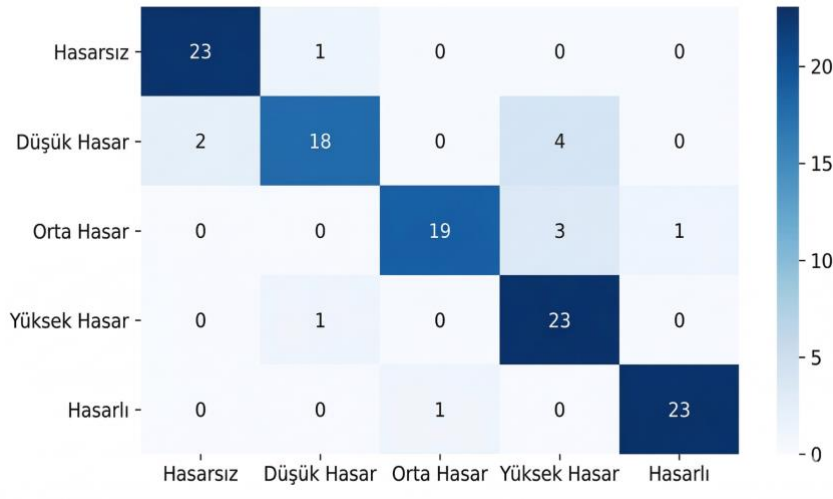
Sınıf bazlı performans (F1-skoru) değerlendirildiğinde (Tablo 3) her iki modelin de "Hasarsız" ve "Hasarlı" sınıflarında yüksek başarı gösterdiği, ancak "Orta Hasar" sınıfında CEKOS modelinin (F1: 0,88), VGG16 modeline (F1: 0,77) kıyasla performans artışı sağladığı görülmüştür.

Tablo 3. CEKOS Test Veri Seti Üzerindeki Sınıf Bazlı Sınıflandırma Performans Metrikleri

	KESİNLİK	DUYARLILIK	F1-SKORU	DESTEK
Hasarlı	0,96	0,96	0,96	24,0
Yüksek Hasar	0,77	0,96	0,85	24,0
Orta Hasar	0,95	0,83	0,88	23,0
Düşük Hasar	0,90	0,75	0,82	24,0
Hasarsız	0,92	0,96	0,94	24,0
Ağırlıklı Ortalama	0,90	0,89	0,89	119,0

Karmaşıklık matrisi analizi (Şekil 6), modelin toplam 119 test örneğinden 106 tanesini doğru sınıflandırdığını göstermektedir (Doğruluk: %89,08). Model, özellikle "Hasarlı" ve "Yüksek Hasar" sınıflarında %96 (23/24) oranında geri çağırma başarısına ulaşarak, üretimdeki kritik hataları yakalamada yüksek güvenilirlik sergilemiştir. Sınıflandırma hatalarının ise görsel benzerlik nedeniyle ağırlıklı olarak ara sınıflarda yoğunlaştığı görülmüştür. Örneğin "Düşük Hasar" sınıfına ait 4 örnek ve "Orta Hasar" sınıfına ait 3 örnek, model tarafından "Yüksek Hasar" olarak tahmin edilmiştir. Buna rağmen sistem, hasarsız ve kritik hasarlı ürünleri ayırt etme noktasında kararlı bir performans ortaya koymuştur.

Şekil 6. CEKOS Modelinin Test Veri Seti Üzerindeki Sınıflandırma Başarısını Gösteren Karmaşıklık Matrisi



4.3 Prototip Sistem Performansı ve İşlem Süreleri

Geliştirilen sistemin Raspberry Pi 4 üzerindeki canlı sistem testlerinde, sadece kontrol kodu çalışırken CPU kullanımının %8-12 aralığında, bellek kullanımının ise yaklaşık 40 MB seviyesinde olduğu gözlemlenmiştir. Tahmin süreleri karşılaştırıldığında, VGG16 modeli ortalama 12,52 saniyede, CEKOS modeli ise 12,83 saniyede tahmin üretmiş olup, iki model arasında hız açısından belirgin bir fark bulunmamaktadır.

Arayüz testlerinde, sistemin tespit edilen hasar seviyesine göre görsel uyarıları başarıyla ürettiği ve kalibrasyon verisi (0,0250 mm/piksel) kullanılarak fiber genişliğini milimetre cinsinden doğru şekilde hesaplayıp kullanıcıya sunduğu doğrulanmıştır.

5. TARTIŞMA

Genel doğruluk açısından CEKOS modeli (%89,08), VGG16 modeline (%88,24) kıyasla karşılaştırılabilir ve kısmi olarak daha yüksek bir başarı sergilemiştir. Sınıf bazlı performans analizlerinde (F1-skorları üzerinden); "Hasarsız" sınıfında her iki modelin de yüksek başarı gösterdiği (VGG16 F1: 0,98, CEKOS F1: 0,94), dolayısıyla modelin sağlıklı numuneleri ayırt etmede son derece güvenilir olduğu görülmüştür. "Düşük Hasar" sınıfında VGG16 (F1: 0,88) öne çıkarken, karmaşık bir hasar tipi olan "Orta Hasar" sınıfında CEKOS (F1: 0,88), VGG16'ya (F1: 0,77) göre belirgin bir üstünlük sağlamıştır. Benzer şekilde "Yüksek Hasar" sınıfında da CEKOS daha başarılı olmuş (F1: 0,85) ve karmaşıklık matrisinde %96'lık bir geri çağırma oranına ulaşarak ciddi hasarların büyük çoğunluğunu tespit etmiştir. Elde edilen bu sonuçlar, Hanbay (2023) tarafından yuvarlak örgü kumaşlarda yapılan çalışmadaki, özelleştirilmiş mimarilerin standart derin öğrenme modellerine kıyasla daha yüksek tespit başarısı sergilediği yönündeki bulgularla paralellik göstermektedir.

Doğrulama doğruluğunun 18. eğitim döngüsü civarında zirve yapması, bu noktanın genelleme için en uygun an olduğunu işaret etmektedir. Sınıflandırma raporundaki destek değerlerinin birbirine yakın olması (sınıf başına 23-24 örnek), veri setinin dengeli olduğunu ve sonuçların güvenilirliğini desteklemektedir.

Modelin doğrulama ve test kümeleri için ayrılan verilerin toplam veri setine oranı yaklaşık %20 seviyesindedir. Bu oran geleneksel istatistiksel analizler perspektifinden sınırlı veya yetersiz gibi değerlendirilebilse de görüntü işleme ve derin öğrenme alanındaki veri setlerinin doğası gereği literatürde kabul gören makul bir dağılımı temsil etmektedir. Görüntü verilerinin içerdiği yüksek boyutlu özniteliklerin model tarafından tam olarak öğrenilebilmesi için eğitim setine büyük bir ağırlık verilmesi zorunludur. Ulaşılan toplam görüntü sayısı ve uygulanan veri artırma teknikleri de dikkate alındığında, ayrılan bu %20'lik doğrulama ve test payı, modelin sınıflandırma performansını doğrulamak için yeterli ve makul kabul edilmektedir.

5.1 Literatür ile Karşılaştırma

Metal eklemeli imalat sürecindeki hataların tespiti üzerine yapılan kapsamlı bir çalışmada, DenseNet ve InceptionV3 modellerine kıyasla en yüksek performansın VGG-16 mimarisine sağlandığı ve %88,3 doğruluk oranına ulaşıldığı raporlanmıştır (Duman ve Özsoy, 2021). Bu çalışmada ise aynı mimariye dayalı transfer öğrenme yaklaşımıyla eğitilen CEKOS modeli (%89,08), söz konusu çalışmadaki referans başarımla rekabetçi bir performans sergileyerek, önerilen yöntemin endüstriyel uygulanabilirliğini desteklemiştir. Benzer bir donanım tabanlı yaklaşım sunan Sağlam vd. (2020) Raspberry Pi 3 üzerinde gerçekleştirdikleri çalışmada elde ettikleri %75,4'lük başarımla oranın ile kıyaslandığında, bu çalışmada kullanılan daha gelişmiş işlem birimi (Raspberry Pi 4) ve optimize edilmiş VGG16 mimarisi sayesinde ulaşılan %89,08'lik doğruluk değeri, donanım kapasitesindeki artışın sınıflandırma performansı üzerindeki pozitif etkisini doğrulamaktadır. Literatürde çelik (Aşçı vd., 2025) ve ahşap (Kılıç vd., 2019; Kılıç ve Özcan, 2023) gibi farklı malzemelerin hata tespitinde daha yüksek doğruluk oranları elde edilmiş olsa da bu çalışmada ulaşılan %89,08'lik başarımla, basit ikili sınıflandırmalar yerine görsel dokusu birbirine çok yakın beş farklı hasar seviyesinin ayrıştırılmasındaki karmaşıklık bağlamında değerlendirilmelidir.

Bu bağlamda, Üzen vd. (2022) geliştirdiği Inc-EFIN mimarisinde olduğu gibi, öznetelik haritalarındaki önemli detayların güçlendirilmesi prensibi, bu çalışmada kullanılan VGG16 tabanlı transfer öğrenme modelinin başarısını açıklayan teorik bir zemin oluşturmaktadır. Ancak cam elyaf malzemesinin görsel dokusunun karmaşıklığı göz önüne alındığında, Üzen vd. (2022) vurguladığı üzere, mekânsal (düşük seviyeli) ve anlamsal (yüksek seviyeli) özneteliklerin entegrasyonu, arka plan ile aşırı uyum gösteren ince hataların tespitinde kritik bir rol oynamaktadır.

Kaynak hataları gibi görsel olarak daha belirgin kusurların tespitinde %93,5 gibi oranlara ulaşabilmektedir (Örs ve Özçelik, 2025) ancak cam elyaf yüzeyindeki ince deformasyonların tespiti daha karmaşık bir problem olduğundan, CEKOS'un ulaştığı doğruluk seviyesi kendi bağlamında rekabetçi olduğu değerlendirilmektedir. Bu durum, çalışmamızdaki sentetik veri odaklı yaklaşımın gerçek verilerle desteklendiğinde ileri görüntü işleme teknikleriyle daha da geliştirilebileceğini göstermektedir. Ayrıca literatürde, kompozit malzemelerdeki hata tespitinde mikrodalga, ultrasonik veya kayma görüntüleme gibi farklı veri tiplerini kullanan güncel çalışmalar da CNN ve derin öğrenme algoritmalarının geleneksel yöntemlere kıyasla doğruluğu ve işlem hızını belirgin şekilde artırdığını göstermektedir (Gao vd., 2025; LeMay ve Boldsaikhan, 2025; Wu vd., 2025). Bu bulgular, çalışmamızda benimsenen derin öğrenme odaklı yaklaşımın endüstriyel kalite kontrolde sunduğu teknolojik potansiyeli ve avantajı doğrudan destekler niteliktedir.

Sonuç olarak yapılan karşılaştırmalar, bu projenin sentetik veri entegrasyonu, Raspberry Pi gibi donanımsal bileşenleri ve özelleştirilmiş kullanıcı arayüzü ile literatürdeki benzer çalışmalardan metodolojik olarak ayrıştığını göstermektedir.

5.2 Endüstriyel ve Bilimsel Çıkarımlar

Bu çalışma teknik bir prototip sunmanın ötesinde, Endüstri 4.0 perspektifinde işletmelerin veri güdümlü karar verme süreçlerine entegre olabilecek bir model önermektedir. Geleneksel süreçlerde kalite kontrol, operatöre bağlı öznel bir süreçken önerilen sistem bu süreci standartlaştırarak dijital bir veri akışına dönüştürmektedir. YBS bağlamında değerlendirildiğinde, bu sistemin bir fabrikanın üretim sistemleri ve ERP modülleri ile entegrasyonu, stratejik bir avantaj sağlayacaktır.

Sistem tarafından üretilen hasar sınıflandırma verileri, ERP sistemine güncel bir kalite skoru olarak işleme imkânı sunmaktadır. Örneğin, "Yüksek Hasar" tespiti yapıldığında sistemin otomatik olarak üretim bandını durdurma sinyali göndermesi veya ilgili partiyi karantinaya alması, hatalı ürünün müşteriye gitmesini engelleyen proaktif bir karar destek mekanizması olarak kurgulanması mümkündür.

Şekil 7'de gösterildiği üzere, sistemin ürettiği sınıflandırma sonuçlarının dış sistemlere aktarılması için gerekli olan RESTful API uç noktaları ve JSON veri paketleme modülleri prototip üzerinde yazılımsal olarak kodlanmış ve yerel bir sunucu ortamında test edilmiştir. Bu çalışma kapsamında aktif çalışan ticari bir ERP sistemine canlı bağlantı yapılmamış olmakla birlikte, geliştirilen API altyapısının standart veri protokollerine uyumluluğu doğrulanmıştır. Bu sayede, sistemin herhangi

bir modern ERP veya üretim sistemi altyapısına entegre edilebilirliği teknik olarak güvence altına alınmıştır.

Şekil 7. Önerilen Sistemin ERP Entegrasyonu ve Karar Destek Akış Şeması



Bu durum, sadece hatalı ürünü ayıklamakla kalmamakta, aynı zamanda geriye dönük veri analitiği ile üretim parametrelerinin optimize edilmesine olanak tanımaktadır. Dolayısıyla önerilen mimari, operasyonel seviyede bir hata yakalayıcı olmaktan çıkıp, taktiksel seviyede bir süreç iyileştirme aracına dönüşmektedir.

Projenin endüstriyel açıdan en önemli katkısı, manuel incelemeye dayalı geleneksel kalite kontrol süreçlerine kıyasla daha hızlı ve otomatik bir çözüm sunmasıdır. Ayrıca, Raspberry Pi gibi düşük maliyetli donanımların kullanımı, bu tür otomasyon sistemlerini KOBİ'ler için de erişilebilir kılmaktadır.

Sistemin işletmeye sağlayacağı ekonomik katkı, teorik bir yatırım getirisi senaryosu ile somutlaştırılabilir. Geleneksel yöntemde bir kalite kontrol operatörünün yıllık maliyeti ve insan hatasından kaynaklanan "Gözden Kaçan Hata Maliyeti" (müşteri iadesi ve marka prestij kaybı) düşünüldüğünde, CEKOS sisteminin donanım maliyeti ihmal edilebilir düzeydedir.

$$ROI = \frac{(M_{operator} + M_{hata-iade}) - (M_{sistem-kurulum} + M_{bakim})}{M_{sistem-kurulum}}$$

Formülde $M_{operator}$ insan gücü maliyetini, $M_{hata-iade}$ ise sistemin yakaladığı ancak insanın kaçıracağı hataların önlediği maliyeti temsil etmektedir. Önerilen sistem, vardiyadan bağımsız olarak numune analizine her an hazır yapısı ve %89.08'lik tutarlı doğruluk oranıyla, $M_{hata-iade}$ kaleminde ciddi bir düşüş sağlayacaktır. Özellikle havacılık gibi yüksek katma değerli sektörlerde, tek bir hatalı makarının iadesinin maliyeti bile sistemin kurulum maliyetini amorti etmeye yetmektedir.

5.3 Kısıtlar

Bu çalışmada geliştirilen sistemin literatüre sunduğu katkı ve elde edilen yüksek doğruluk oranına karşın, sonuçların genellenebilirliği açısından göz önünde bulundurulması gereken bazı sınırlılıkları mevcuttur. Araştırmanın birincil kısıtı, model eğitiminde kullanılan veri setinin yapısından kaynaklanmaktadır. Çalışma, donanım mimarisi ve mekanik tasarımı fiziksel olarak hayata geçirilmiş gerçek bir prototip (CEKOS) üzerinde yürütülmüş olsa da, veri seti aşamasında endüstriyel gizlilik protokolleri ve nadir görülen kusurların sistematik olarak toplanmasındaki operasyonel zorluklar nedeniyle, gerçek dokular üzerine Figma ile işlenmiş simülasyonlardan yararlanılmıştır. Sentetik olarak

oluşturulmuş hasarlı cam elyaf resimleri, modelin öğrenmesi için gerekli çeşitliliği sağlasa da, doğal hata oluşumlarını ve üretim ortamına özgü görüntü gürültülerini gerçekçi bir biçimde temsil etmemektedir. Bu durum, modelin gerçek fabrika verileri üzerindeki performansının ayrıca doğrulanması gerekliliğini ortaya koymaktadır. Sentetik olarak oluşturulmuş hasarlı cam elyaf resimlerinin model tarafından ezberlenmesi riskine karşı, eğitim sürecinde uygulanan yoğun veri artırma teknikleri (gürültü ekleme, bulanıklaştırma, renk sapmaları) kritik bir rol oynamıştır. Bu teknikler, modelin piksel mükemmelliğindeki sentetik desenlere odaklanmasını engelleyerek, daha yapısal ve şekilsel hata özniteliklerini öğrenmesini zorunlu kılmıştır.

İkinci olarak, projenin kapsamı belirli yüzey hatalarının (düşük, orta ve yüksek hasar) tespiti ile sınırlandırılmıştır. Cam elyaf kompozit üretiminde karşılaşılabilecek yüzeyden kolayca tespit edilemeyen diğer potansiyel kusur tipleri bu çalışmanın kapsamı dışında bırakılmıştır. Ayrıca sistemin performans testleri, sabit aydınlatma ve stabil koşulların sağlandığı kontrollü bir laboratuvar ortamında yürütülmüştür. Endüstriyel üretim hatlarında kaçınılmaz olan değişken ışık şiddeti, toz, titreşim ve sıcaklık değişimleri gibi çevresel faktörlerin sistemin kararlılığı üzerindeki etkileri bu aşamada test edilmemiştir. Model her ne kadar veri artırma teknikleri ile gürültüye karşı dayanıklı hale getirilmeye çalışılsa da, sentetik verinin doğası gereği bu fiziksel çevresel faktörleri birebir simüle etmesi mümkün değildir.

Donanım ve model performansı açısından değerlendirildiğinde ise, tercih edilen Raspberry Pi 4 platformu maliyet etkin bir çözüm sunmakla birlikte işlem gücü açısından belirli sınırlara sahiptir. Literatürde de VGG16 gibi geleneksel derin ağların, yüksek hesaplama ve bellek gereksinimleri nedeniyle gerçek zamanlı uç bilişim uygulamalarında darboğaz oluşturabileceği vurgulanmaktadır (Alramli ve Tekerek, 2025). Çalışmada elde edilen 12,83 saniyelik görüntü işleme ve çıkarım süresi, metrelerce elyafın saniyeler içinde üretildiği yüksek hızlı üretim bantlarında her milimetrenin taranması için bir darboğaz oluşturabilir. Ancak YBS disiplini açısından bakıldığında, bu sistemin "Gerçek Zamanlı Sürekli İzleme" yerine "İstatistiksel Proses Kontrol" tabanlı bir "Periyodik Örnekleme Sistemi" veya "Çevrimdışı Kalite Kontrol İstasyonu" olarak konumlandırılması daha gerçekçi bir senaryodur. Bu bağlamda sistem, üretim akışını kesmeden belirli aralıklarla alınan numunelerin hızlı analizi için optimize edilmiş bir "Karar Destek Asistanı" olarak değerlendirilmelidir.

Son olarak, belirlenen hasar sınıfları arasındaki görsel benzerlikler bir diğer kısıtlayıcı faktördür. Karmaşıklık matrisinde görüldüğü üzere (Şekil 6), özellikle "Düşük Hasar" ve "Orta Hasar" sınıflarına ait bazı örneklerin model tarafından "Yüksek Hasar" olarak tahmin edilmesi, modelin hasar şiddetini olduğundan daha yüksek algılama eğiliminde olduğunu ve hasar seviyeleri arasındaki görsel geçişlerin ayrıştırılmasında zorluklar yaşanabileceğini göstermektedir. Bu durum, literatürde Üzen vd. (2021) da aşırı uyum ve değişen hata boyutu başlıkları altında irdelediği hatalı bölge ile arka plan dokusu arasındaki güçlü benzerliğin ve belirsiz hata sınırlarının tespit performansını düşüren temel faktörler olduğu tespiti ile örtüşmektedir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, havacılık ve otomotiv gibi sektörlerde kritik öneme sahip olan cam elyaf malzemelerin üretim süreçlerinde karşılaşılan yüzey hatalarının tespiti amacıyla, derin öğrenme tabanlı ve gömülü sistem mimarisine sahip yenilikçi bir kalite kontrol prototipi geliştirilmiştir. Sistemin yapay zekâ altyapısında, ImageNet veri seti üzerinde ön eğitime tabi tutulmuş VGG16 mimarisinden yararlanılmış ve transfer öğrenme teknikleri uygulanmıştır. Veri seti, gerçek üretim verilerinin kısıtlı olması nedeniyle Figma ve Roboflow araçları kullanılarak üretilen hasarlı cam elyafları temsilen sentetik görsellerle zenginleştirilmiş, böylece modelin farklı hasar seviyelerini ayırt etme kapasitesi artırılmıştır. Geliştirilen CEKOS modeli, test aşamalarında %89,08'lik bir genel doğruluk oranına ulaşarak, %88,24 başarı gösteren standart VGG16 modeline kıyasla rekabetçi ve özelleştirilmiş katmanları sayesinde kararlı bir performans sergilemiştir. Özellikle orta ve yüksek seviyeli hasarların ayırt edilmesinde sağlanan bu başarı, odak kaybı, veri artırma, dinamik öğrenme oranı azaltma ve erken durdurma gibi optimizasyon tekniklerinin modele entegre edilmesiyle desteklenmiş, böylece aşırı öğrenme riski minimize edilerek modelin genelleme yeteneği artırılmıştır.

Geliştirilen sistem ile gerçekleştirilen derin öğrenme algoritmalarının düşük maliyetli fiziksel kontrol donanımları ile başarılı entegrasyonu, karmaşık endüstriyel problemler için bütüncül ve

ekonomik bir çözüm yolu sunmaktadır. Bununla birlikte, sentetik veri setleri kullanılarak yüksek performanslı modellerin eğitilebileceğinin gösterilmesi, endüstride sıkça karşılaşılan veri azlığı sorununa karşı önemli bir metodolojik çözüm önerisi getirmektedir. Endüstri 4.0 prensipleri ile uyumlu olarak tasarlanan bu sistem, modüler donanım ve yazılım mimarisi sayesinde farklı ürün tiplerine ve üretim hatlarına kolayca adapte edilebilir iken, üretim hatalarını ve maliyetleri düşürme potansiyeli taşımaktadır.

Modelin endüstriyel genellenebilirliğini artırmak adına, sentetik verilerin yanı sıra farklı üretim koşullarından elde edilen gerçek cam elyaf hata görüntülerini içeren daha geniş veri setleri ile eğitimin tekrarlanması, ileriye dönük bir araştırma fikri olarak değerlendirilmektedir. Gelecek çalışmalarda, sentetik verilerle eğitilen modelin endüstriyel doğrulamasını sağlamak amacıyla gerçek üretim tesislerinde pilot uygulamalar gerçekleştirilmesi de önerilmektedir. Bu kapsamda, sahadan toplanacak sınırlı sayıdaki gerçek veri ile transfer öğrenme tabanlı ince ayar süreçlerinin devreye alınması ve modelin simülasyondan gerçeğe geçiş performansının deneysel olarak analiz edilmesi, sistemin yaygınlaştırılabilirliği açısından faydalı olacaktır.

Ayrıca, mevcut sistemin sınıflandırma yeteneğine ek olarak, kusurların piksel tabanlı kesin sınırlarını belirlemek amacıyla literatürde başarılı sonuçlar veren U-Net (Aşçı vd., 2025) ve özellik piramit ağı (Üzen vd., 2021) mimarilerinin sisteme entegre edilmesi gelecek çalışmalar için önerilmektedir. Buna ek olarak, derin öğrenme modellerinin "kara kutu" yapısını çözümlenmek ve modelin karar süreçlerini şeffaflaştırmak için Alramli ve Tekerek'in (2025) de gelecek çalışmalar kapsamında işaret ettiği Grad-CAM veya LRP gibi açıklanabilir yapay zekâ tekniklerinin kullanılması, sistemin güvenilirliğini artıracaktır. Yüksek hızlı üretim hatlarında gerçek zamanlı işleme kapasitesini artırmak için NVIDIA Jetson veya FPGA tabanlı daha güçlü donanımların kullanılması ve YOLO, SSD veya Transformer tabanlı hibrit mimarilerin performans etkilerinin araştırılması sistemin verimliliğini artıracaktır. Ayrıca, hasar sınıfları arasındaki görsel benzerlikten kaynaklanan sınıflandırma hatalarını minimize etmek adına, Alramli ve Tekerek (2025) tarafından önerilen öz-dikkat mekanizmalarının yanı sıra Üzen vd. (2022) çalışmalarında hata tespiti için önemli detayları başarıyla güçlendirdiğini kanıtladıkları sıkıştırma ve uyarma bloklarının modele entegre edilmesi önerilmektedir. Son olarak, operasyonel verimliliği desteklemek amacıyla SCADA/MES sistemleri ile entegre çalışabilen, istatistiksel analiz ve raporlama modüllerine sahip gelişmiş kullanıcı arayüzlerinin tasarlanması projenin endüstriyel katma değerini yukarı taşıyacaktır.

KAYNAKÇA

- Alramli, T. ve Tekerek, A. (2025). A hybrid lightweight deep neural network approach for plant disease classification using self-attention mechanism and transfer learning. *Journal of Agricultural Sciences*, 31 (2): 392-412. <https://doi.org/10.15832/ankutbd.1537267>
- Arora, M. (2023). AI-driven Industry 4.0: Advancing quality control through cutting-edge image processing for automated defect detection. *International Journal of Computer Science and Mobile Computing*, 12 (8): 16-32. <https://doi.org/10.47760/ijcsmc.2023.v12i08.003>
- Aşçı, S. Y., Göker, F., Yılmaz, T. ve Güral, A. (2025). U-Net modeli kullanılarak derin öğrenme ile AISI 4340 çeliğinde mikroyapı tahminlerinin ve inklüzyonların belirlenmesi. *Politeknik Dergisi*, 28 (5): 1365-1374. <https://doi.org/10.2339/politeknik.1599580>
- Carvalho, A. V., Enrique, D. V., Chouchene, A. ve Charrua-Santos, F. (2021). Quality 4.0: An overview. *Procedia Computer Science*, 181: 341-346. <https://doi.org/10.1016/j.procs.2021.01.176>
- Çetin, V. ve Yıldız, O. (2022). A comprehensive review on data preprocessing techniques in data analysis. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 28 (2): 299-312. <https://doi.org/10.5505/pajes.2021.62687>
- Dogru, A. K. ve Keskin, B. B. (2020). AI in operations management: applications, challenges and opportunities. *Journal of Data, Information and Management*, 2 (2): 67-74. <https://doi.org/10.1007/s42488-020-00023-1>
- Duman, B. ve Özsoy, K. (2021). Toz yatak füzyon birleştirme eklemeli imalatta kusur tespiti için öğrenme aktarımı kullanan derin öğrenme tabanlı bir yaklaşım. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37 (1): 361-376. <https://doi.org/10.17341/gazimmfd.870436>

- Gao, M., Huo, L., Wang, F. vd. (2025). CNN-based similar microwave reflection signals for improved detectability and intelligent characterization of internal defects in composite materials. *Journal of Nondestructive Evaluation*, 44 (1): 28. <https://doi.org/10.1007/s10921-025-01163-3>
- Hanbay, K. (2023). Classification of circular knitting fabric defects using MobileNetV2 model. *Türk Doğa Ve Fen Dergisi*, 12 (4): 63-68. <https://doi.org/10.46810/tdfd.1327971>
- Kılıç, K. ve Özcan, U. (2023). AlexNet architecture optimized for wood defect detection. *Bozok Journal of Engineering and Architecture*, 2 (2): 20-28.
- Kılıç, Ö., Susuz, D. M. ve Süzek, B. (2019). A quality control system prototype for detecting knot defects in the wooden panel manufacturing. *Mugla Journal of Science and Technology*, 5 (1): 24-33. <https://doi.org/10.22531/muglajsci.473338>
- LeMay, G. ve Boldsaikhan, E. (2025). Detection of release fabric defects in fiber-reinforced composites using through-transmission ultrasound. *Journal of Manufacturing and Materials Processing*, 9 (3): 94. <https://doi.org/10.3390/jmmp9030094>
- Örs, M. E. ve Özçelik, Z. (2025). Görüntü işleme ve derin öğrenme ile kaynak hatalarının gerçek zamanlı tespiti. *DCE Doğa Bilimleri Dergisi*, 5 (2): 83-97.
- Plathottam, S. J., Rzonca, A., Lakhnori, R. ve Iloeje, C. O. (2023). A review of artificial intelligence applications in manufacturing operations. *Journal of Advanced Manufacturing and Processing*, 5(3): e10159. <https://doi.org/10.1002/amp2.10159>
- Sader, S., Husti, I. ve Daroczi, M. (2022). A review of quality 4.0: Definitions, features, technologies, applications, and challenges. *Total Quality Management & Business Excellence*, 33 (9–10): 1164–1182. <https://doi.org/10.1080/14783363.2021.1944082>
- Sağlam, A., Taş, M. ve Baykan, N. (2020). Geri dönüştürülebilir atıkların materyallerine göre sınıflandırılması için Raspberry Pi tabanlı donanım geliştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (20): 30-38. <https://doi.org/10.31590/ejosat.802692>
- Üzen, H., Türkoğlu, M., Arı, A. ve Hanbay, D. (2022). Piksel seviyesinde yüzey hata tespiti için InceptionV3 tabanlı zenginleştirilmiş öznitelik entegrasyon ağ mimarisi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38 (2): 721-732. <https://doi.org/10.17341/gazimmfd.1024425>
- Üzen, H., Türkoğlu, M. ve Hanbay, D. (2021). Result weighting-based Resnet feature pyramid network architecture for surface defect detection. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım Ve Teknoloji*, 9 (4): 760-772. <https://doi.org/10.29109/gujsc.1021785>
- Wu, R., Wei, H., Lu, C. ve Yang, L. (2025). Automatic and accurate determination of defect size in shearography using U-Net deep learning network. *Journal of Nondestructive Evaluation*, 44: 12. <https://doi.org/10.1007/s10921-024-01149-7>