

Derin Öğrenme Tabanlı Görsel Kalite Kontrol

Gülhan TOĞA^{1*}, Berkay KARAMAN², Şemsi Nur KÖMÜ³, Mehmet CİNGÖZ⁴, Kadir Can AKSOY⁵

^{1,2,3,4,5} Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Erciyes Üniversitesi, Kayseri, Türkiye

^{*1} gpala@erciyes.edu.tr, ² krmnberkay1@gmail.com, ³ semsinurkomu@gmail.com, ⁴ mehmetcingoz456@gmail.com, ⁵ kadircanaksoy6@gmail.com

(Geliş/Received: 18/08/2025;

Kabul/Accepted: 05/01/2026)

Öz: Bu çalışmada, üretim sürecinde elde edilen ocak bek kapağı görselleri üzerinde emaye kaplama kusurlarının tespiti amacıyla derin öğrenme tabanlı bir görsel kalite kontrol sistemi geliştirilmiştir. Görsel verilerin sınıflandırılmasında Evrişimsel Sinir Ağı mimarilerinden MobileNetV2 ve DenseNet121 transfer öğrenme yöntemleri kullanılmıştır. Ham görüntü sayısının sınırlı olması nedeniyle, modellerin genelleme yeteneğini artırmak amacıyla veri artırma ve normalizasyon işlemleri uygulanmıştır. Sınıf dengesizliğini azaltmak adına veri kümesi, katmanlı örnekleme ile eğitim, test ve doğrulama kümelerine ayrılmış, sınıf ağırlıkları dikkate alınarak modellerin eğitimi gerçekleştirilmiştir. Modellerin performansı doğruluk, kayıp oranı, karışıklık matrisi, ROC eğrileri ve AUC değerleri gibi metrikler ile değerlendirilmiştir. Sonuçlar, MobileNetV2 mimarisinde %91'in üzerinde, DenseNet121 mimarisinde ise %90'ın üzerinde sınıflandırma doğruluğu ile geliştirilen modellerin kusurlu ürünleri yüksek hassasiyet ve duyarlılıkla ayırt edebildiğini ortaya koymuştur. Bu bulgular, derin öğrenme ve görüntü işleme tabanlı yaklaşımların endüstriyel kalite kontrol süreçlerinde etkin, tutarlı ve otomatik bir çözüm sunduğunu; insan hatalarını ve denetim maliyetlerini azaltarak Endüstri 4.0 uyumlu sistemlere entegrasyon için güçlü bir potansiyel taşıdığını göstermektedir.

Anahtar kelimeler: Kalite kontrol, CNN, MobileNetV2, DenseNet121, görüntü işleme.

Deep Learning based Visual Quality Control

Abstract: In this study, a deep learning-based visual quality control system was developed to detect enamel coating defects on stove burner caps obtained from the production process. For image classification, transfer learning-based Convolutional Neural Network architectures, namely MobileNetV2 and DenseNet121, were employed. Since the number of raw images was limited, data augmentation and normalization techniques were applied to enhance the model's generalization capability. To mitigate class imbalance, the dataset was divided into training, validation, and test sets using stratified sampling, and class weights were incorporated during model training. The models' performances were evaluated using metrics such as accuracy, loss, confusion matrix, and ROC curves. The results demonstrated that the developed models achieved over 91% classification accuracy with MobileNetV2 and over 90% with DenseNet121, effectively distinguishing defective products with high precision and sensitivity. These findings indicate that deep learning and image processing-based approaches provide an efficient, consistent, and automated solution for industrial quality control processes, reducing human error and inspection costs while offering strong potential for integration into Industry 4.0-compliant systems.

Keywords: Quality control, CNN, MobileNetV2, DenseNet121, image processing.

1. Giriş

Üretimde kalite kontrol, işletmelerin verimliliği, maliyet yönetimi ve müşteri memnuniyeti açısından stratejik bir öneme sahiptir. Ürünlerin spesifikasyonlara uygunluğunun denetlenmesi yalnızca nihai kaliteyi güvence altına almakla kalmaz, aynı zamanda üretim sürecindeki aksaklıkların erken aşamada tespit edilmesine de olanak tanır. Ancak manuel kalite kontrol uygulamaları süreklilik, hız ve objektiflik açısından yetersiz kalmakta; insan kaynaklı hataların yanı sıra yüksek iş gücü maliyetine neden olmaktadır. Bu sorunların giderilmesi amacıyla geliştirilen, otomatik görüntü işleme sistemlerine dayalı kalite kontrol uygulamaları, sundukları avantajlarla öne çıkmaktadır [1,2].

Görüntü işleme teknikleri, endüstriyel ortamlarda kamera veya sensörler aracılığıyla elde edilen görsellerin işlenmesi yoluyla kusur tespitine olanak sağlayan yöntemlerdir. Bu sistemler; yüzey çatlakları, renk bozuklukları, eksik parçalar gibi üretim hatalarının hızlı ve tutarlı biçimde tespit edilmesini mümkün kılmaktadır [3]. Özellikle ürün çeşitliliğinin yüksek olduğu üretim hatlarında, görüntü işleme temelli kontrol sistemleri hem süreklilik hem de istikrar bakımından insan denetiminin yerini alabilmektedir. Örneğin, Çelik ve Tekin [4], otomotiv sektöründe

* Sorumlu yazar: gpala@erciyes.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0001-8835-1769, ² 0009-0001-0427-1882, ³ 0009-0001-1439-4229, ⁴ 0009-0007-4798-2119, ⁵ 0009-0005-3922-8883

boya hatalarının görüntü işleme yoluyla otomatik olarak tespit edilmesi sayesinde üretim hatalarında %30 oranında azalma sağlandığını bildirmiştir. Benzer şekilde, Erdoğan ve Alıcı [5], tekstil endüstrisinde iplik kusurlarının, Evrişimsel Sinir Ağı (CNN) ile entegre görüntü işleme sistemleri sayesinde anında tespit edilebildiğini ortaya koymuştur.

Görüntü işleme tabanlı kalite kontrol sistemlerinde en yaygın kullanılan derin öğrenme yaklaşımlarından biri CNN'dir. CNN mimarileri, çok katmanlı yapıları sayesinde görsellerden anlamlı öznitelikler çıkarabilir ve bu öznitelikleri kullanarak yüksek doğrulukta sınıflandırmalar gerçekleştirebilir. Krizhevsky ve ark.'nın [6] ImageNet ile geliştirdiği CNN modeli, bilgisayarla görme alanında temel bir dönüm noktası olmuş; Goodfellow ve ark. [7] bu modellerin çok katmanlı öznitelik öğrenme yeteneği sayesinde karmaşık görsel yapıları başarıyla ayırt edebildiğini vurgulamıştır. Bu tür derin ağlar, özellikle üretim hatlarında gerçek zamanlı kusur tespiti gibi görevlerde yüksek başarı oranlarıyla öne çıkmaktadır.

CNN'in başarısı birçok sektörde kanıtlanmıştır. Başaran ve Cömert [8], medikal görüntüleme alanında geliştirdikleri CNN modeli ile orta kulak hastalıklarının sınıflandırılmasında %94 doğruluk oranına ulaşmıştır. Görgel ve Kavlak [9] ise CNN ve Uzun-Kısa Süreli Bellek (LSTM) kombinasyonunu rüzgâr enerjisi tahmininde kullanarak zaman serisi verilerinde başarılı sonuçlar elde etmişlerdir. Endüstriyel alanda, Değirmenciler ve ark. [10], yüz maskesi tespiti; Türkdamar ve ark. [11] ise iş güvenliği donanımı algılama amacıyla CNN kullanarak başarılı uygulamalar gerçekleştirmiştir. CNN tabanlı modeller ayrıca mobil cihazlarda da uygulanabilir hâle gelmiş ve bu sayede üretim hatlarında entegre edilebilecek hafif yapılar sunulmuştur. Sandler ve ark.'nın [12] geliştirdiği MobileNetV2 mimarisi, düşük hesaplama kapasitesine sahip cihazlarda dahi yüksek doğruluk sağlayarak üretim ortamlarında pratik bir çözüm sunmaktadır. Son yıllarda farklı CNN mimarilerinin karşılaştırıldığı çalışmalar artmıştır. Çelik ve ark. [13], ahşap yüzey kusurlarını tespit etmek için MobileNet, DenseNet ve Inception mimarilerini karşılaştırmış ve en yüksek test doğruluğunun (%88,41) InceptionV3 ile elde edildiğini rapor etmiştir. Bu tür karşılaştırmalar, farklı malzeme türleri ve üretim koşulları için en uygun ağ mimarisinin seçilmesine rehberlik etmektedir.

Benzer biçimde Pınar ve ark. [14] denim kumaş hatalarını, Köse [15] dişli çark deformasyonlarını, Örs ve Özçelik [16] ise kaynak hatalarını görüntü işleme ve derin öğrenme tabanlı sistemlerle tespit etmiştir. Metal sektöründe Bayram [17], Parlak [18] ve Güçlü ve ark. [19] derin öğrenme destekli modellerin, klasik denetim yöntemlerine kıyasla daha hızlı ve yüksek doğrulukta sonuç verdiğini göstermiştir. Selamet [20] ve Gökkaya [21] metalik yüzeylerde CNN tabanlı modellerin kusur türlerini ayırt etmede güçlü performans sergilediğini ortaya koymuştur. Bu kapsamda, Konovalenko ve ark. [22], metal yüzey kusurlarının tespiti için U-Net tabanlı CNN mimarilerini karşılaştırmış ve özellikle karmaşık dokulu yüzeylerde U-Net'in yüksek doğrulukta segmentasyon sağladığını bildirmiştir. Lin ve Wibowo [23], derin öğrenmeye dayalı metal yüzey kusur tespit sistemlerinde veri kalitesinin model başarısı üzerindeki etkisini incelemiş ve uygun veri değerlendirme tekniklerinin yanlış sınıflandırmaları azalttığını göstermiştir. Chouhad ve ark. [24], akıllı veri güdümlü yöntemlerle üretim süreçlerinde yüzey kalitesinin otomatik değerlendirilmesini sağlamış; Balcıoğlu ve ark. [25] ise derin grafik evrişimsel sinir ağlarını (Deep-GCN) kullanarak metal üretiminde hata tanıma sistemlerinin makine tasarımına entegrasyonunu önermiştir. Ayrıca, Nguyen ve ark. döküm parçalarının denetiminde CNN'nin etkinliğini vurgularken, Leng ve Liu [26,27] çelik yüzeylerde Faster R-CNN tabanlı bir sistem geliştirerek hata tespitinde doğruluk oranlarını artırmıştır. Üretim hatlarında gerçek zamanlı denetim uygulamaları da artış göstermektedir. Citlak ve Pillay [28], emaye boya hatlarında mask R-CNN kullanarak nesne sınıflandırmasını gerçek zamanlı biçimde gerçekleştirmiş; Bridges ve Mort [29] ise tel kaplama hatlarında çevrim içi kalite kontrol için yeni sensör tabanlı stratejiler önermiştir. Özcan ve arkadaşları [30] LPG tüplerinde yüzey kirlenme tespiti için görüntü işleme ve makine öğrenimini entegre etmiş; Özyer ve Taşpınar [31] metal ürünlerde derin öğrenme tabanlı kalite kontrolü uygulamıştır. Bu çalışmalar, CNN tabanlı mimarilerin yalnızca görüntü sınıflandırma değil, aynı zamanda nesne tespiti, segmentasyon ve hata yeri belirleme gibi görevlerde de etkin biçimde kullanılabileceğini göstermektedir. MobileNetV2, DenseNet121, InceptionV3, U-Net ve Faster R-CNN gibi modern CNN mimarileri hem yüksek performans hem de düşük hesaplama maliyetleri sayesinde endüstriyel kalite kontrolün dijital dönüşümünü destekleyen güçlü araçlar hâline gelmiştir.

Literatürde derin öğrenme tabanlı görsel kalite kontrol sistemlerinin metal endüstrisi, otomotiv, tekstil ve elektronik gibi çeşitli sektörlerde başarıyla uygulandığı görülmektedir. Ancak yapılan kapsamlı inceleme sonucunda, emaye kaplama prosesine yönelik kalite kontrol süreçleri için geliştirilmiş derin öğrenme tabanlı görüntü işleme çalışmalarına rastlanmamıştır. Bu yönüyle, mevcut çalışma literatürdeki bu boşluğu doldurarak farklı bir saha uygulamasını ele alacak ve literatüre özgün bir katkı sağlayacaktır.

Bu çalışmada, ocak bek kapağı üretimine ilişkin kalite kontrol süreci incelenecektir. Bek kapağı üretimi; sac malzemeden pul alma, şekillendirme, yıkama ve kumlama gibi ön işlemlerle başlamaktadır. Yüzeyi hazırlanan ürünler, emaye kaplanarak son hâlini almaktadır. Bu aşamaların ardından tüm ürünler kalite kontrol sürecine

yönlendirilir. Kalite kontrol sonucunda uygun bulunan ürünler sevkiyata gönderilmekte; hatalı ürünler ise yeniden işleme tabi tutulmakta veya hurdaya ayrılmaktadır. Bu sistematik süreç, ürün kalitesini güvence altına alarak hatalı ürün oranını minimize etmeyi amaçlamaktadır. Ancak kalite kontrol işlemleri genellikle operatörler tarafından manuel olarak yürütülmektedir. Bu geleneksel denetim yöntemi, belli bir standarda sahip olmaması nedeniyle tutarsızlıklara ve insan kaynaklı hatalara açık olup; zaman yetersizliği ve yüksek maliyet nedeniyle düşük verimlilikle sonuçlanmaktadır. Ayrıca insan gözüyle algılanamayan kusurlar, müşteri şikâyetlerine ve ürün iadelerine yol açarak firmanın kurumsal imajına zarar vermekte ve gelecekteki satışlarını olumsuz etkileyerek kâr marjını düşürmektedir. Bununla birlikte, kalite kontrol sürecinde tespit edilemeyen kusurlu ürünlerin yol açtığı garanti, lojistik gibi pek çok gizli kalite maliyeti de söz konusudur. Bu gibi problemlerin giderilmesi için kalite kontrol muayenelerinin otomatik yapıldığı sensör veya görüntü işleme tabanlı sistemler gittikçe yaygınlaşmaktadır. Bu çalışma kapsamında, ocak bek kapağı üretim sürecinde elde edilen kusurlu ürün görselleri üzerinden farklı mimarileri kullanan CNN algoritmasına dayalı sınıflandırma modelleri geliştirilmiştir. Görseller, ilgili yöntem doğrultusunda ön işleme amacıyla veri artırma ve normalizasyon işlemlerinden geçirilmiş; ardından MobileNetV2 ve DenseNet121 mimarileri kullanılarak oluşturulan CNN modelleri yardımıyla kusurlu ürün tespiti gerçekleştirilmiştir. Model başarımları; doğruluk oranı, kayıp oranı, karışıklık matrisi ve ROC (Receiver Operating Characteristic) eğrileri ve AUC değerleri gibi performans metrikleri ile değerlendirilmiştir. Çalışma sonucunda önerilen modellerle yaklaşık olarak %91 test doğruluğu elde edilmiş ve önerilen modeller kusurlu ürünleri yüksek hassasiyet ve duyarlılıkla tespit edebilmiştir.


Yapılan çalışmanın ikinci bölümünde kullanılan yöntemler ayrıntılı biçimde açıklanmakta; üçüncü bölümde uygulama sonuçlarına yer verilmekte, son bölümde ise elde edilen bulgular değerlendirilmekte ve gelecek çalışmalar için önerilerde bulunmaktadır.

2. Materyal ve Metot

Derin öğrenme, insan beyninin öğrenme biçiminden esinlenerek geliştirilen yapay sinir ağlarına dayalı bir makine öğrenmesi yöntemidir [32]. Özellikle büyük veri setleri ile çalışırken, karmaşık örüntüleri ve ilişkileri öğrenme kapasitesi sayesinde etkin sonuçlar üretebilmektedir. Görüntü işleme, doğal dil işleme ve ses tanıma gibi çeşitli alanlarda başarılı uygulama örnekleri sunarak bu alandaki etkinliğini kanıtlamıştır. Derin öğrenme yöntemleri arasında en başarılı ve yaygın olarak kullanılan yapılardan biri Evrişimsel Sinir Ağları'dır [33]. Her ne kadar "Evrişimsel Sinir Ağı" terimi biyolojik bir kavram gibi görünse de CNN mimarisi nesne tanıma görevlerinde son derece etkili sonuçlar üreten hesaplamalı bir yaklaşımdır. CNN modelleri, özellikle görüntü verisi ile çalışmak üzere tasarlanmış derin öğrenme mimarileridir. Görsellerdeki kenar, doku ve şekil gibi temel öznitelikleri çok katmanlı yapıları sayesinde öğrenerek, nesne tanıma, sınıflandırma ve segmentasyon gibi görevlerde yüksek doğruluk sunmaktadır. Bu nedenle, CNN mimarileri; medikal görüntü analizi, otonom araç teknolojileri ve yüz tanıma sistemleri gibi çok çeşitli uygulama alanlarında yaygın olarak kullanılmaktadır.


CNN mimarisi, giriş görüntüsünden öznitelik çıkarımı yapmak amacıyla katmanlı bir yapı kullanır. Bu yapı genellikle sırasıyla evrişimsel katmanlar, aktivasyon fonksiyonları (çoğunlukla ReLU), havuzlama katmanları ve tam bağlantılı katmanlardan oluşur. Evrişimsel katmanlar, görüntü üzerinde yerel filtreler (kernel) uygulayarak düşük seviyeli kenar ve doku gibi öznitelikleri çıkarır. Havuzlama katmanları ise boyut indirgeme yoluyla hem hesaplama yükünü azaltır hem de önemli özniteliklerin korunmasını sağlar. Bu katmanlar, modelin uzamsal değişkenliklere karşı daha dayanıklı olmasına olanak tanır. Bu temel katmanlar ve özellikleri aşağıda özetlenmiştir:

- **Evrişimsel Katman (Convolutional Layer):** Modelin temelini oluşturan bu katman, görsellerdeki düşük ve yüksek seviyeli öznitelikleri algılamak için filtreler uygular. Bu katmanda öğrenilen özellikler, sonraki katmanlar için temel teşkil eder [7].
- **Doğrusalsızlık Katmanı (Non-Linearity Layer):** Genellikle evrişimsel katmanlardan sonra gelen bu katman, veriye doğrusal olmayan dönüşümler kazandırır. Aktivasyon fonksiyonu olarak yaygın biçimde ReLU kullanılmaktadır. Bu dönüşüm, modelin daha karmaşık örüntüleri öğrenmesini mümkün kılar [8].
- **Havuzlama Katmanı (Pooling Layer):** Modeldeki parametre sayısını ve hesaplama maliyetini azaltmak amacıyla kullanılır. Maksimum veya ortalama havuzlama işlemleri ile önemli öznitelikler korunurken, boyut indirgeme sağlanır. Bu katman aynı zamanda modelin özniteliklere karşı konumsal esnekliğini artırır [9].




Şekil 1. Havuzlama katmanı gösterimi [10]

- Düzleştirme katmanı (Flattening Layer): Önceki katmanlardan elde edilen çok boyutlu matrisleri tek boyutlu vektöre dönüştürerek yapay sinir ağının tam bağlantılı katmanına girdi olarak sunar. Bu işlem, sınıflandırma işlemi için gerekli yapıyı oluşturur [8].



Şekil 2. Düzleştirme katmanı gösterimi [10]

- Tam bağlantılı katman (Fully-Connected Layer): CNN mimarisinin son aşamasını oluşturan bu katman, sınıflandırma görevini yerine getirir. Evrişimsel ve havuzlama katmanlarından geçen öz nitelikler burada bir araya getirilerek karar verme işlemi gerçekleştirilir. Ağırlıklar ve bias değerleri bu aşamada optimize edilerek öğrenme tamamlanır [11].



Şekil 3. Tam bağlantı katmanı gösterimi [10]

Modelin eğitimi sırasında, sınıflandırma performansını artırmak amacıyla geriye yayılım (backpropagation) algoritması ile filtre ağırlıkları güncellenmektedir. CNN yapısı, görüntüdeki konumsal ilişkileri koruyarak öz niteliklerin hiyerarşik bir biçimde öğrenilmesine imkân sunar. Bu nedenle, özellikle görüntü sınıflandırma, nesne tanıma ve segmentasyon gibi görüntü işleme problemlerinde yüksek başarı göstermektedir.

Derin öğrenme tabanlı yaklaşımlar, özellikle görsel kusur tespiti alanında endüstriyel kalite kontrol uygulamalarında önemli başarılar elde etmiştir. Bu kapsamda LeNet-5, AlexNet, VGG (VGG16 / VGG19),

GoogLeNet / Inception, ResNet (Residual Networks), DenseNet, MobileNet ve EfficientNet gibi çok farklı CNN mimarileri kullanılabilmektedir. Ancak uygun bir CNN mimarisinin seçimi, hesaplama maliyeti, doğruluk düzeyi ve gerçek zamanlı uygulanabilirlik arasında bir denge kurulmasını gerektirir. Bu çalışmada MobileNetV2 ve DenseNet121 mimarileri seçilmiştir çünkü bu iki yapı, hesaplama verimliliği ve özellik yeniden kullanımı yönünden evrimsel sinir ağı tasarımıyla birbirini tamamlayan iki farklı yaklaşımı temsil etmektedir. DenseNet121, katmanlar arasındaki yoğun bağlantılar sayesinde sinyal (gradyan) akışını iyileştirir ve böylece çok derin ağlarda yaşanan "gradyan kaybı" sorununu azaltır [34]. Bu sayede daha derin özellik çıkarımı sağlar. MobileNetV2 ise hafif yapısı, az parametre sayısı ve gerçek zamanlı çalışma uygunluğu sayesinde üretim ortamlarında gömülü sistemlerde kolaylıkla uygulanabilir [35]. Bu iki mimarinin karşılaştırılması, kalite kontrol süreçlerinde model karmaşıklığı ile hesaplama maliyeti arasındaki dengeyi ortaya koymayı amaçlamaktadır. Ayrıca hafif yapılı mimari ile derin yapılı mimariyi kıyaslama olanağı da bulunacaktır.

3. Bulgular

Üretimde kalite kontrol işlemlerinin derin öğrenme temelli görüntü işleme yöntemleriyle gerçekleştirilmesi amacı ile tasarlanan sistem ile, üretilen bir ürünün hatalı ya da hatasız olup olmadığının daha hızlı, daha güvenilir, daha düşük maliyetle ve daha yüksek verimlilikle tespit edilmesi amaçlanmıştır. Bu hedeflere ulaşmada, sistemin yüksek doğruluk oranıyla çalışması en temel başarı kriterlerinden biri olarak belirlenmiştir. Bu kapsamda, ocak bek kapağı üretim sürecinde meydana gelen emaye kusurlarının, görüntü işleme yöntemleri aracılığıyla tespit edilmesine odaklanılmıştır. Sistemin geliştirilme sürecinde ilk olarak, hatalı ve hatasız ürünleri temsil eden örnek veri görselleri toplanmıştır (Bkz. Şekil 4 ve Şekil 5). Görseller, fabrikadaki kalite kontrol operatörleri tarafından manuel olarak etiketlenmiş (insan denetimi ile “hatalı / hatasız” sınıflandırması) ve etiketleme sürecinde operatörler arasında tutarlılık sağlamak amacıyla örnek kontroller yapılmıştır. Hata tipine ait herhangi bir sınıflandırma verisi bulunmamaktadır. Görüntüler sabit konumlu bir kamera (1080p çözünürlük) ile üretim hattındaki standart aydınlatma koşulları altında çekilmiş; kamera pozisyonu ve çekim açısı tüm örneklerde sabit tutulmuştur.



Şekil 4. Farklı açılardan hatasız ürün görselleri



Şekil 5. Kusurlu ürün görselleri

3.1. Veri ön işleme aşaması

Kalite kontrol sürecinde kullanılmak üzere gerekli veri seti, yerli bir ocak üretim firmasından temin edilen hatalı ve hatasız ocak bek kapağı görsellerinden oluşturulmuştur. Ancak elde edilen orijinal görsellerin sayısal olarak yetersiz olması, modellerin genellenebilirliğini artırma ve doğruluk-hassasiyet oranlarını iyileştirme gerekliliğini doğurmuştur. Derin CNN, aşırı öğrenme (overfitting) sorununu önleyebilmek ve yüksek performans gösterebilmek için geniş veri setlerine ihtiyaç duymaktadır. Ancak birçok uygulama alanında yeterli büyüklükte veri elde etmek güçtür. Bu nedenle, veri artırma (data augmentation) işlemi görüntü işleme literatüründe yaygın biçimde başvurulan bir yöntemdir [36]. Veri artırma aşaması öncesi (orijinal) veri kümesi toplam 1050 görüntüden oluşmakta iken; bunların 450'si kusurlu, 600'ü hatasız ürünleri temsil etmektedir. Artırma sonucunda sınıf büyüklükleri dengelenmeye çalışılmış ve artırma sonrası toplam görüntü sayısı 2826 (kusurlu: 1314, hatasız: 1512) olarak elde edilmiştir. Bu artışlar orijinal görüntü sayıları göz önüne alındığında yaklaşık kusurlu için $2,92 \times$; hatasız için $2,52 \times$ çarpına karşılık gelmektedir. Veri artırma şamasında uygulanan dönüşümler şunlardır: Belirli açılarla döndürme (15° , 30° , 45° , 60° , 90° , 180° , 270°), yatay ve dikey yansıtma, iki farklı ölçekleme ($0,5 \times$ ve $1,5 \times$) ve parlaklık düzeyinde değişiklik (%50 artırma ve %50 azaltma). Bu işlemler sayesinde modellerin farklı görüntü varyasyonlarını öğrenmesi ve dolayısıyla genelleme yetilerinin artması hedeflenmiştir. Sınıflandırma modellerinin vektörel çıktı üretmesi gerektiğinden, ürün etiketleri (kusurlu-hatasız) tek sıcaklık kodlaması (one-hot encoding) yöntemiyle kodlanmıştır. Bu kapsamda, 0 etiketi [1, 0]; 1 etiketi ise [0, 1] biçiminde dönüştürülerek model girişine uygun hale getirilmiştir. Tüm görseller, MobileNetV2 ve DenseNet121 mimarileri ile uyumlu olacak şekilde 224×224 piksel boyutuna yeniden boyutlandırılmıştır. Ayrıca, modellerin eğitildiği ImageNet veri yapısıyla uyum sağlamak amacıyla görseller, OpenCV içerisindeki normalize işleviyle 0 ile +1 aralığına dönüştürülerek ölçeklendirilmiştir. Bu normalizasyon işlemi, verilerin tekrarı, kaybı ya da tutarsızlığı gibi sorunların önüne geçerek modellerin daha verimli öğrenmesini sağlamaktadır.

Çalışmanın tamamı, tekrarlanabilirlik ve performans kıyaslaması açısından kolaylık sunması nedeni ile Google Colab bulut sistemi üzerinden Python programlama dili kullanılarak yapılmıştır. Her iki CNN mimarisi için, Google Colab T4 GPU kullanılmış olup, Görseller, açık kaynak kodlu ve yaygın olarak tercih edilen OpenCV (cv2) kütüphanesi aracılığıyla işlenmiştir. Ayrıca TensorFlow versiyon: 2.19.0; Keras versiyon: 3.10.0; tf.keras versiyon: 3.10.0 kütüphanelerinden faydalanılmıştır.

3.2. Modellerin eğitilmesi ve performans değerlendirme

Modellerin yalnızca eğitim verileri üzerinde değil, daha önce görülmemiş veriler üzerinde de yüksek doğrulukla çalışabilmesi, yani genelleme yeteneğinin güçlü olması hedeflenmiştir. Bu doğrultuda, modellerin eğitiminde dikkatli bir strateji izlenmiş ve verinin eğitim, doğrulama ve test olarak ayrılması esas alınmıştır. Veri kümesi, sınıf dağılımı korunarak %70 eğitim, %15 test ve %15 doğrulama olacak şekilde katmanlı örnekleme

yöntemiyle rastgele bölünmüş, böylece her kümede sınıflar dengeli biçimde temsil edilmiştir. Ayrıca, veri setinde sınıf dengesizliği bulunması nedeniyle modelin az örnek içeren sınıflara da duyarlılık gösterebilmesi amacıyla sınıf ağırlıkları hesaplanarak modele entegre edilmiştir. Bu işlem, örnek sayısı ile ters orantılı olacak şekilde sınıflara ağırlık atanmasını sağlayan `compute_class_weight()` fonksiyonu ile gerçekleştirilmiştir.

Model mimarileri olarak, önceden ImageNet veri seti üzerinde eğitilmiş olan MobileNetV2 ve DenseNet121 kullanılmıştır. Bu mimarilerde sınıflandırma katmanı çıkarılarak (`include_top=False`) yalnızca temel öznitelik çıkarım yeteneklerinden faydalanılmış, böylece modellerin daha önce öğrenmiş olduğu genel görüntü özellikleri bu çalışmaya aktarılmıştır. Bu temel yapı üzerine GlobalAveragePooling2D katmanı eklenerek özellik haritalarının boyutu düşürülmüştür. Modellerde sınıflandırma katmanında, ReLU aktivasyon fonksiyonlu 128 nöronlu bir tam bağlantılı (Dense) katman kullanılmıştır. Son katmanda iki sınıfa ait olasılıkları yansıtan softmax aktivasyonlu bir çıkış katmanı yapılandırılmıştır. 128 nöron sayısı, modelin öğrenme kapasitesini korurken aşırı karmaşıklık ve hesaplama yükünü önlemek amacıyla belirlenmiştir. Literatürde, benzer CNN temelli modellerde düşük parametrelili sınıflandırma katmanlarının aşırı öğrenmeyi azaltarak doğrulama başarısını artırdığı belirtilmektedir [37-38]. Ayrıca, Goodfellow, Bengio ve Courville [7] derin öğrenme modellerinde nöron sayısının, model kapasitesi ile genelleme yeteneği arasında önemli bir denge unsuru olduğunu vurgulamaktadır.

Tam bağlantılı katmanın ardından, aşırı öğrenmenin önlenmesi ve modellerin genelleme yeteneğinin artırılması amacıyla %40 oranında dropout uygulanmıştır. Dropout, eğitim sürecinde nöronların belirli bir kısmını rastgele devre dışı bırakarak modelin belirli özelliklere aşırı bağımlı hale gelmesini engelleyen bir düzenleme tekniğidir [39]. Literatürde yaygın olarak önerilen %30–%50 aralığındaki dropout oranları [7] dikkate alınarak yapılan ön denemelerde, %40 oranının doğrulama kaybını en düşük seviyeye indirdiği gözlemlenmiştir. Bu yapı sayesinde modeller hem yeterli öğrenme kapasitesine sahip olmuş hem de aşırı uyumdan kaçınarak daha istikrarlı bir performans sergilemiştir.

Modellerin derleme aşamasında, parametre güncellemelerinde yaygın olarak tercih edilen “Adam” optimizasyon algoritması kullanılmış, öğrenme oranı 0,0001 olarak belirlenmiştir. Kayıp fonksiyonu olarak çok sınıflı sınıflandırma problemlerinde tercih edilen categorical crossentropy seçilmiş ve performans metriği olarak doğruluk (accuracy) esas alınmıştır. Eğitim süreci boyunca modellerin başarısını izleyebilmek ve aşırı öğrenmenin önüne geçmek amacıyla bazı geri çağırım mekanizmaları kullanılmıştır. Bunlardan ilki olan EarlyStopping, doğrulama kaybı veya doğruluk değerinde beş ardışık yinleme boyunca iyileşme gözlenmediği durumda (patience=5) eğitimi sonlandırmakta ve en iyi ağırlıkların geri yüklenmesini sağlamaktadır. Buna ek olarak, ModelCheckpoint geri çağırımı sayesinde doğrulama seti üzerindeki en iyi başarıya ulaşılan modellerin ağırlıkları kaydedilmiştir.

Modellerin eğitimi, `model.fit()` fonksiyonu ile gerçekleştirilmiş ve eğitim süresince her biri 62 örnekten oluşan mini-batch’ler kullanılarak toplam 30 epok boyunca yürütülmüştür. Eğitim süresince hem eğitim hem doğrulama verileri üzerinde modellerin başarıları takip edilmiştir. Eğitim sonrasında, modellerin daha önce hiç görmediği test verileri üzerinde sınıflandırma başarıları değerlendirilmiş ve modellerin genelleme yeteneği analiz edilmiştir. Bu analiz kapsamında, `evaluate()` fonksiyonu ile test doğruluğu ve kayıp değeri hesaplanmış, ayrıca tahmin edilen sınıflar (test sonuçları) ile gerçek sınıflar karşılaştırılarak bir karışıklık matrisi (confusion matrix) oluşturulmuştur. Bu matris yardımıyla modelin hangi sınıflarda doğru ya da hatalı tahmin yaptığı gözlemlenmiş; doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif gibi temel sınıflandırma ölçütleri elde edilmiştir. Doğru pozitif (TP), hatalı ürünün doğru tahmin edilmesi; doğru negatif (TN), hatasız ürünün doğru tahmin edilmesi; yanlış pozitif (FP), hatasız ürünün hatalı olarak tahmin edilmesi; yanlış negatif (FN) ise hatalı ürünün hatasız olarak tahmin edilmesi şeklinde ifade edilmektedir.


“validation_data” parametresi aracılığıyla oluşturulan veri seti modeller için bir doğrulama seti görevi görmüş ve her adım sonunda modellerin genelleme yeteneği bu küme üzerinde izlenmiştir. Nihai model performansı, eğitim sürecinin daha izlenebilir ve anlaşılabilir olması amacıyla eğitim ve doğrulama verileri için doğruluk (accuracy) ve kayıp (loss) değerleri ile görselleştirilmiştir. Eğitim ve doğrulama başarımları arasında büyük farklar olması durumunda ise modelin aşırı ezberlediği ya da yeterince öğrenemediği yorumlanabilir. Bu sayede, modellerin eğitimi yalnızca nicel sonuçlara değil, aynı zamanda görsel analizlere de dayandırılarak değerlendirilmiştir. Bütün bu yapı sayesinde modellerin öğrenme süreci dengeli biçimde kontrol edilmiş, en iyi ağırlıklar korunmuş ve yeni veriler üzerinde güvenilir sonuçlar elde edilmiştir. Geliştirilen modellere ait sözde kod “Ek A” kısmında verilmiştir. Ayrıca modellerin performansının değerlendirilmesinde ROC eğrisi ve AUC (Area Under the Curve) metriği de kullanılmıştır. ROC eğrisi, modelin farklı sınıflandırma eşik değerlerinde doğru pozitif oranı (TPR) ile yanlış pozitif oranı (FPR) arasındaki ilişkiyi görselleştirerek modelin ayırt etme yeteneğini ortaya koyar. AUC ise ROC eğrisinin altında kalan alanı ifade eder ve modelin genel sınıflandırma başarısını tek bir sayısal değerle özetler. AUC değeri 1’e yaklaştıkça modelin kusurlu ve hatasız ürünleri doğru bir şekilde ayırt etme gücü artar; 0,5 civarında bir değer ise modelin rastgele tahmin yaptığını gösterir [40]. Bu metrikler, özellikle

sınıf dengesizliğinin bulunduğu görsel kalite kontrol uygulamalarında modelin güvenilirliğini değerlendirmek için önemlidir.


Önerilen sınıflandırma modellerinde, bir ocak bek kapağının kusur tespiti süreci, görselin bir CNN'e giriş katmanı aracılığıyla sunulmasıyla başlamaktadır. Bu katman, kapağın dijital görüntüsünü (Eğer bir ocak bek kapağının fotoğrafı 250×250 piksel çözünürlüğünde ve renkli bir görüntü ise, giriş katmanı bu görseli 250 satır, 250 sütun ve 3 renk kanalından (kırmızı, yeşil, mavi) oluşan $250 \times 250 \times 3$ boyutunda bir veri küpü olarak kabul etmektedir.), bilgisayarın anlayabileceği piksel matrisleri şeklinde alır. Bu ilk aşama, kapağın üzerindeki en küçük çizikten en belirgin deformasyona kadar tüm potansiyel kusurların ham piksel verisini sağlar. Ardından, modellerin ImageNet veri kümesi üzerindeki ön eğitimiyle uyum sağlamak amacıyla, her bir piksel değeri OpenCV içerisindeki normalize işleviyle 0 ile +1 aralığına dönüştürür. MobileNetV2 mimarisi ve DenseNet121 bu ham veriyi anlamlı özelliklere dönüştürür. Derinlemesine ayrılabilir evrişimler, standart işlemini iki ayrı adıma bölerek (uzamsal ve kanal bazlı işlem), modellerin hesaplama maliyetini önemli ölçüde düşürür. Tersine çevrilmiş artık bloklar ise, bilgiyi düşük boyutlu bir gösterimden yüksek boyuta genişletip işledikten sonra tekrar düşük boyuta daraltır ve araya atlama bağlantıları ekleyerek bilgi akışını optimize eder. Bu sayede, MobileNetV2 ve DenseNet121 mimarileri kapağın dairesel şekli, yüzey dokusu ve en önemlisi çizikler, çatlaklar veya renk anormallikleri gibi kusurlara özgü ince desenleri başarılı bir şekilde yakalar. Bu özellik çıkarma işleminin ardından, ReLU aktivasyon fonksiyonu, yakalanan özellik sinyallerini keskinleştirerek sadece önemli olanların sonraki katmanlara ilerlemesini sağlar. Elde edilen yüksek seviyeli ve soyut özellikler, modellerin son aşamasına, yani tam bağlantılı katmanlara iletilir. Burada, farklı kusur özelliklerinin kombinasyonları değerlendirilerek, "Eğer bek kapağında belirli bir yüzey kusuru varsa VE bir deformasyon belirtisi varsa, o zaman bu KUSURLUDUR" gibi karmaşık ilişkiler öğrenilir. Nihai sınıflandırma tahmini, Softmax aktivasyon fonksiyonu kullanılan Çıkış Katmanında yapılır. Softmax, tam bağlantılı katmanlardan gelen bilgileri alarak, her bir sınıf ("Kusurlu", "Kusursuz") için bir olasılık değeri üretir. Bu olasılıkların toplamı daima 1'e eşittir. Örneğin, bir bek kapağı için [0,90, 0,10] çıktısı, modelin %90 olasılıkla "Kusurlu" olduğunu ve %10 olasılıkla "Kusursuz" olduğunu düşündüğünü gösterir. Bu olasılık dağılımı sayesinde, sistem bek kapağının durumunu objektif ve nicel bir şekilde belirler.

4. Tartışma ve Sonuç

Çalışmada derin öğrenme tabanlı bir yöntem olan CNN algoritması kullanılmış olup kusurlu ve hatasız ürünlerin sınıflandırmasını yapacak iki farklı mimari geliştirilmiştir. Modeller 30 adım boyunca izlenmiş ve modellerin eğitim ve doğrulama aşamasındaki model doğruluğu ve model kaybı değerleri saklanarak grafiğe aktarılmıştır. Şekil 6 ve Şekil 7'de sırası ile MobileNetv2 mimarisi ve DenseNet121 mimarisine ait sonuçlar verilmektedir. Doğruluk ve kayıp grafiklerinde eğitim verisine ait sonuçlar mavi, doğrulama verisine ait sonuçlar ise turuncu eğri ile belirtilmiştir. Toplam eğitim süreleri (veri çoğaltma adımı dahil) MobileNetV2 mimarisi için 840 sn. iken DenseNet121.mimarisi için 912 saniyedir. Bu durum DenseNet121'in daha karmaşık yapısına göre beklenen bir sonuçtur.



Şekil 6. MobileNetV2 ile oluşturulan modelin eğitim ve doğrulama aşamasındaki doğruluk ve kayıp grafikleri




Şekil 7. DenseNet121 modelinin eğitim ve doğrulama aşamasındaki doğruluk ve kayıp grafikleri

MobileNetV2 mimarisinde, eğitim doğruluğu ilk birkaç epokta hızlı bir artış göstermiş ve 5. epok civarında %85 seviyelerine ulaşmıştır. Daha sonraki epoklarda doğruluk değerleri %90 civarında sabitlenmiş, doğrulama doğruluğu ise benzer şekilde %88–89 aralığında kararlı bir seyir izlemiştir. Eğitim ve doğrulama eğrilerinin birbirine yakın ilerlemesi, modelin genelleme yeteneğinin yüksek olduğunu ortaya koymaktadır. Ayrıca eğitim ve doğrulama kayıplarının benzer oranlarda azalması, modelin eğitim sürecinde istikrarlı bir öğrenme gerçekleştirdiğini göstermektedir. DenseNet121 mimarisi de benzer bir şekilde erken epoklarda hızlı bir öğrenme göstermiş, doğruluk oranları %88–91 aralığında seyretmiştir. Ancak doğrulama doğruluğundaki küçük dalgalanmalar, modelin yüksek karmaşıklığı nedeniyle veri setine karşı daha hassas tepki verdiğini ve sınırlı veri koşullarında kısmen aşırı uyum eğilimi gösterebildiğini düşündürmektedir. Bununla birlikte, doğrulama kaybının eğitim kaybına yakın seyretmesi, aşırı öğrenmenin belirgin bir problem oluşturmadığını da göstermektedir. Genel olarak her iki model de yüksek sınıflandırma başarısı sergilemiş; ancak MobileNetV2, daha az parametrelili ve hesaplama açısından daha verimli bir mimari olmasına rağmen DenseNet121 ile benzer doğruluk oranlarına ulaşarak veri seti için daha uygun bir yapı ortaya koymuştur.

Bununla birlikte, her iki modelde de dikkat edilmesi gereken bazı sınırlılıklar mevcuttur. Eğitim ve doğrulama doğruluklarının birbirine yakın seyretmesine rağmen doğrulama eğrilerinde görülen dalgalanmalar, veri setinin görece sınırlı boyutundan kaynaklanan hafif bir aşırı uyum riski olduğu şeklinde de yorumlanabilir. Özellikle DenseNet121 mimarisinin yüksek parametre sayısı, küçük veri kümelerinde modelin gürültüye duyarlılığını artırarak genel performansın istikrarsızlaşmasına neden olabilir. Ayrıca, eğitim kaybının belirli bir noktadan sonra azalmaya devam etmesine karşın doğrulama kaybının daha sınırlı bir iyileşme göstermesi, modelin erken durdurma kriterine yaklaşmış olabileceğini de düşündürmektedir.

Modellerin test aşaması başarısını anlayabilmek için daha önce hiç görmedikleri yeni görüntüler üzerinde nasıl bir tahmin başarısı sergilediğini ortaya koymak amacı ile karışıklık matrisleri Şekil 8’de verilmiştir. MobileNetV2 ve DenseNet121 modellerine ait karışıklık matrisleri incelendiğinde, her iki modelin de kusurlu ve hatasız ürünleri büyük oranda benzer şekilde doğru şekilde sınıflandırdığı görülmektedir. Her iki modelde de TP ve TN değerlerinin yüksek, FP ve FN değerlerinin bu değerlerden düşük olması, modelin hem duyarlılık (recall) hem de özgüllük (specificity) açısından dengeli bir performans gösterdiğini ortaya koymaktadır.

DenseNet121 modelinde, MobileNetV2’ye nazaran yanlış pozitif sayısının (14) daha fazla olduğu gözlenmiştir. Böyle bir durum, DenseNet121 modelinin daha derin ve karmaşık yapısının küçük veri kümelerinde tam genelleme yapamamasından kaynaklanabilir. Yanlış pozitif durumları, üretim sürecinde gereksiz ayıklama veya yeniden işleme maliyetlerine yol açabilir. Ayrıca her iki modelde de FN değeri 26 olarak bulunmuştur ki bu durum modelin bazı kusurlu ürünleri hatasız olarak tanımladığı anlamına gelmektedir. Yanlış negatif durumlar kalite güvence açısından daha kritik bir hata türüdür, çünkü hatalı ürünün üretim hattından geçmesine neden olabilir. Bu tür hatalar, modelin belirli kusur tiplerinde daha düşük ayırt etme gücüne sahip olabileceğini düşündürülebilir. Şekil 8’de modellere bu bakış açısı ile bakıldığında MobileNetV2 mimarisi daha düşük FN oranı ile daha başarılı olmuştur.



Şekil 8. MobileNetV2 ve DenseNet121 karışıklık matrisleri


Tablo 1’de karışıklık matrisleri sonuçlarına göre elde edilen hassasiyet (precision), duyarlılık ve F1 skoru değerleri görülmektedir. Buradan anlaşıldığı üzere modellerde daha yüksek hassasiyet varken duyarlılık değerleri nispeten düşüktür. Bu durum modellerin bazı kusurlu ürünleri kaçırabileceğine işaret eder. Bu nedenle çoğu çalışmada ikisi arasındaki dengeyi gösteren F1-score kullanılır. F1 skoru değerine göre hatalı ürün tespitinde her iki model de 0,90 oranı ile başarılı iken, hatasız ürünler de MobileNetV2 mimarisi daha başarılıdır.

Tablo 1. MobilNetV2 ve DenseNet121 mimarilerine ait hatalı ve hatasız sınıf performans metrikleri

	MobileNetV2			Densenet121		
	Hassasiyet	Duyarlılık	F1-score	Hassasiyet	Duyarlılık	F1-score
Hatalı	0,94	0,87	0,90	0,92	0,87	0,90
Hatasız	0,89	0,95	0,92	0,89	0,94	0,91

Şekil 9’da MobileNetV2 ve DenseNet121 modellerine ait ROC eğrisi gösterilmektedir. Eğrinin sol üst köşeye (TPR=1, FPR=0) yakın olması, modelin hem yüksek duyarlılığa hem de düşük hata oranına sahip olduğunu göstermektedir. MobileNetV2 ve DenseNet121 modelleri için elde edilen AUC değerleri sırası ile 0,96 ve 0,97 olup, bu değerler modelin pozitif ve negatif sınıfları ayırt etme kabiliyetinin oldukça yüksek olduğunu göstermektedir. AUC’nin 1,0’a yakın olması, modelin kusurlu ve hatasız ürünleri yüksek doğrulukla ayırabildiğini; yani rastgele tahminde bulunmadığını ve sınıflandırma performansının güvenilir olduğunu ortaya koymaktadır. Yüksek AUC değeri, modelin yalnızca doğruluk oranı açısından değil, duyarlılık ve özgüllük dengesini de başarılı bir şekilde koruduğunu göstermektedir. Özellikle üretim sürecinde kusurlu ürünlerin yanlışlıkla hatasız olarak sınıflandırılması ciddi kalite sorunlarına yol açabileceğinden, bu denge endüstriyel kalite kontrol uygulamaları açısından büyük önem taşımaktadır.

AUC değerinin yüksek olmasına rağmen, ROC eğrisinin bazı bölümlerinde doğrusal eğilimden küçük sapmalar gözlenmektedir. Bu durum, modellerin belirli örneklerde düşük güven skorlarıyla karar verdiğini ve karar eşiklerinin optimize edilmesiyle performansın daha da iyileştirilebileceğini düşündürmektedir. Özellikle gerçek üretim ortamlarında değişken ışık koşulları, yansımalar ve yüzey dokuları gibi faktörler göz önüne alındığında, ROC performansının bu tür çevresel koşullarda yeniden test edilmesi yararlı olabilir. Tablo 2’de ise her iki mimarinin de tüm test setindeki sınıflandırma performans metrikleri verilmiştir.



Şekil 9. MobileNetV2 ve DenseNet121 mimarilerine ait ROC eğrileri

Tablo 2. MobilNetV2 ve DenseNet121 mimarilerine ait test aşaması performans metrikleri

Model	Test Doğruluğu	ROC-AUC	F1-Skoru
MobileNetV2	0,912	0,965	0,921
DenseNet121	0,906	0,971	0,914

Elde edilen sonuçlar, geliştirilen derin öğrenme tabanlı kalite kontrol modellerinin üretim sürecinde kusurlu ve kusursuz ürünleri yüksek doğrulukla ayırt edebildiğini göstermektedir. MobileNetV2 modeli %91,2 test doğruluğu, 0,965 ROC-AUC ve 0,921 F1-skoru ile en yüksek genel performansı sergilemiştir. DenseNet121 modeli ise %90,6 doğruluk, 0,971 ROC-AUC ve 0,914 F1-skoru değerleriyle benzer bir başarı göstermiştir. MobileNetV2 modeli, test doğruluğu ve F1-skoru ile genel sınıflandırma başarısı bakımından DenseNet121'e kıyasla bir miktar üstün performans sergilemiştir. Buna karşın DenseNet121'in 0,971'lik ROC-AUC değeri, sınıflar arasındaki ayrımı daha net yapabildiğini göstermektedir. Bu durum, MobileNetV2'nin genel doğruluk açısından, DenseNet121'in ise ayırım duyarlılığı açısından avantajlı olduğunu ortaya koymaktadır. Dolayısıyla, uygulamanın önceliklerine bağlı olarak her iki mimarinin de farklı koşullarda tercih edilebileceği söylenebilir. MobileNetV2, daha hafif yapısı ve hızlı çıkarım süresi nedeniyle üretim hattına entegre edilmek için daha uygun bir seçenek olarak değerlendirilebilir. Geliştirilen MobileNetV2 ve DenseNet121 modelleri, metal endüstrisine yönelik literatürdeki benzer görüntü işleme tabanlı çalışmalarla karşılaştırıldığında rekabetçi ve tutarlı performans sergilediği Tablo 3'te görülmektedir. Literatürdeki çalışmaların büyük çoğunluğunda daha yüksek veri setleri ile çalışılmıştır. DenseNet121 mimarisi, ROC-AUC değeri bakımından 0,971 ile yüksek ayırt etme gücü göstermiştir. MobileNetV2 modeli ise %91,2 test doğruluğu ile literatürdeki çalışmaların çoğu ile benzer ya da yüksek sonuç elde etmiştir. Bu bulgular, önerilen yaklaşımların, sınırlı veri setleriyle dahi yüzey hatalarının tespiti için etkili çözümler sunabildiğini göstermektedir.

Tablo 3. Metal endüstrisi odaklı benzer çalışmalarla model performanslarının karşılaştırılması

Çalışma	Kullanılan Mimari	Veri Seti	Performans
Bayram [17]	Morfolojik işlemler ve Hough dönüşümü	26	89 Doğruluk
Parlak [18]	CNN (YOLOv5)	47 500	97 (mAP)
Güçlü vd. [19]	CNN (YOLOv7)	6000	76,3 (mAP)
Selamet [20]	SFS ve Faster R-CNN	3335	83 Doğruluk
Gökkaya [21]	Faster R-CNN	2000	90 Doğruluk
Konovalenko vd. [22]	U-Net CNN	9385	91,3 Doğruluk
Leng ve Liu [27]	Faster R-CNN	1800	80,2 (mAP)
Citlak ve Pillay [28]	Mask R-CNN	330 000	98 Doğruluk

Özyer ve Taşpınar [31]	ResNet50	285	90,2 F1 Skoru
Yapılan Çalışma	CNN- MobileNetV2	2826	91,2
Yapılan Çalışma	CNN- DenseNet121	2826	90,6

Bu çalışma, görüntü işleme tekniklerinin modern kalite kontrol süreçlerinde ne denli kritik ve başarılı bir rol oynayabileceğini ortaya koymaktadır. Geleneksel denetim yöntemlerinin aksine, derin öğrenme tabanlı bu yaklaşım, ürünlerdeki "hatalı" ve "hatasız" durumlarını yüksek doğrulukla ayırt etme olanağı sunar. Ayrıca bu modeller, IoT (Internet of Things) tabanlı bir otomatik kusur tespit sisteminin ilk aşaması olabilme özelliğine de sahiptir. MobileNetV2 gibi hafif yapılı bir CNN mimarisinin veya DenseNet121 gibi daha karmaşık yapılı bir CNN mimarisinin transfer öğrenme ile kullanılması, modellerin karmaşık görsel özellikler etkin bir şekilde öğrenmesini ve genelleme yapabilmesini sağlamıştır. Özellikle, küçük boyutlu hataların veya ince kusurların insan gözüyle tespitinin zorlaştığı durumlarda, bu tür bir otomatik sistem tutarlılık, hız ve nesnellik sağlayarak üretim hattında verimliliği artırabilir ve insan hatasını minimize edebilir. Dolayısıyla, bu çalışma, görüntü işlemenin endüstriyel kalite kontrol alanında güvenilir ve başarılı bir çözüm olarak kullanılabileceğine dair somut bir örnektir.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. İlk olarak, kullanılan veri setinin boyutu görece küçük olup, özellikle farklı kusur tiplerini temsil eden örneklerin sınırlı olması modelin genelleme kabiliyetini kısmen etkilemiştir. Veri artırma yöntemleri ile bu eksiklik azaltılmaya çalışılmış olsa da daha geniş ve çeşitlendirilmiş bir veri setiyle modelin performansının artırılacağı değerlendirilmektedir. Ayrıca, ürün kalite kontrolü amacıyla tasarlanan sistemlerde FN oranının yüksek olması, doğrudan müşteri memnuniyetsizliği, ürün iadeleri, ek maliyetler ve marka itibarı kaybı gibi önemli iş riskleri doğurabilmektedir. Bu nedenle, modelin FN oranını düşürmek, pratik uygulamalarda güvenilirlik ve kabul edilebilirlik açısından büyük önem taşımaktadır. Gelecek çalışmalarda, daha gelişmiş mimariler, daha dengeli veya daha büyük veri setleri ya da hata türlerine özel odaklanan eğitim stratejileri ile FN oranının minimize edilmesi hedeflenmelidir. Veri setinde yalnızca kusurlu-kusursuz ayrımının ötesine geçilerek kusur tiplerinin sınıflandırılacağı modellerin geliştirilmesi sayesinde geri işlenebilir parçaların ayrımı da sağlanabilir. Bunun yanı sıra, özellik çıkarımında performans artırmak için batch normalization gibi tekniklerin kullanımı değerlendirilebilir. Ayrıca, görüntü işleme aşamasında farklı derin öğrenme mimarilerinin (ör. YOLOv8, EfficientNet vb.) kullanımı ve hiperparametre optimizasyonu yapılmasıyla daha başarılı sonuçlar elde edilebilir.

İkinci olarak, sistemin tüm aşamaları bilgisayar ortamında yürütülmüş ve gerçek üretim hattı koşullarında tam entegrasyon sağlanmamıştır. Gelecekte, gerçek zamanlı IoT tabanlı sistemlerin tasarlanmasıyla kusurlu ürün tespitinin eş zamanlı yapılması ve bu sayede kalitesizlik maliyetinin minimize edilmesi hedeflenebilir. Gerçek zamanlı uygulamalarda değişken aydınlatma, yansıma, kamera pozisyonu gibi çevresel faktörlerin model performansı üzerinde etkili olabileceği öngörülmektedir. Üçüncü olarak, MobileNetV2 gibi mimariler gömülü sistemlere uygun hafif bir yapı sunsa da üretim hattı üzerindeki donanım kısıtları (GPU kapasitesi, veri aktarım hızı vb.) gerçek zamanlı çıkarım hızını sınırlayabilir. Bu sınırlılıkların giderilmesi amacıyla gelecekteki çalışmalarda, donanım hızlandırıcıların (ör. FPGA, TPU) kullanımıyla gerçek zamanlı entegrasyonun test edilmesi planlanmaktadır.

Kaynaklar

- [1] Orman S, Tiryaki F, Ulusoy A. Görüntü işleme uygulamalarıyla otomatik kalite kontrol sistemleri: Derin öğrenme tabanlı bir inceleme. Mühendislik Bilimleri Dergisi 2021; 27(2): 97–106.
- [2] Çelik H, Tekin M. Endüstriyel görüntü işlemede otomasyon sistemlerinin yeri. Sanayi ve Teknoloji Dergisi 2020; 14(1): 33–40.
- [3] Szeliski R. Computer Vision: Algorithms and Applications. Berlin, Germany: Springer, 2011.
- [4] Çelik H, Tekin M. Otomotiv sektöründe boya kusurlarının tespiti için görüntü işleme tabanlı yaklaşım. İmalat Teknolojileri Dergisi 2020; 15(3): 245–252.
- [5] Erdoğan M, Alıcı E. Tekstil iplik kusurlarının CNN destekli görüntü işleme ile tespiti. Uygulamalı Yapay Zekâ Dergisi 2021; 3(1): 17–25.
- [6] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. In: NIPS; 2012. pp. 1097–1105.
- [7] Goodfellow I, Bengio Y, Courville A. Deep Learning. Cambridge, MA, USA: MIT Press, 2016.
- [8] Başaran E, Cömert Z, Şengür A. Evrimsel sinir ağları ile orta kulak hastalıklarının tespiti. Bilgisayar Bilimleri Dergisi 2020; 13(1): 1–10.
- [9] Görgel P, Kavlak E. Rüzgar enerjisi üretiminde CNN-LSTM tabanlı tahmin modeli. Dicle Üniversitesi Mühendislik Dergisi 2020; 11(1): 69–80.

- [10] Değirmenciler A, Cengiz B, İleri K. COVID-19 için CNN tabanlı maske takma denetimi. *Mühendislik Araştırmaları Dergisi* 2022; 4(2): 259–265.
- [11] Türkdamar MU, Taşyürek M, Öztürk C. İnşaat sahalarında kask takma kontrolü için derin öğrenme uygulaması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi* 2023; 12(1): 39–51.
- [12] Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. MobileNetV2: Inverted residuals and linear bottlenecks. In: *CVPR*; 2018. pp. 4510–4520.
- [13] Çelik Y, Dengiz B, Güney S. Ahşap ham maddelerde yüzey hatasını belirlemek için görüntü işleme tabanlı kalite kontrol sistemi. *Mühendislik Bilimleri ve Tasarım Dergisi* 2023; 11(4): 1365–1382.
- [14] Pınar Z, Gülağz FK, Altuncu MA, Şahin S. Denim kumaşlarda görüntü işleme ile hata tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi* 2020; 9(4): 1609–1620.
- [15] Köse F. Dişli çark hatalarının görüntü işleme yöntemleri ile ölçümü. 2005.
- [16] Örs ME, Özçelik Z. Görüntü işleme ve derin öğrenme ile kaynak hatalarının gerçek zamanlı tespiti. *DCE Doğa Bilimleri Dergisi* 2025; 5(2): 83–97.
- [17] Bayram RB. Metal sektörü için görüntü işleme tabanlı bir kusurlu ürün tespit sistemi. Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi, 2019.
- [18] Parlak İE. Alüminyum döküm hatalarının derin öğrenme yaklaşımıyla tespiti ve sınıflandırılması. Doktora Tezi, Bursa Uludağ Üniversitesi, 2022.
- [19] Güçlü E, Aydın İ, Şener TK, Akın E. Çelik yüzeylerdeki kusurların tespiti için derin öğrenme tabanlı gömülü sistem tasarımı. *EMO Bilimsel Dergi* 2022; 12(2): 27–33.
- [20] Selamet F. Derin öğrenme yöntemleri ile metalik yüzeylerde kusur tespiti ve sınıflandırılması. 2023.
- [21] Gökkaya H. Derin öğrenme teknikleri ile anomali içeren metal somunların hata tespit ve sınıflandırılması. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, 2020.
- [22] Konovalenko I, Maruschak P, Brezinová J, Prentkovskis O, Brezina J. Research of U-Net-based CNN architectures for metal surface defect detection. *Machines* 2022; 10(5): 327.
- [23] Lin HI, Wibowo FS. Image data assessment approach for deep learning-based metal surface defect-detection systems. *IEEE Access* 2021; 9: 47621–47638.
- [24] Chouhad H, El Mansori M, Knoblauch R, Corleto C. Smart data driven defect detection method for surface quality control in manufacturing. *Measurement Science and Technology* 2021; 32(10): 105403.
- [25] Balçioğlu YS, Sezen B, Çerasi CC, Huang SH. Machine design automation model for metal production defect recognition with deep graph convolutional neural network. *Electronics* 2023; 12(4): 825.
- [26] Nguyen TP, Choi S, Park SJ, Park SH, Yoon J. Inspecting method for defective casting products with CNN. *Int J Precision Eng Manufacturing-Green Technology* 2021; 8(2): 583–594.
- [27] Leng Y, Liu J. Improved Faster R-CNN for steel surface defect detection in industrial quality control. *Scientific Reports* 2025; 15(1): 30093.
- [28] Citlak T, Pillay N. Real-time object classification on an enamel paint coating conveyor line using mask R-CNN. *Automation* 2024; 5(3): 213–229.
- [29] Bridges LW, Mort N. New approaches to on-line quality control for enamelled wire manufacture. *Control Engineering Practice* 1998; 6(11): 1397–1403.
- [30] Özcan H, Gençtürk HT, Genç G, Yıldırım TE, Durmuş F, Gürleyen A. Gerçek zamanlı kusur tespiti: LPG tüplerinde görüntü işleme ve makine öğrenimi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi* 2024; 24(2): 330–340.
- [31] Özyer B, Taşpınar YS. Realising quality control of metal products used in industry through deep learning. *Intelligent Methods in Engineering Sciences* 2024; 3(4): 118–125.
- [32] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015; 521(7553): 436–444.
- [33] Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems* 2021; 33(12): 6999–7019.
- [34] Poojitha V, Baskar R. Improving the accuracy of detecting rice leaf disease using DenseNet algorithm comparing it with MobileNet algorithm. In: *International Conference on Trends in Quantum Computing and Emerging Business Technologies*; March 2024. IEEE. pp. 1–5.
- [35] Melyani NA, Lubis AF, Tatamara A, Haiban RR, Iltizam M, Rofiqi MA, Ismail MI. Analysis comparison classification image disease eye using the CNN algorithm, Inception V3, DenseNet 121 and MobileNet V2 architecture models. *Public Research Journal of Engineering, Data Technology and Computer Science* 2025; 3(1): 42–58.
- [36] Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. *Journal of Big Data* 2019; 6(1): 1–48.
- [37] Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Adam H. MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017.
- [38] Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*; 2017. pp. 4700–4708.
- [39] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research* 2014; 15(1): 1929–1958.
- [40] Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters* 2006; 27(8): 861–874.