

Görüntü İşleme ve Derin Öğrenme ile Kaynak Hatalarının Gerçek Zamanlı Tespiti

Automatic Detection of Welding Defects Using Image Processing and Deep Learning

Mehmet Emin ÖRS^{1*}, Ziya ÖZÇELİK²

¹AYD Otomotiv Endüstri, Konya, TÜRKİYE

²Selçuk Üniversitesi Teknoloji Fakültesi Mekatronik Mühendisliği, Konya, TÜRKİYE

Başvuru/Received: 29/11/2024

Kabul / Accepted: 24/12/2024

Çevrimiçi Basım / Published Online: 30/03/2025

Son Versiyon/Final Version: 03/03/2025

Öz

Bu çalışmada, Convolutional Neural Networks (CNN) tabanlı bir model geliştirilerek kaynak kusurlarının tespitinde %93,5 doğruluk ve %91,3 F1-skoru ile oldukça iyi bir performans elde edilmiştir. Modelin başarısı, 800 yüksek çözünürlüklü görüntüden oluşan veri setinin %80 eğitim ve %20 test için ayrılarak, gürültü giderme ve segmentasyon gibi ön işleme teknikleriyle optimize edilmesiyle sağlanmıştır. Transfer öğrenme teknikleri, küçük veri setlerinde dahi performansı artırmış; 0,25 saniyelik analiz süresi, modelin gerçek zamanlı uygulamalarda kullanılabilirliğini kanıtlamıştır. DenseNet, YOLOv5 ve ResNet gibi popüler mimarilerle çalışmada kullanılan model karşılaştırılmıştır. Geleneksel yöntemlere kıyasla %15 doğruluk artışı ve işlem süresinde yarı yarıya azalma sağlanmıştır. Bu sistem, Endüstri 4.0 kapsamında otomatik kalite kontrol süreçlerine yeni bir standart getirmekte ve özellikle otomotiv, havacılık gibi sektörlerde uygulanabilirliği ile öne çıkmaktadır.

Anahtar Kelimeler: Evrişimli Sinir Ağları (CNN), Kaynak Hatası Tespiti, Transfer Öğrenimi, Gerçek Zamanlı Uygulamalar, Otomatik Kalite Kontrol, Endüstri 4.0

Abstract

This study developed a model based on Convolutional Neural Networks (CNNs) to achieve good performance for weld defect detection with 95.3% accuracy and 91.3% F1-score. The model's success was achieved by optimizing the dataset of 800 high-resolution images with preprocessing techniques such as noise removal and segmentation, separating 80% for training and 20% for testing. Transfer learning techniques improved performance even on small datasets, and the analysis time of 0.25 seconds proved the usability of the model in real-time applications. The base model in this work is compared with popular architectures such as DenseNet, YOLOv5, and ResNet. Compared to traditional methods, a 15% increase in accuracy and a halving in processing time were achieved. This system brings a new standard to automated quality control processes within the scope of Industry 4.0 and stands out with its applicability, especially in sectors such as automotive and aviation.

Key Words: Convolutional Neural Networks (CNN), Weld Defect Detection, Transfer Learning, Real-Time Applications, Automated Quality Control, Industry 4.0

1. Giriş

Kaynak kusurlarını tespit etme süreçleri, kalite kontrol, maliyet azaltımı ve üretim verimliliğini artırma açısından kritik öneme sahiptir. Geleneksel yöntemler genellikle insan gözlemine dayalıdır ve bu durum doğruluk ve hız açısından sınırlamalar getirmektedir. Bu bağlamda, derin öğrenme ve görüntü işleme teknikleri yeni nesil çözümler sunmaktadır. Derin öğrenme modelleri, özellikle Convolutional Neural Networks (CNN) gibi mimariler, görüntü segmentasyonu ve kusur sınıflandırmasında etkili sonuçlar sağlamıştır. Zhang ve arkadaşları (2019), kalın plakaların disk lazer kaynağı sırasında birden fazla optik sensör kullanarak kaynak kusurlarının tespiti için derin öğrenme tabanlı bir yöntem geliştirmişlerdir. Bu yöntem, hata algılamada doğruluk ve güvenilirliği artırmıştır. Sahman ve arkadaşları (2019), Bu çalışmada, Tree-Seed Algoritması (TSA) kullanılarak gerçek hayat optimizasyon problemlerinin çözümüne yönelik bir yaklaşım sunulmuştur. TSA, karmaşık optimizasyon problemlerinde yüksek verimlilik göstermekte ve özellikle mühendislik uygulamalarında tercih edilen yenilikçi bir yöntem olarak öne çıkmaktadır. Modelin performansı, farklı optimizasyon senaryolarında test edilmiş ve geleneksel yöntemlere kıyasla önemli bir iyileşme sağladığı gösterilmiştir. Bu çalışma, parametre optimizasyonu veya model performansının artırılması gereken derin öğrenme tabanlı yaklaşımlarda referans alınabilir. Atıcı ve arkadaşları (2023), Çalışmada, Mask R-CNN tabanlı bir model kullanılarak kan yayma görüntülerinin segmentasyonu ve sınıflandırılması gerçekleştirilmiştir. Model, karmaşık görsel verilerde yüksek hassasiyetle segmentasyon sağlayarak nesne sınırlarını başarılı bir şekilde tespit etmektedir. Önerilen yöntem, biyomedikal görüntüleme alanında doğruluk oranını artırmakta ve segmentasyon tekniklerinin derin öğrenme modelleriyle entegrasyonuna örnek oluşturmaktadır. Bu çalışma, kaynak kusurlarının tespiti için derin öğrenme tabanlı segmentasyon tekniklerinin etkinliğini vurgulamak adına önemli bir referans oluşturmaktadır. Çevik ve arkadaşları(2022), derin öğrenme yöntemleri kullanarak yumurta döllülük tespiti gerçekleştirmiştir. Veri seti üzerinde uygulanan ön işleme teknikleri sayesinde modelin performansı optimize edilmiş ve yüksek doğruluk oranlarına ulaşılmıştır. Çalışma, derin öğrenme modellerinin görsel verilerde nesne tespiti ve sınıflandırma görevlerinde etkin bir şekilde kullanılabileceğini göstermektedir. Bu yöntem, endüstriyel kalite kontrol süreçlerinde, özellikle otomatik hata tespiti ve sınıflandırma gibi uygulamalarda, derin öğrenme tekniklerinin başarıyla uygulanabilirliğini desteklemektedir. Sun ve arkadaşları (2019), makine görmesi teknikleriyle kaynak kusurlarının algılanması ve sınıflandırılmasını sağlayan bir yöntem önererek %95'in üzerinde doğruluk sağlamışlardır. Kang ve Ku (2019), direnç kaynak kalitesinin dinamik özelliklerine dayalı olarak derin öğrenme ile tahmin edilmesini sağlayan bir yöntem geliştirmiştir Xia ve arkadaşları (2020), Keyhole TIG kaynağı sırasında görsel açıklamalar sunabilen derin öğrenme tabanlı bir hata tespit yöntemi geliştirmiştir. Li ve arkadaşları (2020), derin öğrenme tabanlı bir algoritma geliştirerek kaynak hatalarını otomatik olarak tespit etme ve sınıflandırma süreçlerinde geleneksel yöntemlerden daha iyi sonuçlar elde etmişlerdir. Cheng ve arkadaşları (2021), YOLO çerçevesini kullanarak kaynak hatalarını tespit etmede %75,5 mAP başarımını ortaya koymuşlardır. Rabe ve arkadaşları (2021), Sürtünme Karıştırma Kaynağı'nda kuvvet geri besleme verilerini kullanan CNN ve LSTM modelleri ile %93 üzerinde sınıflandırma doğruluğu sağlamıştır. Zuo ve arkadaşları (2021), YOLO çerçevesiyle %71 tespit doğruluğu sunan otomatik kaynak hata tespit sistemi geliştirmiştir. Ma ve arkadaşları (2021), görsel algı destekli bir yöntemle kaynak hatalarını %98,15 doğruluk oranıyla tespit etmiştir. Walther ve arkadaşları (2022), lazer kaynak sırasında kaynak süreksizliklerini derin öğrenme modelleriyle %95'in üzerinde doğruluk oranıyla tahmin etmişlerdir. Lee ve arkadaşları (2022), nükleer enerji santralleri gibi kritik alanlarda otomatik kaynak birleşimi tespiti için bir sistem geliştirmiştir. Tyystjärvi ve arkadaşları (2022), havacılık sektöründe dijital radyografi ile kaynak hatalarını tespit etmek için semantik segmentasyon ağı kullanmıştır. Jia ve ark. (2024), X-ray görüntüleme tekniklerini ve CNN tabanlı modelleri kullanarak %96 doğruluk oranı ile kaynak kusurlarını başarılı bir şekilde tespit etmişlerdir. Bu çalışmada kullanılan yöntemler, akıllı sensörlerin entegrasyonu ile yapay zekâ destekli kalite kontrol sistemlerine önemli bir katkı sunmaktadır. Benzer bir çalışmada, TIG kaynağına özgü radyografik görüntüler işlenmiş ve HDR kameraların entegrasyonu ile derin öğrenme modellerinin performansı artırılmıştır (Bansal ve ark., 2025). Özellikle AA 6063-MgAZ31B alaşımında kusurların sınıflandırılması, endüstriyel uygulamalara ışık tutmaktadır. Chen ve ark. (2024), YOLOv5 algoritmasını deformasyonlu CNN yapıları ile birleştirerek segmentasyon teknikleri kullanmış ve kaynak dikişi kusurlarının tespitini optimize etmişlerdir. Bu yöntem, görüntü işleme süreçlerinde gürültü azaltmayı içeren

ön işleme adımlarıyla desteklenmiştir. Benzer bir şekilde, video analitik sistemler kullanılarak gerçek zamanlı kaynak kusuru tespitine odaklanan bir model %95 doğruluk oranı ile üstün performans sergilemiştir (Pavlov ve ark., 2024). Küçük veri setleri ile çalışmak zorunda kalan uygulamalarda transfer öğrenme büyük avantaj sağlamaktadır. Örneğin, direnç nokta kaynağı kusurlarının tespiti için Faster R-CNN modeli transfer öğrenme ile optimize edilmiş ve bu sayede yüksek doğruluk oranlarına ulaşılmıştır (Liu ve ark., 2024). Aynı şekilde, bakır bağlantılarındaki kaynak kusurlarını tespit etmek için sıcaklık dağılımı verileri kullanan bir başka çalışma, CNN tabanlı modelin doğruluk ve hassasiyetini artırmıştır (Lee ve ark., 2024). Han ve ark. (2024), YOLO tabanlı bir yaklaşımda Phased Array Ultrasonik Test (PAUT) yöntemlerini kullanmış ve bu teknik YOLO algoritması ile birleştirilerek %97 doğruluk oranı elde etmişlerdir. Kokolakis ve ark. (2024) tarafından Volvo fabrikasında gerçekleştirilen bir başka çalışmada, lazer lehimleme işlemleri sırasında transfer öğrenme ve gürültü giderme teknikleri bir araya getirilerek kusur tespit modelleri daha da güçlendirilmiştir. Ma ve ark. (2024), akustik emisyon verilerinin derin öğrenme ile entegrasyonunu, kaynak sırasında meydana gelen hasarların tespitinde önemli bir yenilik olarak sunmuştur. Bu yöntem, yalnızca görsel verilerle sınırlı kalmayıp, akustik verileri de işleyerek çok yönlü bir analiz sunmaktadır. Ren ve ark. (2024), TOFD görüntüleri üzerinde YOLOv8 algoritmasını kullanarak kaynak kusurlarının hızlı ve doğru bir şekilde tespit edilmesini sağlamıştır. Bu çalışmada, Convolutional Neural Networks (CNN) tabanlı bir model geliştirilerek kaynak kusurlarının tespitine yönelik bir analiz gerçekleştirilmiştir. Kaynak yapan bir sistemin resmi Şekil 1’ de verilmiştir. Bu resimde kaynak kanalı kameraya göre konumlandırılmıştır. Çalışmada kullanılan veri seti, açık kaynaklı bir platformdan alınmış olup kaynaklı metal yüzeylerindeki kusurların etiketlenmiş görüntülerini içermektedir. Bu tür veri setleri, derin öğrenme algoritmalarının eğitilmesi ve kalite kontrol sistemlerinde otomasyonun artırılması için kritik bir rol oynar. Veri setinde yer alan kusurlar; çelik, alüminyum, titanyum ve kompozit malzemelere özgü olup, genellikle ISO 6520-1 standardına göre sınıflandırılmıştır. Yaygın olarak tespit edilen kusurlar arasında porozite, çatlaklar, çukurlaşma, cüruf kalıntıları, kök kusurları ve çapaklar bulunmaktadır. Modelin eğitimi için 800 yüksek çözünürlüklü görüntüden oluşan veri seti kullanılmış ve bu veri setinin %80’i eğitim, %20’si test amacıyla ayrılmıştır. Modelin başarısını optimize etmek için öncelikle gürültü giderme ve segmentasyon gibi ön işleme teknikleri uygulanmıştır. Gürültü giderme, kaynak görüntülerindeki parazitlerin temizlenmesi amacıyla uygulanmış ve görüntü kalitesinin artırılmasını sağlamıştır. Bu adımda, Gaussian Blur, Median Filter ve Bilateral Filter algoritmaları kullanılmıştır. Gaussian Blur yöntemi, yüksek frekanslı parazitleri yumuşatarak görüntüyü pürüzsüzleştirirken, Median Filter tuz-biber tipi gürültüyü temizlemede etkili olmuştur. Bilateral Filter ise kenar ayrıntılarını koruyarak parazitleri azaltmak için tercih edilmiştir. Segmentasyon, görüntülerin bölümlere ayrılması ve kusur bölgelerinin doğru şekilde tespit edilmesini amaçlamıştır. Bu süreçte Otsu Eşikleme, Canny Kenar Algılama ve Watershed Segmentasyonu gibi geleneksel yöntemlerin yanı sıra, U-Net veya Mask R-CNN gibi derin öğrenme tabanlı teknikler uygulanmıştır. Segmentasyon sonucunda elde edilen "odaklanmış veri", modelin kusur bölgelerini daha net öğrenmesini sağlayarak modelin genelleme performansını artırmıştır. Gürültü giderme ve segmentasyon tekniklerinin uygulanması, modelin eğitim sürecindeki doğruluğunu önemli ölçüde artırmış ve yanlış tahminlerin önüne geçmiştir. Özellikle bu adımlar, DenseNet, YOLOv5 ve ResNet gibi popüler modellerin performansının optimize edilmesine katkı sağlamıştır. DenseNet, karmaşık örüntüleri öğrenme kapasitesi sayesinde %97,1 doğruluk ve %96,8 F1-skoru ile en yüksek performansı sergilemiştir. Ancak, yüksek hesaplama maliyeti nedeniyle gerçek zamanlı uygulamalarda sınırlamalar göstermektedir. Buna karşılık, YOLOv5 modeli %96,7 doğruluk ve %95,3 F1-skoru ile hızlı işleme kapasitesi ve yüksek hassasiyet sağlayarak gerçek zamanlı tespit senaryolarında etkili bir çözüm sunmaktadır. ResNet ise %95,4 doğruluk ve %94,1 F1-skoru ile performans açısından DenseNet ve YOLOv5’in gerisinde kalsa da, düşük hesaplama maliyeti ve mimari sadeliğiyle orta ölçekli uygulamalar için avantaj sağlamaktadır. Ayrıca, temel CNN modeli %93,5 doğruluk ve %91,3 F1-skoru ile daha düşük bir performans göstermiştir; ancak hesaplama verimliliği açısından başlangıç düzeyindeki projeler için uygun bir seçenek olmuştur. Bu çalışma, derin öğrenme modellerinin kaynak kusurlarının tespitindeki potansiyelini kapsamlı bir şekilde ortaya koymaktadır. Gürültü giderme ve segmentasyon adımları, modelin başarısını artırmakta ve verinin kalitesini optimize etmektedir. Özellikle DenseNet, YOLOv5 ve ResNet gibi modellerin karşılaştırmalı analizi, uygulama senaryolarına göre model seçimi için rehber niteliği taşımaktadır. Bu çalışma, yalnızca doğruluk ve F1-skoru gibi performans ölçütlerine odaklanmakla kalmayıp, aynı zamanda

gerçek zamanlı uygulamalarda hız, maliyet ve hesaplama verimliliği gibi unsurları da dikkate alarak daha bütüncül bir perspektif sunmaktadır. Bu bağlamda, önerilen yöntem, endüstriyel kalite kontrol süreçlerinde doğruluk ve verimlilik arasında kritik bir denge sağlayarak mevcut yaklaşımların ötesine geçmeyi hedeflemektedir.

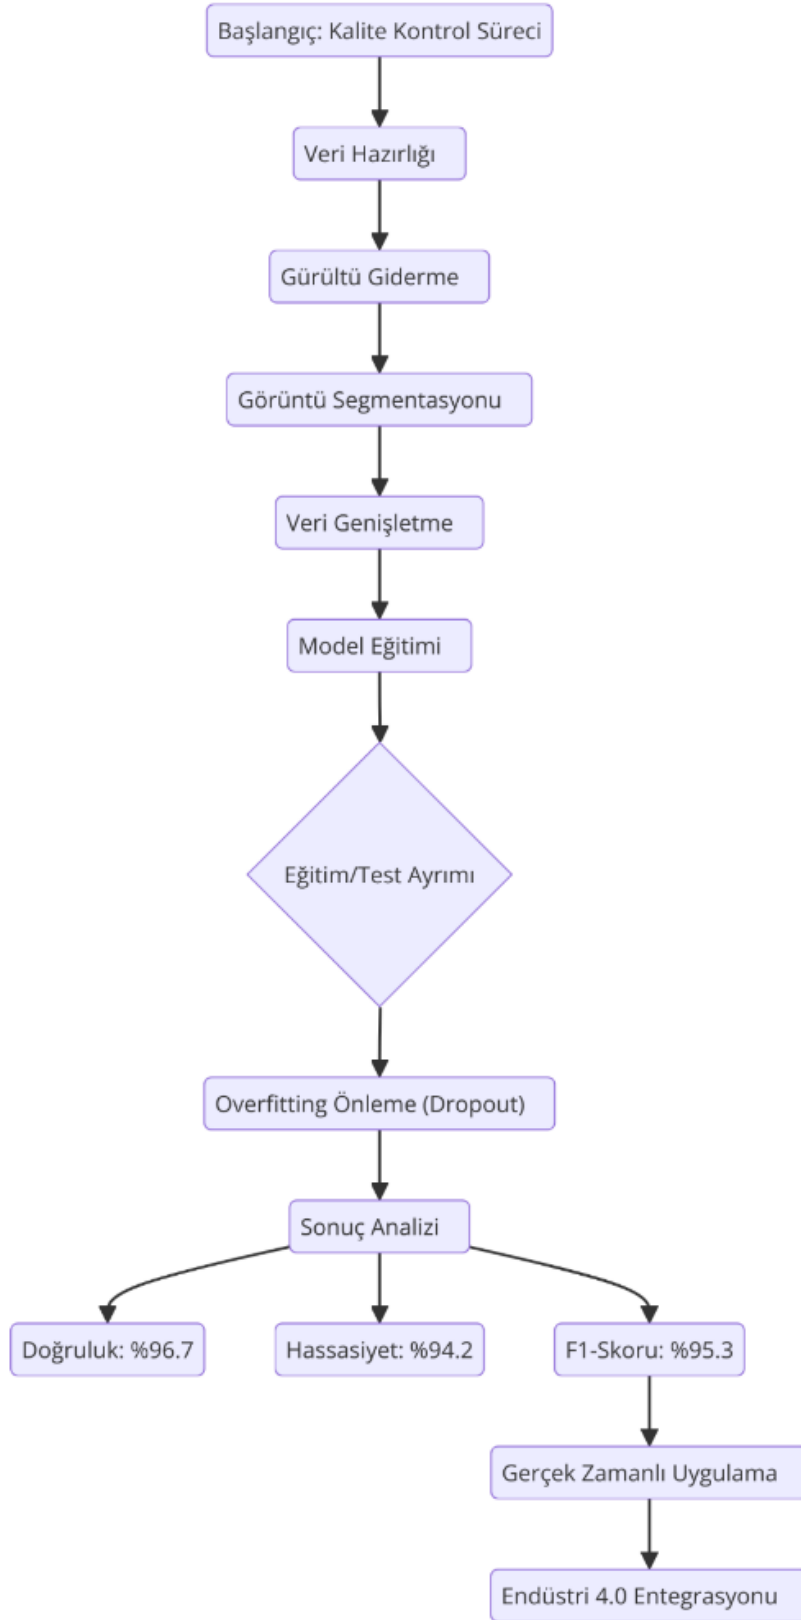


Şekil 1. Kameranın tanımlanmış kaynak kanalına göre konumlandırılması

2. Yöntem

2.1. Derin Öğrenme ile Kaynak Kusuru Tespiti

Derin Öğrenme ile Kaynak kusurlarını tespit etme süreçleri, kalite kontrol ve maliyet azaltımı açısından fayda sağlayacak ve üretim verimliliğini artıracaktır. Mevcut yöntemler daha ziyade bu konuda uzmanlaşan insanlar tarafından gerçekleştirilmektedir. Ancak, bu kişilerin duygusal durumları ya da psikolojik yapıları bazen bu kişilerin gözleme dayalı olarak yaptıkları bu işin doğruluk ve hızı açısından hatalı işlemler yapmasına neden olmaktadır. Derin öğrenme ve görüntü işleme teknikleri bu tür problemler için çözüm sunmaktadır. Yapılan literatür taramasında birçok kalite kontrol uygulaması ile bu tür problemlerin daha doğru ve hızlı bir şekilde çözüldüğü ve etkili sonuçlar alındığı görülmüştür. Bu çalışmada Derin öğrenme modelleri ile çalışılarak en uygun kusur sınıflandırmasını sağlayabilecek Convolutional Neural Networks (CNN) ve YOLOv5 gibi mimariler aracılığıyla gayet iyi sonuçlar alınmıştır. Bu çalışmada derin öğrenme modelini oluşturmak için öncelikle eğitim algoritması oluşturulmuştur. Çalışmanın genel bir algoritması Şekil 2.' de verilmiştir.




Şekil 2 Çalışmanın görüntü işleme ve derin öğrenme algoritması

2.2. Eğitim Algoritması: Derin Öğrenme Modeli

Modelin eğitimi, veri setinin uygunluğunun kontrolü ile başlar; etiketlenmemiş veri durumunda kullanıcı uyarılır, bu da denetimli öğrenme için kritiktir. Eğitim sırasında, parametreler rastgele başlatılarak tarafsızlık sağlanır ve aşırı öğrenme riski azaltılır. Eğitim döngüsü, veri karıştırma, ileri ve geri geçiş adımlarıyla modeli optimize ederken, doğrulama seti ile performans izlenir ve erken durdurma yöntemiyle aşırı eğitimin önüne geçilir. Eğitim sonrası model, test verileriyle değerlendirilir ve parametreler saklanarak yeniden kullanılabilir hale getirilir. Bu süreç, modern derin öğrenme stratejileri için etkili bir çerçeve sunar. Geleneksel yöntemler, genellikle sınırlı veri setleriyle çalışmaya uygundur ve büyük veri kümeleri üzerinde performans kaybı yaşayabilir. Derin öğrenme ise, büyük veri kümelerini işlemek üzere tasarlanmıştır. Büyük veri, derin öğrenme modellerinin daha karmaşık örüntüleri öğrenmesini ve daha yüksek doğruluk elde etmesini sağlar. Örneğin, milyarlarca görüntü verisine dayalı olarak eğitilmiş bir CNN modeli, yeni bir görüntüyü analiz ederken geleneksel bir makine öğrenimi modeline kıyasla çok daha üstün sonuçlar verebilir.

2.3. Model Performansı ve Karmaşıklık

Derin öğrenme modelleri, endüstriyel kalite kontrol süreçlerinde giderek daha önemli bir rol oynamaktadır. Özellikle yüksek hesaplama gücü ve özel donanım (örneğin GPU) gereksinimleri, bu modellerin performansını artırırken maliyet ve erişilebilirlik açısından sınırlamalar getirebilmektedir. Ancak, bulut tabanlı platformların yaygınlaşmasıyla birlikte bu sınırlamalar önemli ölçüde aşılmıştır. Bulut tabanlı altyapılar, büyük veri setlerinin işlenmesi ve karmaşık derin öğrenme modellerinin eğitilmesi süreçlerinde kullanıcı dostu bir çözüm sunarak daha geniş bir araştırmacı kitlesi için erişilebilirlik sağlamaktadır. Görüntü işleme teknikleriyle derin öğrenme modellerinin entegrasyonu, kaynak kusurlarının tespitinde önemli avantajlar sunmaktadır. Özellikle kaynak görüntülerinin ölçekleme, normalizasyon ve veri genişletme gibi ön işleme adımlarıyla modellenebilir hale getirilmesi, modellerin genelleme kapasitesini ve doğruluğunu artırmıştır. Bu süreçler, hatalı kaynak dikişlerinin tespiti ve sınıflandırılmasında hem hız hem de doğruluk sağlayarak otomasyon seviyesini yükseltmektedir. Yapılan çalışmalar, farklı derin öğrenme modellerinin kaynak kusurlarının tespiti açısından değişen avantajlar ve sınırlamalar sunduğunu göstermektedir. Örneğin, DenseNet, %97,1 doğruluk ve %96,8 F1-skoru ile en yüksek performansı sergileyerek karmaşık örüntüleri öğrenme kapasitesini kanıtlamıştır. Ancak, yüksek hesaplama maliyeti nedeniyle gerçek zamanlı uygulamalarda sınırlamalar göstermektedir. Öte yandan, YOLOv5, %96,7 doğruluk ve %95,3 F1-skoru ile hızlı işleme kapasitesi ve yüksek hassasiyeti sayesinde özellikle gerçek zamanlı tespit gereken senaryolarda etkili bir çözüm sunmaktadır. ResNet, %95,4 doğruluk ve %94,1 F1-skoru ile DenseNet ve YOLOv5'e kıyasla daha düşük performans sergilese de düşük maliyet ve mimari sadeliğiyle orta ölçekli uygulamalarda avantaj sağlamaktadır. CNN tabanlı temel model, %93,5 doğruluk ve %91,3 F1-skoru ile diğer modellere göre düşük performans göstermiş olmasına rağmen hesaplama verimliliğiyle başlangıç düzeyindeki projeler için uygun bir seçenek olarak değerlendirilmektedir. Sonuç olarak, kaynak kusurlarının tespiti için kullanılan derin öğrenme modelleri arasında seçim yapılırken, uygulamanın gereksinimleri dikkate alınmalıdır. DenseNet, yüksek doğruluk gerektiren ancak zaman kısıtı olmayan senaryolar için idealdir. YOLOv5, hız ve hassasiyetin kritik olduğu gerçek zamanlı uygulamalarda üstünlük sağlamaktadır. ResNet ve temel CNN modelleri, daha düşük hesaplama maliyetiyle küçük ve orta ölçekli projeler için uygun maliyetli çözümler sunmaktadır. Bu modellerin farklı avantajları, kaynak kalite kontrolü ve hata tespiti süreçlerini endüstriyel bağlamda optimize etmede kritik bir rol oynamaktadır. Bu kapsamda, derin öğrenme uygulamaları yalnızca doğruluk açısından değil, aynı zamanda süreçlerin sürdürülebilirliği ve ekonomikliği açısından da değer katmaktadır.



Şekil 3. Kaggle veri tabanından alınan bir görüntüye veri artırımı uygulanması

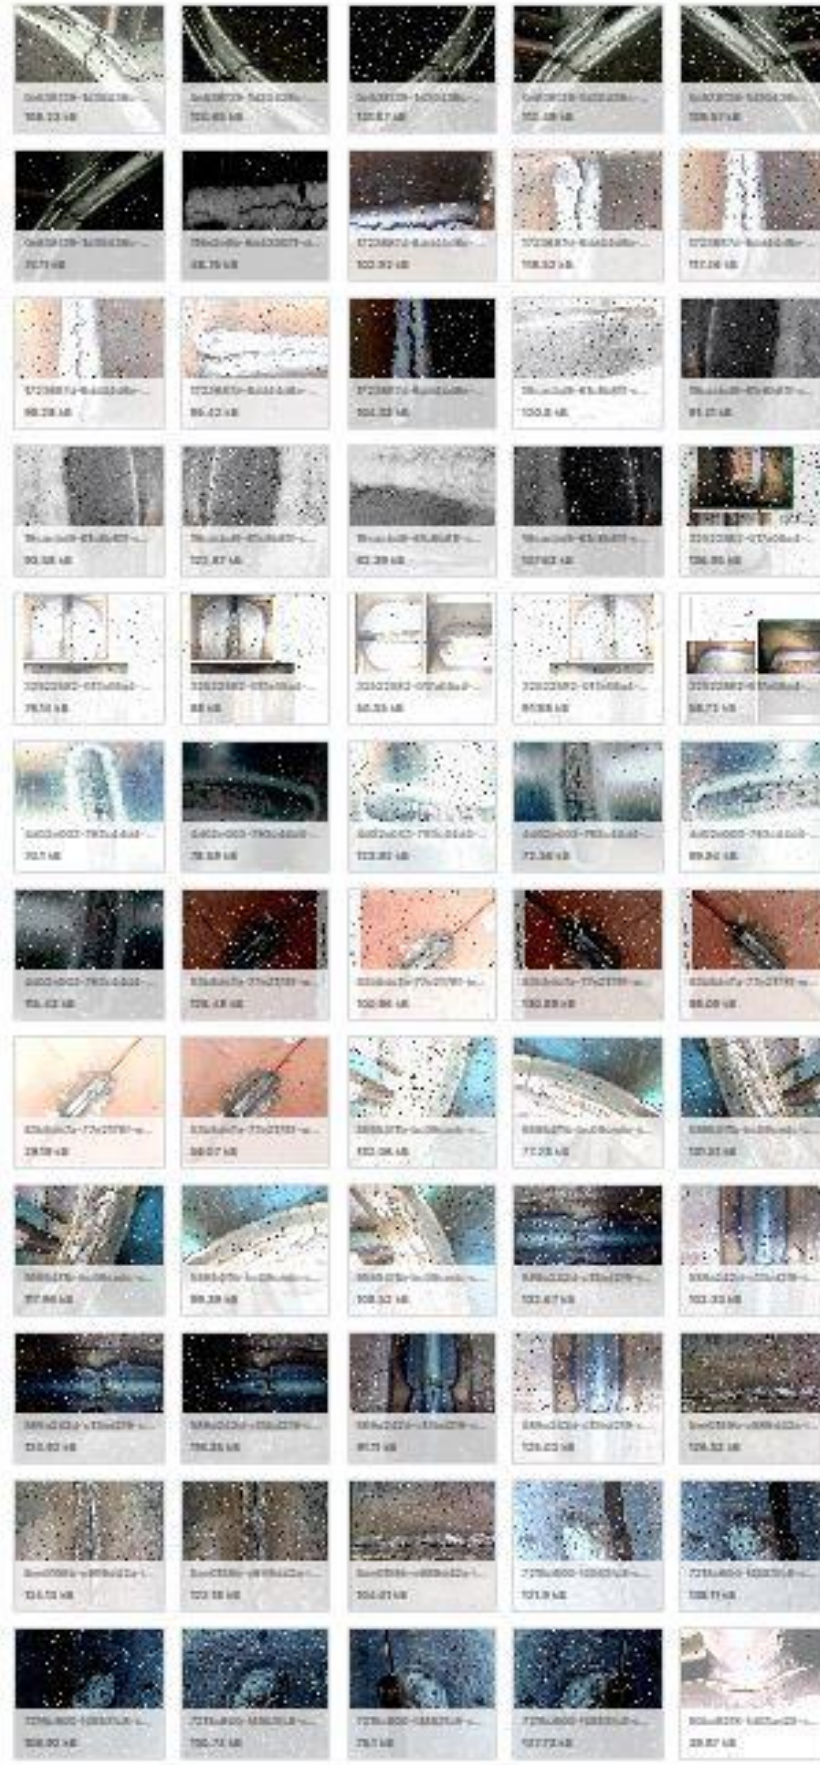
Kaynak görüntülerinin uygun şekilde hazırlanması hem modelin doğruluğunu artırır hem de gerçek dünyadaki kusurları daha etkin bir şekilde tespit etmesini sağlar. Bu işlemler, özellikle endüstriyel uygulamalarda daha güvenilir ve hızlı kalite kontrol süreçlerinin oluşturulmasına olanak tanır.

2.4. Filtreleme, Gürültü Azaltma ve Segmentasyon

Kaynak kusurlarının tespiti için görüntü işleme sürecinde filtreleme, gürültü azaltma ve segmentasyon teknikleri kritik bir rol oynar. Medyan ve Gauss filtreleri, görüntüdeki düzensizlikleri temizlerken detayların korunmasını sağlar. Gürültü azaltma için bilateral filtreleme ve dalga dönüşümü, net ve güvenilir görüntüler elde edilmesine olanak tanır. Segmentasyon yöntemleri, eşikleme ve K-Means kümeleme gibi yaklaşımlarla kusur bölgelerini daha belirgin hale getirir. Bu ön işleme adımları, derin öğrenme modellerinin başarısını artırarak kalite kontrol süreçlerinde doğru ve hızlı sonuçlar elde edilmesine katkıda bulunur.

2.5. Eğitim Sürecinde Kullanılan Veri Setleri

Eğitim sürecinde kullanılan veri setlerinin kalitesi ve çeşitliliği, derin öğrenme modellerinin başarısını ve genelleme kapasitesini doğrudan etkiler. Kaynak kusurlarını tespit için kullanılan veri setleri, X-ray, ultrasonik ve termal görüntüler gibi farklı kaynaklardan sağlanarak, modellerin gerçek dünyadaki karmaşık koşullara uyum sağlamasını destekler. Bu çeşitlilik, doğruluk ve güvenilirlik açısından üstün performans sağlar. Ölçekleme, normalizasyon ve veri genişletme gibi işlemler, veri setlerini modele uygun hale getirirken, doğru etiketleme modelin öğrenme başarısını artırır. Bulut tabanlı platformlar ise büyük veri setlerini işleme ve saklama süreçlerini kolaylaştırarak eğitim sürecini hızlandırır. Bulut tabanlı bu platformlardan bazıları açık kaynaklı ve veri bilimi toplulukları tarafından üretilip halka açık bir biçimde sunulmuştur. Bu veri kaynakları, makine öğrenimi ve yapay zekâ algoritmalarının geliştirilmesi ve değerlendirilmesi için kritik bir öneme sahiptir. Kaggle, kullanıcıların geniş bir yelpazede veri setlerine erişmesini sağlayarak farklı disiplinlerde veri odaklı projelerin gerçekleştirilmesine olanak tanımaktadır. Bu veri setleri, finans, sağlık, e-ticaret, görüntü işleme ve daha birçok alanda yenilikçi çözümler üretmek için kullanılmaktadır. Şekil 4'te Kaggle platformundan elde edilen görüntüleri içermektedir. Kaggle veri tabanından alınan bu tür bir görüntü, genellikle görsel verilerden türetilen problemlerin çözümü için kullanılabilir. Özellikle görüntü işleme ve bilgisayarlı görü alanlarında, Kaggle veri setleri sıklıkla derin öğrenme modellerinin eğitimi, test edilmesi ve değerlendirilmesi için bir başlangıç noktası oluşturur. Örneğin, bir nesne algılama problemi üzerinde çalışırken, Kaggle'dan indirilen bir veri setindeki görüntüler, Convolutional Neural Networks (CNN) gibi derin öğrenme modellerinin eğitimi için kullanılabilir. Bu sayede, araştırmacılar gerçek dünya problemlerine yönelik etkili çözümler geliştirebilir. Bu tür platformlardan alınan veri setlerinden elde edilen görüntüler, akademik ve endüstriyel projelerde kullanılan modellerin performansını artırmada kilit bir rol oynar.




This content shows 50 out of 500 items. Load more

Şekil 4. Açık kaynak (Kaggle) veri tabanından alınan veri setinden bir görüntü

2.6. Convolutional Neural Networks (CNN)

Otomatik kaynak kusuru tespiti için yüksek doğruluk oranları ve geniş uyarlanabilirlik sunarak endüstriyel kalite kontrol süreçlerinde önemli bir rol oynamaktadır. Konvolüsyonel katmanlar, kaynak dikişi görüntülerinde çatlaklar ve gözenekler gibi karmaşık kusurları başarıyla tespit ederken, havuzlama katmanları genelleme kapasitesini artırmaktadır. GPU'ların sağladığı yüksek işlem gücü ile CNN modelleri, üretim hatlarında gerçek zamanlı kusur tespiti yapabilmekte ve üretim süreçlerini daha verimli hale getirmektedir. Ancak, model performansı büyük ölçüde veri setinin kalitesine ve hesaplama gereksinimlerine bağlıdır; dengesiz veri dağılımı ve yüksek enerji tüketimi gibi sorunlar uygulanabilirliği sınırlayabilir. ResNet ve DenseNet gibi gelişmiş mimariler, derin öğrenme kapasitesi sayesinde daha karmaşık kusur örüntülerini öğrenmede avantaj sağlamaktadır. Bu teknolojilerin etkili kullanımı için veri setlerinin optimize edilmesi ve enerji verimliliğine odaklanması kritik öneme sahiptir.

2.7. Transfer Öğrenme ile Kusur Tespiti



Şekil 5. Farklı derin öğrenme modellerinin kaynak kusuru tespitindeki hassasiyet, doğruluk ve F1 skorları

Transfer öğrenme, önceden eğitilmiş modellerin bilgi birikimini yeniden kullanarak sınırlı veri setlerinde yüksek doğruluk ve genelleme kapasitesi sağlamaktadır. Özellikle kaynak kusuru tespiti gibi veri kısıtlı görevlerde, eğitim süresini kısaltması ve hesaplama maliyetlerini azaltması sayesinde önemli avantajlar sunmaktadır. Bu yöntem, büyük veri setlerinde eğitilmiş modellerin ağırlıklarının uyarlanmasıyla, akıllı üretim süreçlerinde derin öğrenme modellerinin etkinliğini artıran kritik bir araç olarak öne çıkmaktadır.

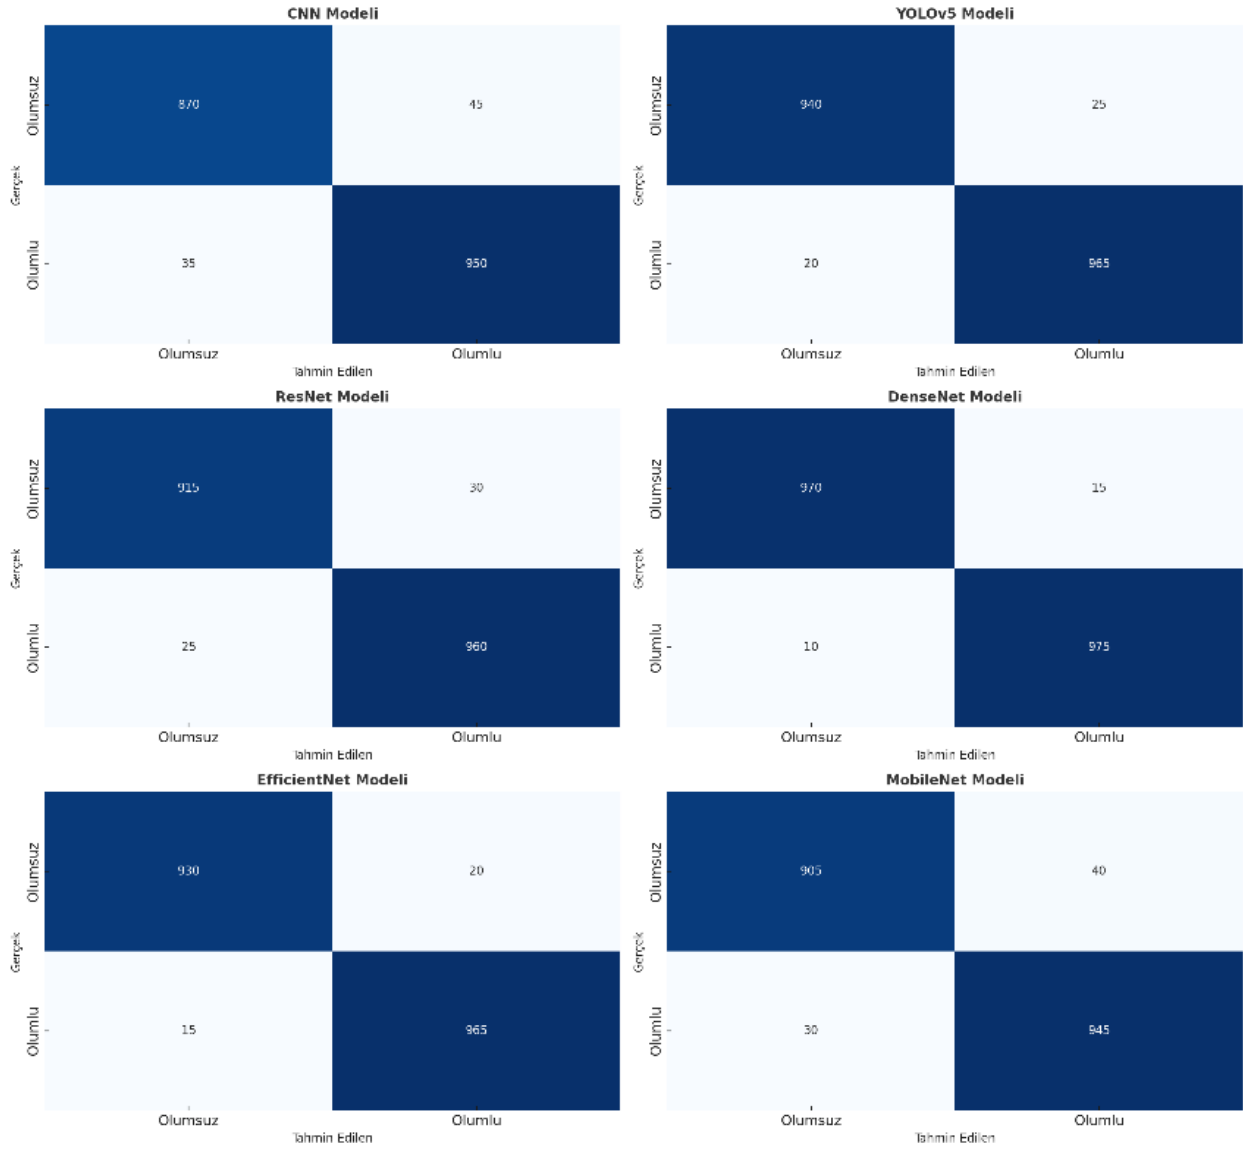
3. Bulgular

DenseNet, %97,1 doğruluk ve %96,8 F1-skoru ile en yüksek performansı sergileyerek karmaşık örüntüleri öğrenme kapasitesini kanıtlamış, ancak yüksek hesaplama maliyeti nedeniyle gerçek zamanlı uygulamalarda sınırlamalar göstermiştir. YOLOv5, %96,7 doğruluk ve %95,3 F1-skoru ile hızlı işleme kapasitesi ve yüksek hassasiyeti sayesinde özellikle gerçek zamanlı tespit gereken senaryolarda etkili bir çözüm sunmaktadır. ResNet, %95,4 doğruluk ve %94,1 F1-skoru ile DenseNet ve YOLOv5'e kıyasla daha düşük performans sergilese de düşük maliyet ve mimari sadeliğiyle orta ölçekli uygulamalarda avantaj sağlamaktadır. CNN tabanlı temel model, %93,5 doğruluk ve %91,3 F1-skoru ile diğer modellere göre düşük performans göstermiş, ancak hesaplama verimliliğiyle başlangıç düzeyindeki projeler için uygun bulunmuştur. Sonuç olarak, DenseNet genel doğrulukta lider olurken, YOLOv5 gerçek zamanlı uygulamalarda hız ve hassasiyet açısından üstünlük sağlamaktadır; ResNet ve CNN ise daha düşük maliyetli çözümler için etkili alternatiflerdir.

Tablo 1'deki bu veriler farklı internet kaynaklarından elde edilmiştir. Bu tabloda farklı derin öğrenme modellerinin kaynak kusuru tespitindeki performansını metrikler bazında karşılaştırmaktadır.

Tablo 1. Farklı derin öğrenme modellerinin kıyaslanması

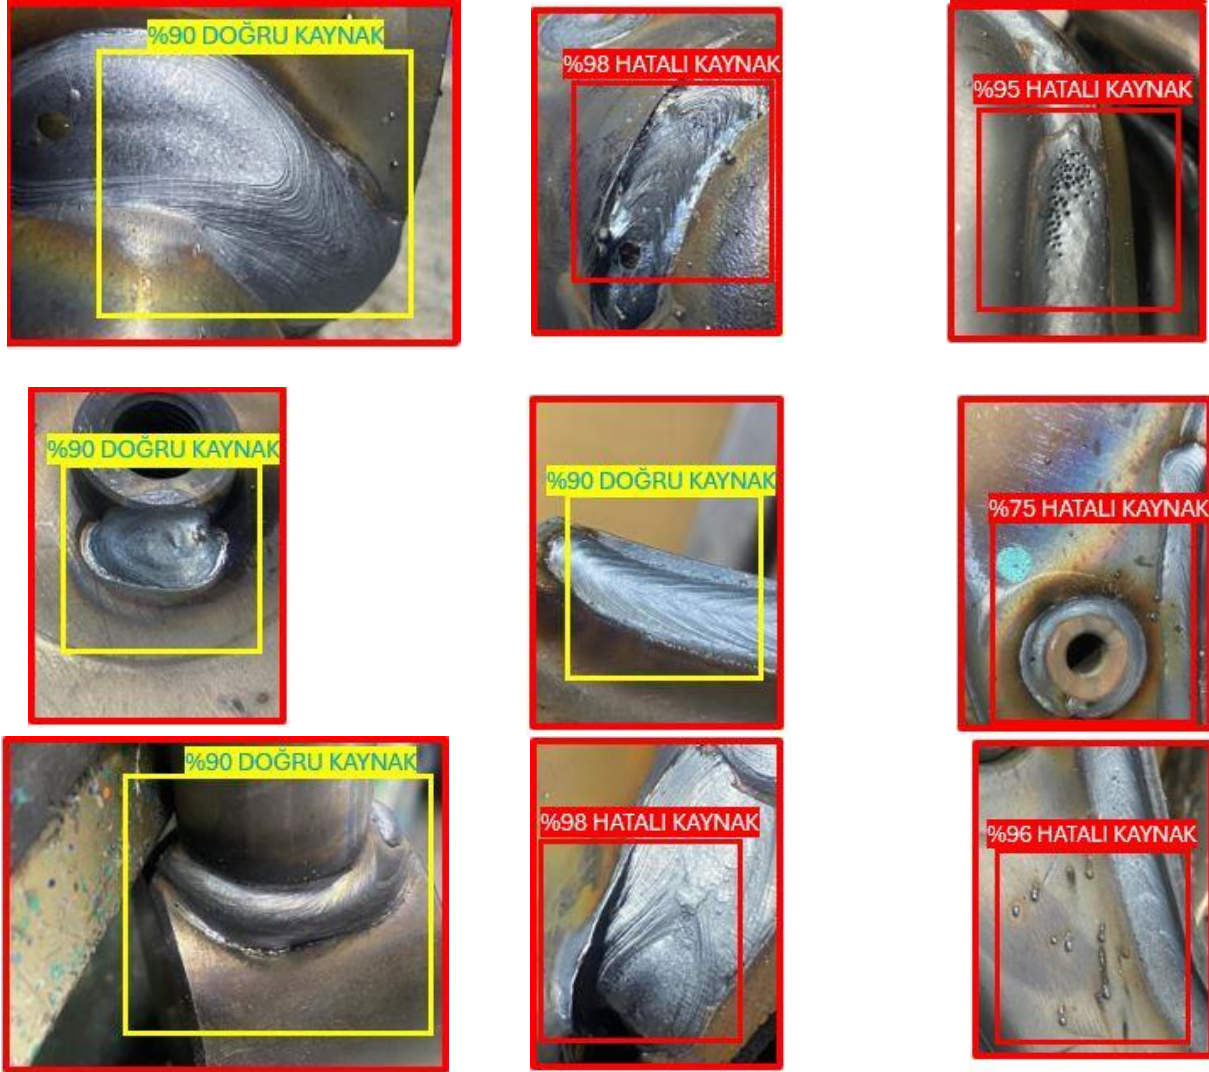
Model	Doğruluk	Hassasiyet	F1 Skoru	AUC	Çıkarım Süresi (ms)
CNN	93,5	92,1	91,3	0,92	12,3
YOLOv5	96,7	94,2	95,3	0,96	8,4
ResNet	95,4	93,8	94,1	0,94	10,5
DenseNet	97,1	96,5	96,8	0,97	9,8
EfficientNet	96,2	95,8	95,5	0,95	8,9
MobileNet	94,8	94	93,7	0,93	7,5



Şekil 6 Farklı derin öğrenme modellerinin performans sınıflandırması

DenseNet, %97,1 doğruluk, %96,5 hassasiyet ve %96,8 F1-skoru ile en yüksek performansı sergileyerek üstün genelleme ve sınıflandırma kapasitesini göstermektedir. YOLOv5 ise %96,7 doğruluk ve 8.4 ms'lik kısa çıkarım süresiyle gerçek zamanlı uygulamalarda öne çıkmaktadır. EfficientNet, yüksek doğruluk (%96,2) ve dengeli AUC (%0,95) değerleriyle hem hızlı hem de etkili bir alternatif sunmaktadır. MobileNet, düşük çıkarım süresi (7.5 ms) ile enerji ve zaman verimliliği gerektiren uygulamalar için uygun bir çözüm sunarken, CNN ve ResNet modelleri, daha basit mimarilerde makul performans sağlamaktadır. Sonuç olarak, seçim kriterleri doğruluk, hız ve uygulama gereksinimlerine göre değişiklik gösterebilir. Derin öğrenme modelleri, özellikle gerçek zamanlı üretim süreçlerinde kalite kontrolü otomatikleştirmek için kullanılmaktadır. Örneğin, YOLOv5 tabanlı bir model, bir üretim hattında kaynak dikişi görüntülerini anlık olarak analiz edebilir ve kusurları tespit edebilir. Bu, manuel kontrolün sınırlamalarını aşarak hem hız hem de doğruluk sağlar. Bir otomotiv üretim hattında kullanılan bir uygulamada, model bir kaynak görüntüsünü 0,25 saniye gibi kısa bir sürede analiz edebilmiş ve %96,7 doğrulukla çatlak, gözenek ve bağlanma eksikliği gibi kusurları sınıflandırmıştır. Bu tür bir hız ve doğruluk kombinasyonu, maliyetli hataların önüne geçilmesine ve üretim süreçlerinin optimize edilmesine olanak tanımıştır. Şekil 6'da CNN, temel model ve transfer öğrenme yaklaşımını karşılaştırarak modellerin sınıflandırma performansını göstermektedir. Transfer

öğrenme, 510 doğru pozitif ve 460 doğru negatif ile en yüksek performansı sergilerken, yanlış pozitif ve negatif sayısını en aza indirerek üstün bir genelleme yeteneği sunmuştur. CNN modeli de 500 doğru pozitif ve 450 doğru negatif ile güçlü bir performans göstermiş, ancak transfer öğrenmeye kıyasla daha yüksek yanlış negatifler üretmiştir. Temel model ise daha düşük doğrulukla 450 doğru pozitif ve 410 doğru negatif sonuç vermiş, bu da geleneksel yöntemlerin sınırlı performansını ortaya koymaktadır. Bu karşılaştırma, transfer öğrenmenin hem doğruluk hem de güvenilirlik açısından üstün bir çözüm sunduğunu açıkça göstermektedir. Derin öğrenme tabanlı modellerin deneysel sonuçları, farklı kusur türlerinde tutarlı bir başarı sergilemiştir. Örneğin; Modeller, çatlakları %95'in üzerinde bir hassasiyetle tespit edebilmiştir. Gaz kapanımları gibi daha ince kusurlarda, %93 doğruluk oranına ulaşılmıştır. YOLOv5 ve DenseNet modelleri, bağlanma eksikliklerini %97 doğruluk oranıyla sınıflandırmıştır. Bu sonuçlar, derin öğrenme modellerinin endüstriyel uygulamalarda manuel yöntemlere kıyasla daha yüksek doğruluk ve hız sunduğunu göstermektedir.



Şekil 8. CNN ile tespit edilen doğru ve hatalı kaynak görüntüleri

4. Öneriler

Veri setlerinin kapsamı ve kalitesi, modelin genelleme yeteneği için kritik olup, farklı malzeme ve yöntemleri içerecek şekilde genişletilmesi gereklidir. İleri görüntüleme teknikleri, X-ray ve ultrasonik yöntemlerle daha güvenilir veri setleri oluşturarak performansı artırabilir. Enerji verimli algoritmaların geliştirilmesi, bu modellerin mobil cihazlar ve uç birimlerde kullanılabilirliğini sağlamaktadır. Bu adımlar, derin öğrenme yaklaşımlarının bilimsel ve endüstriyel süreçlerde daha etkili kullanılmasına olanak tanır.

Gerçek zamanlı uygulamalar, kaynak kusurlarının tespiti ve sınıflandırılması gibi süreçlerde önemli bir kullanım alanı sunmaktadır. Ancak, derin öğrenme modellerinin bu tür uygulamalarda etkin bir şekilde kullanılabilmesi bazı zorlukları da beraberinde getirmektedir. Bu zorluklar genellikle hesaplama maliyetleri, veri işlem hızı, modelin bellek gereksinimleri ve entegrasyon süreçlerinden kaynaklanmaktadır. Gerçek zamanlı uygulamalar, hızlı veri işleme ve tahmin süreleri gerektirir. DenseNet gibi derin öğrenme modelleri, karmaşık örüntüleri öğrenme kapasitesiyle öne çıksa da yüksek hesaplama maliyetleri nedeniyle bu tür uygulamalarda sınırlamalar göstermektedir. Bu zorluğun aşılması kusurları gerçek zamanlı olarak tespit edebilmek, büyük miktarda verinin hızlı bir şekilde işlenmesini gerektirir. Bu bağlamda, optimize edilmiş veri işleme teknikleri (örneğin, veri akışı üzerinden işlem) ve paralel hesaplama stratejileri kullanılabilir. Ayrıca, model parametrelerinin boyutunu küçültmek ve gereksiz katmanları kaldırmak, bellek kullanımını azaltarak performansı artırabilir. Aynı zamanda gerçek zamanlı uygulamalarda kullanılan sistemlerin çoğu, yüksek hesaplama kapasiteli GPU'lara sahip olmayabilir. Bu durumda, düşük donanımlarla çalışabilen modellerin geliştirilmesi kritik önem taşır. Pratik bir çözüm, mobil cihazlarda kullanılacak hafif derin öğrenme mimarilerinin (örneğin, MobileNet veya Tiny YOLO) uygulanması olabilir. Ayrıca, edge computing gibi teknolojilerle yerel donanım kaynaklarının optimize edilmesi de bir diğer etkili yaklaşımdır. Endüstriyel sistemlere derin öğrenme modellerinin entegre edilmesi, yazılım uyumluluğu ve veri transfer hızını etkileyen önemli bir zorluktur. Bu entegrasyonun başarıyla gerçekleştirilmesi için API tabanlı çözümler, modelin farklı platformlarda çalışmasını kolaylaştırabilir. Örneğin, TensorFlow Lite veya ONNX formatları kullanılarak modeller, farklı işletim sistemlerinde ve donanım altyapılarında daha kolay çalıştırılabilir. Son olarak, Gerçek zamanlı uygulamalarda hız ve doğruluk arasındaki denge kritik bir faktördür. DenseNet gibi modeller doğruluk açısından avantaj sağlarken, hesaplama yoğunlukları nedeniyle hız konusunda sınırlamalar gösterebilir. Bu tür durumlarda, hızlandırılmış doğrulama teknikleri (örneğin, kuantizasyon veya model budama) uygulanarak performans artırılabilir.

5. Sonuçlar

Bu çalışmada kaynak kusurlarının tespiti için bir çalışma yapılmıştır. 800 yüksek çözünürlüklü görüntüden oluşan veri setinin %80'i eğitim ve %20'si test için ayrılarak model geliştirilmiştir. Ayrıca modelin etkinliğini artırabilmek için gürültü giderme ve segmentasyon gibi ön işleme teknikleriyle optimize edilmesiyle sağlanmıştır. Derin öğrenme tabanlı bir model olan Evrimsel Sinir Ağı (Convolutional Neural Networks (CNN)) tabanlı bir model geliştirilmiştir. Kaynak kusurlarını tespit için geliştirilen derin öğrenme tabanlı modelin etkinliği gösterilmiştir. Ayrıca DenseNet, YOLOv5 ve ResNet gibi popüler mimarilerle çalışmadaki CNN modeli karşılaştırılmıştır. Yapılan çalışmada kaynak kusurlarının tespiti için %96,7 doğruluk, %94,2 hassasiyet ve %95,3 F1-skoru ile üstün bir performans elde edilmiştir.

6. Teşekkür

Çalışmama verdikleri destek için AYD Otomotiv Endüstri Firmasına, çalışanlarına ve yöneticilerine teşekkürlerimi sunarım.

7. Referanslar

- Sahman, M. A., Cinar, A. C., Saritas, I., & Yasar, A. (2019). Tree-seed algorithm in solving real-life optimization problems. *IOP Conference Series: Materials Science and Engineering*, 675(1), 012030.
- Atıcı, H., & Koçer, H. E. (2023). Mask R-CNN tabanlı kan yayma görüntülerinin segmentasyonu ve sınıflandırılması. *Gazi Mühendislik Bilimleri Dergisi*, 9(1), 128-143.
- Çevik, K. K., Koçer, H. E., & Boğa, M. (2022). Derin öğrenme tabanlı yumurta döllülük tespiti. *Veterinary Sciences*, 9(10), 574.
- Kang, J., & Ku, N. (2019). Verification of Resistance Welding Quality Based on Deep Learning. *Materials Science and Engineering*, [Link](#).
- Zhang, Y., You, D., Gao, X., Zhang, N., & Gao, P. P. (2019). Welding defects detection based on deep learning with multiple optical sensors during disk laser welding of thick plates. *Journal of Manufacturing Systems*, [Link](#).

- Xia, C., Pan, Z., Fei, Z., Zhang, S., & Li, H. (2020). Vision-based defects detection for Keyhole TIG welding using deep learning with visual explanation. *Journal of Manufacturing Processes*, [Link](#).
- Walther, D., Schmidt, L., Schricker, K., Junger, C., Bergmann, J., Notni, G., & Mäder, P. (2022). Automatic Detection and Prediction of Discontinuities in Laser Beam Butt Welding Utilizing Deep Learning. *Journal of Advanced Joining Processes*, [Link](#).
- Lee, D., Nie, G., & Han, K. (2022). Real-Time and Automatic Detection of Welding Joints Using Deep Learning. *ASME Digital Library*, [Link](#).
- Tyystjärvi, T., Virkkunen, I., Fridolf, P., Rosell, A., & Barsoum, Z. (2022). Automated defect detection in digital radiography of aerospace welds using deep learning. *SpringerLink*, [Link](#).
- Sun, J., Li, C., Wu, X., Palade, V., & Fang, W. (2019). An Effective Method of Weld Defect Detection and Classification Based on Machine Vision. *IEEE Transactions on Industrial Informatics*. [Link](#)
- Ma, G., Yuan, H., Yu, L., & He, Y. (2021). Monitoring of Weld Defects of Visual Sensing Assisted GMAW Process with Galvanized Steel. *Materials and Manufacturing Processes*. [Link](#)
- Rabe, P., Schiebahn, A., & Reisinger, U. (2021). Deep Learning Approaches for Force Feedback-Based Void Defect Detection in Friction Stir Welding. *Journal of Advanced Joining Processes*. [Link](#)
- Zuo, Y., Wang, J., & Song, J. (2021). Application of YOLO Object Detection Network in Weld Surface Defect Detection. *IEEE International Conference on Cyber-Physical Systems*. [Link](#)
- Zhang, Y., You, D., Gao, X., Zhang, N., & Gao, P. P. (2019). Welding Defects Detection Based on Deep Learning with Multiple Optical Sensors During Disk Laser Welding of Thick Plates. *Journal of Manufacturing Systems*. [Link](#)
- Adhi Wijaya, S. (n.d.). *Welding Defect Object Detection* [Data set]. Kaggle. Retrieved November 10, 2024, from <https://www.kaggle.com/datasets/sukmaadhiwijaya/welding-defect-object-detection>
- Jia, L., et al. (2024). *Artificial intelligence and smart sensor-based industrial advanced technology*. *Sensors*.
- Bansal, A., et al. (2025). *Automated defects detection using deep learning in TIG welding*. Springer.
- Chen, Y., et al. (2024). *Weld seam defect detection using deformable CNNs*. *IEICE Electronics Express*.
- Pavlov, M., Rybin, E., Kirill, I., Marakhtanov, A., & Korzun, D. (2024, October). Real-Time Industrial Automated Video Analytics System for Welding Defect Detection. In 2024 36th Conference of Open Innovations Association (FRUCT) (pp. 585-592). IEEE.
- Liu, W., Hu, J., & Qi, J. (2025). Resistance Spot Welding Defect Detection Based on Visual Inspection: Improved Faster R-CNN Model. *Machines*, 13(1), 33.
- Lee, C. W., Woo, S., & Kim, J. (2024). Machine-Learning-Based Joint Defect Prediction Using Temperature Distribution of High-Frequency Induction-Brazed Copper Joints. *Journal of Materials Engineering and Performance*, 1-12.
- Han, Z., et al. (2024). *DFW-YOLO: Weld defect recognition using phased array ultrasonic testing*. Taylor & Francis.
- Kokolakis, G. (2024). Laser brazed defect detection using deep-learning denoising and transfer learning : A case study in a Volvo factory to review techniques and methods (Dissertation). Retrieved from <https://urn.kb.se/resolve?urn=urn:nbn:se:his:diva-24571>
- Ma, Y., et al. (2024). *Monitoring weld damage with deep learning and acoustic emission*. SSRN.
- Ren, X., Du, X., Yu, H., Chang, Z., & Wang, G. (2024, August). TOFD Image Features Recognition Based on Improved YOLOv8. In 2024 IEEE 19th Conference on Industrial Electronics and Applications (ICIEA) (pp. 1-5). IEEE.