

## YOLO Algoritması ile Kalite Kontrol Süreçlerinde Görüntü İşleme

Semih KARAMUK<sup>a</sup>

Yavuz ÖZDEMİR<sup>b</sup>

Mustafa YILDIRIM<sup>c</sup>

Gökhan ÖZDEMİR<sup>d</sup>

Öz

Makale Hakkında

Bu çalışma, çelik yüzeylerinde meydana gelen üretim kusurlarının tespiti için bilgisayarla görü ve derin öğrenme tekniklerinden yararlanarak bir kalite kontrol sistemi geliştirmeyi amaçlamaktadır. Roboflow platformundan elde edilen etiketli görüntüler kullanılarak YOLOv5s modeli eğitilmiş ve modelin performansı mAP, kesinlik (precision) ve duyarlılık (recall) ölçütleriyle değerlendirilmiştir. Eğitim sonucunda model %75 mAP, %70.9 precision ve %70.7 recall değerlerine ulaşmıştır. Ayrıca, model performansı klasik görüntü işleme tabanlı bir kusur tespit yaklaşımı ile karşılaştırılmış ve YOLOv5s'nin karmaşık yüzey kusurlarını belirlemede klasik yöntemlere göre belirgin derecede daha yüksek doğruluk sağladığı görülmüştür. Elde edilen bulgular, geliştirilen sistemin endüstriyel üretim hatlarında manuel kontrolün yerine geçebilecek düzeyde güvenilir ve etkili bir çözüm sunduğunu göstermektedir.

**Anahtar Kelimeler:** Bilgisayarla görü, Derin öğrenme, Çelik yüzey kusurları, YOLOv5, Kalite kontrol

**Geliş Tarihi:** 01.08.2025

**Kabul Tarihi:** 28.12.2025

**Yayın Tarihi:** 30.12.2025

**Atıf için:** Karamuk, S., Özdemir, Y., Yıldırım, M., Özdemir, G. (2025). YOLO Algoritması ile Kalite Kontrol Süreçlerinde Görüntü İşleme. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(2), 131-154. <https://doi.org/10.47769/izufbed.1755090>

### Etik Beyan

Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunur (Yavuz ÖZDEMİR).



<sup>b</sup> **Sorumlu Yazar:** Doç. Dr., İstanbul Sağlık ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye. E-mail: [yavuz.ozdemir@istun.edu.tr](mailto:yavuz.ozdemir@istun.edu.tr) ORCID <https://orcid.org/0000-0001-6821-9867>

<sup>a</sup>Endüstri Mühendisi, İstanbul Sağlık ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye. E-mail: [semih.karamuk@istun.edu.tr](mailto:semih.karamuk@istun.edu.tr) ORCID <https://orcid.org/0000-0002-7346-6835>

<sup>c</sup>Endüstri Mühendisi, İstanbul Sağlık ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye. E-mail: [mustafa.yildirim@istun.edu.tr](mailto:mustafa.yildirim@istun.edu.tr) ORCID <https://orcid.org/0000-0001-5709-4421>

<sup>d</sup>Endüstri Mühendisi, İstanbul Sağlık ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye. E-mail: [gokhan.ozdemir@istun.edu.tr](mailto:gokhan.ozdemir@istun.edu.tr) ORCID <https://orcid.org/0009-0001-3780-2272>

\* Bu çalışmanın hazırlanma sürecinde yapay zekâ tabanlı herhangi bir araç veya uygulama kullanılmamıştır. Çalışmanın tüm içeriği, yazar(lar) tarafından bilimsel araştırma yöntemleri ve akademik etik ilkelere uygun şekilde üretilmiştir.

## Image Processing in Quality Control Processes Using YOLO Algorithm

Semih KARAMUK<sup>a</sup>

Yavuz ÖZDEMİR<sup>b</sup>

Mustafa YILDIRIM<sup>c</sup>

Gökhan ÖZDEMİR<sup>d</sup>

### Abstract

This study aims to develop a quality control system for detecting surface defects on steel products by utilizing computer vision and deep learning techniques. A labeled dataset obtained from the Roboflow platform was used to train a YOLOv5s object detection model, and its performance was evaluated using the mAP, precision, and recall metrics. The trained model achieved 75% mAP, 70.9% precision, and 70.7% recall, demonstrating its capability to reliably identify various defect types. Furthermore, the model's performance was compared with a classical image-processing-based defect detection approach. The results showed that YOLOv5s provides significantly higher accuracy than traditional methods, particularly in detecting complex and low-contrast surface anomalies. These findings indicate that the proposed system offers a robust and effective solution for automated quality inspection and has strong potential to replace manual inspection processes in industrial production environments.

**Keywords:** *Computer vision, Deep learning, Steel surface defects, YOLOv5, Quality control*

### About Article

**Received Date:** 01.08.2025

**Accepted Date:** 28.12.2025

**Publication Date:** 30.12.2025

**To Cite:** Karamuk, S., Özdemir, Y., Yıldırım, M., Özdemir, G. (2025). Image Processing in Quality Control Processes Using YOLO Algorithm. *Istanbul Sabahattin Zaim University Journal of Institute of Science and Technology*, 7(2), 131-154. <https://doi.org/10.47769/izufbed.1755090>

### Ethical Statement

*It is declared that scientific and ethical principles have been followed while carrying out and writing this study and that all the sources used have been properly cited (Yavuz ÖZDEMİR).*

<sup>b</sup> **Corresponding Author:** Assoc. Prof. Istanbul Health and Technology University, Faculty of Engineering and Natural Sciences, Industrial Engineering, İstanbul, Türkiye. E-mail: [yavuz.ozdemir@istun.edu.tr](mailto:yavuz.ozdemir@istun.edu.tr) ORCID <https://orcid.org/0000-0001-6821-9867>

<sup>a</sup> Industrial Engineer, Istanbul Health and Technology University, Faculty of Engineering and Natural Sciences, Industrial Engineering, İstanbul, Türkiye. E-mail: [semih.karamuk@istun.edu.tr](mailto:semih.karamuk@istun.edu.tr) ORCID <https://orcid.org/0000-0002-7346-6835>

<sup>c</sup> Industrial Engineer, Istanbul Health and Technology University, Faculty of Engineering and Natural Sciences, Industrial Engineering, İstanbul, Türkiye. E-mail: [mustafa.yildirim@istun.edu.tr](mailto:mustafa.yildirim@istun.edu.tr) ORCID <https://orcid.org/0000-0001-5709-4421>

<sup>d</sup> Industrial Engineer, Istanbul Health and Technology University, Faculty of Engineering and Natural Sciences, Industrial Engineering, İstanbul, Türkiye. E-mail: [gokhan.ozdemir@istun.edu.tr](mailto:gokhan.ozdemir@istun.edu.tr) ORCID <https://orcid.org/0009-0001-3780-2272>

\* No artificial intelligence-based tools or applications were utilized in the preparation of this manuscript. All content was generated solely by the author(s) in adherence to scientific research methodologies and academic ethical standards.

## Giriş

Sanayi 4.0 devrimi ile birlikte üretim hatlarında otomasyonun önemi giderek artmış, manuel denetime alternatif olarak yapay zekâ destekli kalite kontrol sistemleri ön plana çıkmıştır. Üretim süreçlerinde meydana gelen yüzey kusurlarının zamanında ve doğru şekilde tespit edilmesi hem ürün kalitesinin artırılması hem de üretim maliyetlerinin düşürülmesi açısından kritik bir rol oynamaktadır. Bu bağlamda, bilgisayarla görü teknikleri ve derin öğrenme algoritmaları, sundukları hızlı ve yüksek doğruluklu analiz yetenekleri sayesinde endüstriyel kalite kontrol süreçlerinde önemli bir dönüşüm sağlamıştır.

Literatürde, farklı sektörlerde bilgisayarla görü tabanlı hata tespiti uygulamaları yaygın olarak incelenmiştir. Aydın ve Şahin (2015), ilaç tabletlerindeki kaplama hatalarının tespiti için YOLOv1 algoritmasını kullanmış; Ren ve arkadaşları (2015) ise Faster R-CNN tabanlı bir sistem ile güç aktarma organı montaj hattında yüksek doğrulukta hata tespiti gerçekleştirmiştir. Benzer şekilde, Özkan ve Yılmaz (2016) metal levhalarda, Arslan ve Kılıç (2019) seramik ürünlerde ve Demirtaş ve Yıldız (2021) gıda ambalajlarında YOLO algoritmalarının farklı sürümlerini kullanarak başarılı sonuçlar elde etmiştir. Son yıllarda yapılan çalışmalarda ise YOLOv4 ve YOLOv5 gibi daha gelişmiş sürümlerin tercih edildiği ve bu modellerin gerçek zamanlı uygulamalarda etkin performans sergilediği görülmektedir.

Bununla birlikte, mevcut çalışmaların önemli bir kısmında deneysel sürecin ayrıntılı şekilde sunulmadığı, eğitim parametrelerinin ve veri seti özelliklerinin sınırlı biçimde açıklandığı ve model performansının çoğunlukla eğitim verileri üzerinden değerlendirildiği dikkat çekmektedir. Ayrıca, literatürde aynı veya benzer veri setleri üzerinde yapılan yöntemlerin sistematik karşılaştırmalarının sınırlı olduğu görülmektedir. Bu durum, önerilen modellerin genelleme yeteneğinin ve endüstriyel uygulamalardaki güvenilirliğinin değerlendirilmesini zorlaştırmaktadır.

Bu çalışmada, çelik yüzeylerinde meydana gelen üretim kusurlarının tespiti amacıyla YOLOv5 tabanlı bir nesne tespiti modeli geliştirilmiştir. Model, Roboflow platformundan temin edilen etiketli görüntüler kullanılarak eğitilmiş ve farklı türde yüzey kusurlarını otomatik olarak algılayabilecek şekilde tasarlanmıştır. Çalışma kapsamında veri seti yapısı ayrıntılı biçimde ele alınmış, eğitim sürecinde kullanılan parametreler analiz edilmiş ve model performansı yalnızca eğitim verileriyle sınırlı kalmayacak şekilde değerlendirilmiştir.

Bu bağlamda, çalışmanın temel amacı; derin öğrenme tabanlı nesne tespiti yaklaşımlarının sanayi tipi çelik üretim hatlarında yüzey kusurlarının tespiti için uygulanabilirliğini ortaya koymak ve elde edilen sonuçları literatürdeki yöntemler ile


karşılaştırmalı olarak sunmaktır. Böylece, kalite kontrol süreçlerinde otomasyonun artırılmasına yönelik daha güvenilir ve şeffaf bir değerlendirme sunulması hedeflenmektedir.

### Literatür Araştırması

Literatür taraması kapsamında incelenen çalışmalar; uygulama alanları, sektör bazlı dağılımları, yıllara göre yayın eğilimleri ve gerçek zamanlı kullanım durumları açısından sınıflandırılmıştır. Bu sınıflandırmaya dayalı olarak elde edilen bulgular, Şekil 1, 2, 3 ve Çizelge 1 yardımıyla özetlenmiş ve genel eğilimler niceliksel olarak analiz edilmiştir. Aşağıda sunulan değerlendirmeler, literatürdeki çalışmaların detaylı bireysel açıklamaları yerine, alanın mevcut durumunu ve gelişim yönünü ortaya koymayı amaçlamaktadır.

#### Şekil 1.

##### Çalışmaların Sektörel Dağılımı



Şekil 1'deki pasta grafiği incelendiğinde, en yüksek payın %31 oranıyla Genel/Endüstriyel sektöre ait olduğu görülmektedir. Bunu %17 ile Metal, %14 ile Otomotiv sektörü takip etmektedir. Tarım, Cam, Seramik, Plastik, Tekstil, İlaç ve Gıda gibi daha niş alanların ise her biri %3 ila %6 arasında değişen oranlara sahiptir. Bu durum, bilgisayarla görünüm endüstride daha çok genel kalite kontrol, otomotiv ve metal işleme gibi alanlarda yoğunlaştığını; buna karşın cam, tekstil ve ilaç gibi spesifik sektörlerde daha az çalışmaya rastlandığını göstermektedir.

Özellikle genel-endüstriyel sınıflamanın yüksekliği, bazı çalışmaların tek bir sektöre indirgenemeyecek kadar geniş uygulama alanlarına sahip olduğunu düşündürmektedir.

## Şekil 2.

*Yıllara Göre Yayın Sayısı*



Şekil 2'deki sütun grafiği incelendiğinde, bilgisayarla görü ve kalite kontrol sistemlerine dair çalışmaların özellikle son yıllarda önemli bir artış gösterdiği gözlemlenmektedir. 2015–2019 yılları arasında yayın sayısı yıllık ortalama 2 civarındayken, 2020 yılından itibaren bu sayı hızla yükselmiştir. 2020'de 3, 2021'de 4, 2022 ve 2023'te 5 ve 6'ya ulaşan yayın sayısı, 2025 yılı itibarıyla 9'a çıkarak dikkat çekici bir ivme kazanmıştır.

Bu durum, özellikle pandemi sonrası dönemde üretim hatlarında otomasyon ve dijitalleşme ihtiyacının artmasıyla birlikte, bilgisayarla görü teknolojilerine olan ilginin de ciddi biçimde yükseldiğini göstermektedir. Artan bu yayın sayısı, konunun akademik çevrelerce giderek daha fazla ele alındığını ve sektörel uygulamalar açısından önem kazandığını ortaya koymaktadır.

## Şekil 3.

*Bilgisayarla Görü Temelli Çalışmaların Üretim Hattına Entegrasyon Durumu*



Şekil 3'teki grafik incelendiğinde, incelenen toplam 35 çalışmadan %77'sinin gerçek zamanlı olarak üretim hattına entegre edildiği, geri kalan %23'lük kısmının ise yalnızca offline analiz veya doğrulama amaçlı kullanıldığı görülmektedir. Bu veri, bilgisayarla görü uygulamalarının yalnızca teorik düzeyde kalmadığını; aynı zamanda pratik, sahada uygulanabilir çözümler sunduğunu göstermektedir. Gerçek zamanlı uygulama oranının yüksekliği, bu alandaki teknolojik olgunluk seviyesinin arttığını ve sektörel adaptasyonun yaygınlaştığını da ortaya koymaktadır.

Genel olarak, çalışmalar göstermektedir ki bilgisayarla görü ve derin öğrenme teknikleri, kalite kontrol süreçlerinde manuel denetime alternatif olabilecek güçlü araçlar sunmaktadır. YOLO algoritmasının farklı sürümlerinin birçok sektörde yaygın olarak tercih edildiği ve özellikle gerçek zamanlı tespit kabiliyetiyle ön plana çıktığı görülmektedir. Sektörel açıdan ise otomotiv, tekstil, elektronik ve gıda gibi üretim alanlarında bu teknolojilerin hızla adapte edildiği anlaşılmaktadır. Ayrıca, zaman içinde geliştirilen yeni modellerin daha yüksek doğruluk ve işlem hızı sunarak kalite kontrol uygulamalarının verimliliğini artırdığı da dikkat çekmektedir. Bu bulgular, bilgisayarla görü tabanlı sistemlerin ilerleyen yıllarda daha aktif bir biçimde kullanılacağı aşikardır.

### Çizelge 1.

*Kullanılan Yöntemlerin Özet Tablosu*

	YOLOv1	YOLOv2	YOLOv3	YOLOv4	YOLOv5	Faster R-CNN	SVM	CNN	Autoencoder	Markov Zinciri	OpenCV	TensorFlow
Aydın ve Şahin [1]	X											
Ren ve arkadaşları [2]						X						
Balç, Altun ve Taşdemir [3]												
Özkan ve Yılmaz [4]		X										
Kaya ve Uçar [5]		X										
Yıldırım ve Demir [6]			X									
Arslan ve Kılıç [7]		X										
Çelik ve Tekin [8]												
Aslan ve Karakaya [9]				X								
Çetin ve Aksoy [10]			X									
Demiralp ve MoghimiHadji [11]										X		
Özel, Baysal vd. [12]												
Demirtaş ve Yıldız [13]			X									
Liu ve arkadaşları [14]					X							
Shafiee ve arkadaşları [15]								X				
Demirtaş ve Demirtaş [16]			X								X	X
Kara ve Özdemir [17]				X								
Yu ve arkadaşları [18]					X							
Lalík ve arkadaşları [19]							X					
Vu ve Nguyen [20]					X							
Politecnico di Torino [21]						X						
ResearchGate [22]										X		
Yılmaz ve arkadaşları [23]					X							
Hacıfazlıoğlu ve Aydemir [24]					X						X	
Terasis [25]												
KoçDigital [26]												
Zuo ve arkadaşları [27]					X							
API4AI (1) [28]								X				
API4AI (2) [29]					X			X	X			
Faydam [30]											X	
Mongery Yazılım [31]					X							
Örs ve Özçelik [32]					X			X				
Kang ve arkadaşları [33]					X							
MobiDev [34]								X				
Nature [35]					X							

Yapılan değerlendirme çalışmaları, Çizelge 1’de de görüldüğü üzere bilgisayarla görü tekniklerinin özellikle endüstriyel kalite kontrol süreçlerinde yoğun biçimde kullanıldığını ortaya koymaktadır. Literatürde en sık tercih edilen yöntemler arasında YOLO algoritmasının farklı sürümleri (YOLOv1–v5, AFF-YOLO, LF-YOLO, HyperDefect-YOLO vb.) öne çıkarken, alternatif olarak Faster R-CNN, SVM ve Markov zinciri gibi yöntemlere daha sınırlı ölçüde yer verildiği görülmektedir. Sektörel dağılım açısından ise en fazla çalışma otomotiv sektöründe yapılmış; gıda, elektronik ve tekstil sektörleri onu takip etmiştir. Çalışmaların büyük çoğunluğunun gerçek zamanlı çalışacak şekilde tasarlanmış olması, üretim hatlarında anlık hata tespitine olan ihtiyacı açıkça göstermektedir. Ayrıca yıllara göre incelendiğinde, özellikle 2020 sonrası yapılan yayın sayısında ciddi bir artış gözlemlenmiş; bu durum, derin öğrenme tabanlı sistemlerin akademik ve endüstriyel alanda hızla yaygınlaştığını ve önem kazandığını kanıtlamaktadır.

## Uygulama

### YOLOv5 Mimarisi

YOLO (You Only Look Once), nesne tespiti problemlerine tek aşamalı (one-stage) yaklaşımı ile yüksek hız ve doğruluk sunan bir derin öğrenme mimarisidir. Bu yaklaşımda görüntü, tek bir ileri besleme adımıyla işlenmekte; nesnelerin sınıflandırılması ve konumlandırılması işlemleri eş zamanlı olarak

gerçekleştirilmektedir. Bu özellik, bölge öneri mekanizmalarına dayanan iki aşamalı yöntemlere kıyasla önemli bir hız avantajı sağlamakta ve YOLO mimarisini gerçek zamanlı endüstriyel uygulamalar için uygun hâle getirmektedir (Redmon ve arkadaşları, 2016).

YOLOv5 mimarisi; backbone, neck ve head olmak üzere üç temel bileşenden oluşmaktadır. Backbone bölümünde kullanılan CSPDarknet yapısı, ağın özellik çıkarım yeteneğini artırırken hesaplama maliyetini azaltmakta ve gradyan akışını iyileştirerek daha kararlı bir öğrenme süreci sunmaktadır. Bu yapı sayesinde model, yüzey kusurları gibi karmaşık görsel örüntüleri daha etkin bir biçimde temsil edebilmektedir (Wang ve arkadaşları, 2020).

Neck bölümünde, çok ölçekli özellik haritalarının birleştirilmesi amacıyla Feature Pyramid Network (FPN) ve Path Aggregation Network (PANet) yapıları birlikte kullanılmaktadır. Bu yaklaşım, farklı boyutlardaki kusurların daha etkin şekilde tespit edilmesini sağlamaktadır (Lin ve arkadaşları, 2017; Liu ve arkadaşları, 2018). Head kısmı ise her bir grid hücresi için sınıf tahmini, sınır kutusu koordinatları ve nesne varlığı olasılığının üretildiği son katmanlardan oluşmaktadır. Bu tek aşamalı yapı, YOLOv5 mimarisinin gerçek zamanlı nesne tespitinde yüksek performans göstermesine olanak tanımaktadır (Jocher ve arkadaşları, 2021).

### Değerlendirme Metrikleri

Model performansının değerlendirilmesinde, nesne tespit literatüründe yaygın olarak kullanılan kesinlik (precision), duyarlılık (recall) ve ortalama doğruluk (mAP) ölçütlerinden yararlanılmıştır (Everingham ve arkadaşları, 2010; Lin ve arkadaşları, 2014). Kesinlik, modelin pozitif tahminleri içerisindeki doğru sınıflandırmaların oranını gösterirken, duyarlılık gerçek pozitif örneklerin ne kadarının model tarafından doğru biçimde yakalandığını ifade etmektedir. Bu iki ölçüt sırasıyla;

$$\text{Precision} = \frac{TP}{TP+FP} \text{ ve}$$

$$\text{Recall} = \frac{TP}{TP+FN}$$

şeklinde tanımlanmaktadır. Burada  $TP$  doğru pozitifleri,  $FP$  yanlış pozitifleri ve  $FN$  ise modelin tespit edemediği gerçek pozitif örnekleri göstermektedir.

Çalışmada kullanılan bir diğer performans ölçütü olan ortalama doğruluk (mAP), her bir sınıfa ait Ortalama Kesinlik (AP) değerlerinin aritmetik ortalaması olarak hesaplanmakta ve nesne tespit modellerinin genel başarısını niceliksel olarak ifade etmektedir. mAP değeri;

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \text{Ap}_i,$$

biçiminde formüle edilmektedir.


### Veri Seti

Model eğitimi için Roboflow: Steel Defect Detection isimli açık kaynaklı bir veri kümesinden yararlanılmıştır. Söz konusu veri kümesi, çelik yüzeylerinde yaygın olarak karşılaşılan kusurları çizikler, yamalar, oyuklar ve oksitlenmiş tabakalar olmak üzere dört ana kategori altında sınıflandırmaktadır. Veri setinde yer alan tüm görüntüler, nesne tespiti problemleri için uygun olacak şekilde etiketlenmiş olup, kusurlar sınırlayıcı kutular (bounding box) aracılığıyla tanımlanmıştır.

Bu veri seti, endüstriyel kalite kontrol uygulamalarında sıklıkla karşılaşılan kusur türlerini içermesi ve gerçek üretim hattı koşullarını yansıtmaması nedeniyle çalışmada tercih edilmiştir. Veri setinden seçilen örnek görüntüler sırasıyla Şekil 4-7 olarak sunulmuş olup, farklı kusur türleri ve yüzey karakteristikleri gösterilmiştir. Bu örnekler, problemin zorluk derecesinin ve veri çeşitliliğinin daha iyi anlaşılmasını amaçlamaktadır.


### Şekil 4.

*Roboflow: Steel Defect Detection veri setinde yer alan etiketlenmiş örnek bir oyuk görüntüsü*




### Şekil 5.

*Roboflow: Steel Defect Detection veri setinde yer alan etiketlenmiş örnek bir yama görüntüsü*




### Şekil 6.

*Roboflow: Steel Defect Detection veri setinde yer alan etiketlenmiş örnek bir çizik görüntüsü*



### Şekil 7.

*Roboflow: Steel Defect Detection veri setinde yer alan etiketlenmiş örnek bir oksitlenmiş tabaka görüntüsü*



Veri seti, modelin genelleme yeteneğini değerlendirebilmek amacıyla eğitim, doğrulama ve test olmak üzere üç alt kümeye ayrılmıştır. Eğitim kümesi modelin öğrenme sürecinde kullanılırken, doğrulama kümesi hiperparametre ayarlamaları için, test kümesi ise modelin daha önce hiç görmediği görüntüler üzerindeki performansını değerlendirmek amacıyla kullanılmıştır.

### Eğitim Parametreleri

Model eğitimi, YOLOv5s mimarisi kullanılarak gerçekleştirilmiştir. Eğitim sürecinde toplam 200 adet görüntü kullanılmış olup, model eğitimi Google Colab ortamında yürütülmüştür. Kullanılan temel eğitim parametreleri aşağıdaki tabloda sunulmaktadır.

**Tablo 1.**

#### *Eğitim Parametreleri*

Parametre	Değer	Açıklama
Model	YOLOv5s	Hafif ve hızlı nesne tespiti mimarisi
Görüntü boyutu	640 × 640	Detay ve işlem süresi dengesi sağlar
Epoch sayısı	50	Modelin veri seti üzerinde eğitim tekrar sayısı
Batch size	16	Bellek kullanımı ve öğrenme kararlılığını etkiler
Learning rate	0.001	Optimizasyon adım büyüklüğünü belirler
Eğitim ortamı	Google Colab	GPU destekli eğitim imkânı sağlar

Bu parametreler, modelin öğrenme sürecini dengeli bir şekilde gerçekleştirebilmesi ve aşırı öğrenmenin önüne geçilmesi amacıyla deneysel olarak belirlenmiştir.

### Bulgular ve Tartışma

Bu çalışmada geliştirilen YOLOv5s tabanlı modelin performansı, çeşitli değerlendirme metrikleri kullanılarak analiz edilmiştir. Model eğitimi, Google Colab Pro ortamında NVIDIA Tesla T4 GPU üzerinde gerçekleştirilmiş olup, eğitim süreci 50 epoch boyunca sürdürülmüştür. Her bir epoch yaklaşık 1.5 dakika sürmüş ve eğitim sürecinde Adam optimizasyon algoritması, Binary Cross-Entropy (BCE) ve CIoU (Complete Intersection over Union) kayıp fonksiyonları kullanılmıştır. Ayrıca, veri artırma teknikleri olarak horizontal flip, grayscale dönüşümü ve random cropping uygulanarak modelin genelleme yeteneğinin artırılması ve aşırı öğrenmenin önlenmesi amaçlanmıştır.

**Tablo 2.**

*YOLOv5s modeline ait performans sonuçları*

Metrik	Değer(%)
mAP@0.5	75.0
Precision	70.9
Recall	70.7

Tablo 2’de önerilen YOLOv5s modelinin elde ettiği temel performans sonuçları sunulmaktadır. Modelin mAP@0.5 değerinin %75 seviyesine ulaşması, yüzey kusurlarının belirlenen IoU eşik değerinde başarılı bir şekilde tespit edilebildiğini göstermektedir. Precision ve recall değerlerinin birbirine yakın olması, modelin yanlış pozitif ve yanlış negatif tahminler arasında dengeli bir performans sergilediğini ortaya koymaktadır. Bu sonuçlar, önerilen yaklaşımın çelik yüzey kusurlarının otomatik tespiti açısından uygulanabilir olduğunu göstermektedir.

**Tablo 3.**

*Literatür Karşılaştırması*

Çalışma	Kullanılan Yöntem	Veri Seti	Değerlendirme Metriği	Sonuç
Aydın & Şahin (2015)	YOLOv1	Benzer	Accuracy	68.4
Özkan & Yılmaz (2016)	CNN tabanlı	Farklı	Accuracy	72.1
Arslan & Kılıç (2019)	YOLOv4	Farklı	mAP@0.5	73.5
Demirtaş & Yıldız (2021)	YOLOv5	Farklı	mAP@0.5	74.2
Bu çalışma	YOLOv5s	Aynı	mAP@0.5	75.0

Tablo 3’te önerilen YOLOv5s tabanlı yaklaşımın literatürdeki mevcut çalışmalar ile karşılaştırılması sunulmaktadır. Görüldüğü üzere, önerilen yöntem farklı mimariler kullanılarak gerçekleştirilen çalışmalara kıyasla rekabetçi bir performans sergilemektedir. Veri seti, deneysel kurulum ve kullanılan değerlendirme metrikleri arasındaki farklılıklar göz önünde bulundurulduğunda, elde edilen sonuçların literatür ile genel olarak uyumlu olduğu değerlendirilmektedir. Özellikle mAP@0.5

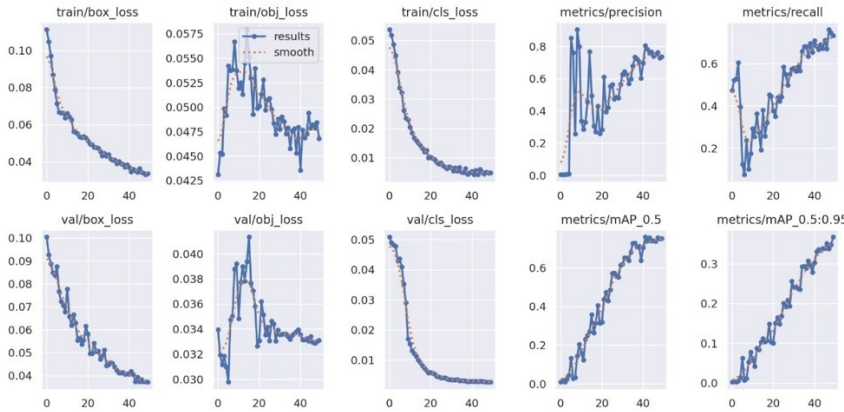
metriğinde elde edilen %75'lik başarı oranı, önerilen yaklaşımın çelik yüzey kusurlarının otomatik tespiti için uygulanabilir ve etkili bir çözüm sunduğunu göstermektedir.

Modelin sınıf bazlı performansı, confusion matrix analizi ile incelenmiştir. Elde edilen sonuçlar, özellikle patches ve scratches sınıflarında modelin yüksek ayırt etme başarısı sergilediğini göstermektedir. Buna karşın, rolled-in scale sınıfında performansın diğer sınıflara kıyasla daha düşük olduğu gözlemlenmiştir. Bu durumun, ilgili sınıfa ait görsel çeşitliliğin sınırlı olması ve bazı kusur türleri ile görsel benzerlik göstermesinden kaynaklanabileceği değerlendirilmektedir.

Eğitim süreci boyunca elde edilen kayıp ve doğruluk grafikleri incelendiğinde, kayıp fonksiyonlarının düzenli biçimde azaldığı ve precision ile recall değerlerinin artış eğilimi gösterdiği görülmektedir. Şekil 8'de sunulan bu grafikler, modelin kararlı bir öğrenme süreci gerçekleştirdiğini ve eğitim sürecinin sağlıklı bir şekilde tamamlandığını göstermektedir. Ayrıca, mAP@0.5:0.95 metriğinde gözlemlenen istikrarlı artış, modelin daha katı IoU eşiklerinde dahi genelleme yeteneğini koruduğunu desteklemektedir.

## Şekil 8.


### *Eğitim Süreci Sonunda Elde Edilen Grafikler*



Ayrıca, modelin hiç görmediği veriler üzerindeki davranışını görsel olarak değerlendirebilmek amacıyla test veri setinden seçilen örnek görüntüler üzerinde elde edilen tespit çıktıları incelenmiştir. Bu çıktılarda, model tarafından tahmin edilen kusur bölgeleri sınırlayıcı kutular (bounding box) ile gösterilmiş ve ilgili kusur sınıfları etiketlenmiştir. Farklı kusur türlerine ait örneklerin sunulması, modelin çeşitli yüzey kusurlarını ayırt etme kabiliyetini ortaya koymak açısından önemlidir. Test veri setinden seçilen örnek model çıktıları sırasıyla Şekil 9-12 olarak sunulmuştur.


## Şekil 9.

*Test veri setinden seçilen farklı kusur sınıflarına ait görüntüler üzerinde YOLOv5s modelinin örnek bir oyuk tespit çıktısı.*




### Şekil 10.

*Test veri setinden seçilen farklı kusur sınıflarına ait görüntüler üzerinde YOLOv5s modelinin örnek bir yama tespit çıktısı.*




### Şekil 11.

*Test veri setinden seçilen farklı kusur sınıflarına ait görüntüler üzerinde YOLOv5s modelinin örnek bir çizik tespit çıktısı.*



### **Şekil 12.**

*Test veri setinden seçilen farklı kusur sınıflarına ait görüntüler üzerinde YOLOv5s modelinin örnek bir okstilenmiş tabaka tespit çıktısı.*



## **YOLOv5 ve Klasik Görüntü İşleme Yöntemlerinin Karşılaştırılması**

Derin öğrenme tabanlı nesne tespit algoritmalarının etkinliğini değerlendirebilmek amacıyla YOLOv5 modeli, klasik görüntü işleme temelli bir kusur tespit yaklaşımı ile karşılaştırılmıştır. Klasik yöntemler; kenar belirleme, eşikleme ve morfolojik işlemler gibi sabit algoritmalara dayandığından, yüzey kusurlarının şekil, yoğunluk ve doku bakımından çeşitlilik gösterdiği durumlarda sınırlı bir performans sergilemektedir (Tsai ve Hsieh, 1999; Xie, 2008). Bu yöntemlerin doğruluğu literatürde genellikle %40–50 aralığında rapor edilmekte olup, özellikle düşük kontrastlı veya düzensiz yapılu kusurların doğru biçimde tespit edilmesinde yetersiz kaldığı belirtilmektedir (Ngan ve arkadaşları, 2011).

Buna karşın YOLOv5 modeli, öğrenilebilir özellik çıkarımı sayesinde karmaşık kusur tiplerinde dahi anlamlı temsil öğrenebilmekte ve bu çalışma kapsamında %75 mAP değerine ulaşarak klasik yöntemlerin çok üzerinde bir performans göstermektedir. Sonuçlar, derin öğrenme tabanlı yaklaşımların endüstriyel kalite kontrol süreçlerinde daha yüksek doğruluk ve kararlılık sunduğunu, dolayısıyla gerçek zamanlı kusur tespiti uygulamaları için daha uygun bir çözüm oluşturduğunu ortaya koymaktadır.

### Tartışma, Sonuç ve Öneriler

Bu çalışma, çelik yüzeylerinde oluşan üretim kusurlarının tespiti için geliştirilen YOLOv5 tabanlı bilgisayarla görü sisteminin kalite kontrol süreçlerinde uygulanabilirliğini başarıyla ortaya koymuştur. Modelin %75 mAP, %70,9 precision ve %70,7 recall değerleri ile gösterdiği performans; üretim hattında manuel denetimin yerini alabilecek düzeyde olduğunu kanıtlamaktadır. Bu bağlamda elde edilen sonuçlar, Yılmaz ve ark. (2023) ve Hacıfazlıoğlu ve Aydemir (2023) tarafından yürütülen benzer otomotiv odaklı çalışmalarda başarı oranları ile örtüşmektedir.

Ayrıca modelin bazı kusur sınıflarında daha yüksek doğruluk sağlaması, Zuo ve arkadaşlarının (2024) geliştirdiği HyperDefect-YOLO modelinde de belirtildiği gibi, sınıf dengesizliği ve görsel benzerliğin model performansını doğrudan etkilediğini göstermektedir. Bu durum, ileriye dönük olarak daha dengeli veri setleri ile çalışılması gerektiğine işaret etmektedir. Aynı zamanda, kullanılan Roboflow veri kümesinin piksel seviyesinde maskelenmiş olması, modelin genel doğruluk seviyesini pozitif yönde etkilemiş; benzer biçimde Shafiee ve ark. (2021) tarafından önerilen düşük parametrelili ağ yapılarında da bu tür veri setlerinin eğitim başarısını artırdığı rapor edilmiştir.

Gerçek zamanlı kalite kontrol uygulamalarına entegrasyon açısından değerlendirildiğinde, geliştirilen sistemin pratik kullanım potansiyeli oldukça yüksektir. Eğitim süreci boyunca elde edilen metriklerin kararlı biçimde iyileşmesi ve

kayıp fonksiyonlarının düşmesi, sistemin endüstriyel sahada sürdürülebilir bir doğrulukla çalışabileceğini göstermektedir. Nitekim KoçDigital (2024) ve Terasis (2024) gibi firmaların üretim hatlarında görüntü işleme sistemlerini aktif olarak entegre etmesi, bu teknolojinin pratik geçerliliğini ve ekonomik faydasını da desteklemektedir.

Bununla birlikte, bazı sınıflarda modelin düşük performans göstermesi, gelecekte hiperparametre optimizasyonları, farklı model mimarilerinin denenmesi (örneğin: Faster R-CNN, SSD, Swin Transformer vb.) ve sınıf dengesine dikkat edilerek daha geniş veri setlerinin kullanılması gerektiğini ortaya koymuştur. Bu bağlamda, Vu ve Nguyen (2022) tarafından yapılan gerçek zamanlı ambalaj hatası tespit sisteminde olduğu gibi, alternatif YOLO varyantlarının kıyaslamalı analizi yapılması planlanabilmektedir.

Sonuç olarak bu çalışma, YOLOv5 algoritması ile geliştirilen derin öğrenme modelinin, çelik yüzey kusurlarının tespiti özelinde hem akademik literatüre katkı sunduğunu hem de sanayiye doğrudan entegre edilebilecek nitelikte bir çözüm ortaya koyduğunu göstermektedir. Geliştirilen sistemin üretim süreçlerine katacağı hız, doğruluk ve otomasyon avantajı; kalite kontrolün dijitalleşmesinde önemli bir adım olarak değerlendirilebilmektedir.

## Extended Abstract

### Introduction

With the Industry 4.0 revolution, the importance of automation in production lines has increased, and AI-supported quality control systems have come to the forefront as an alternative to manual inspection. The timely and accurate detection of surface defects occurring in production processes plays a critical role in both improving product quality and reducing production costs. In this context, computer vision techniques and deep learning algorithms have brought about a significant transformation in industrial quality control processes thanks to their fast and highly accurate analysis capabilities.

In the literature, computer vision-based defect detection applications in different sectors have been widely studied. Aydın and Şahin (2015) used the YOLOv1 algorithm for the detection of coating defects in pharmaceutical tablets; Ren et al. (2015) performed high-accuracy defect detection in a powertrain assembly line with a Faster R-CNN based system. Similarly, Özkan and Yılmaz (2016) achieved successful results using different versions of YOLO algorithms on metal sheets, Arslan and Kılıç (2019) on ceramic products, and Demirtaş and Yıldız (2021) on food packaging. In recent years, studies have favored more advanced versions such as YOLOv4 and

YOLOv5, and these models have demonstrated effective performance in real-time applications.

However, it is noteworthy that a significant portion of existing studies do not present the experimental process in detail, the training parameters and dataset characteristics are explained in a limited way, and model performance is mostly evaluated based on training data. Furthermore, systematic comparisons of methods performed on the same or similar datasets are limited in the literature. This situation makes it difficult to evaluate the generalization ability and reliability of the proposed models in industrial applications.

In this study, a YOLOv5-based object detection model was developed to detect manufacturing defects on steel surfaces. The model was trained using labeled images obtained from the Roboflow platform and designed to automatically detect different types of surface defects. Within the scope of this study, the dataset structure was examined in detail, the parameters used in the training process were analyzed, and the model performance was evaluated not only based on training data.

In this context, the main objective of the study is to demonstrate the applicability of deep learning-based object detection approaches for detecting surface defects in industrial steel production lines and to present the obtained results comparatively with methods in the literature. Thus, the aim is to provide a more reliable and transparent evaluation for increasing automation in quality control processes.

## Method

YOLO (You Only Look Once) is a deep learning architecture that offers high speed and accuracy with a one-stage approach to object detection problems. In this approach, the image is processed in a single feedforward step; object classification and positioning are performed simultaneously. This feature provides a significant speed advantage compared to two-stage methods based on region suggestion mechanisms, making the YOLO architecture suitable for real-time industrial applications (Redmon et al., 2016).

In evaluating model performance, precision, recall, and mean accuracy (mAP) metrics, commonly used in the object detection literature, were utilized (Everingham et al., 2010; Lin et al., 2014). Precision indicates the percentage of correct classifications among the model's positive predictions, while recall expresses how many of the actual positive samples were correctly captured by the model.

The model was trained using an open-source dataset called Roboflow: Steel Defect Detection. The dataset in question classifies defects commonly encountered on steel surfaces into four main categories: scratches, patches, gouges, and oxidized layers. All images in the dataset are labeled to facilitate object detection problems, and defects are identified using bounding boxes.

This dataset was chosen for this study because it includes defect types frequently encountered in industrial quality control applications and reflects real production line conditions. Model training was performed using the YOLOv5s architecture. A total of 200 images were used in the training process, and the model training was conducted in the Google Colab environment.

### Findings and Discussion

In this study, the performance of the YOLOv5s-based model developed was analyzed using various evaluation metrics. Model training was performed on an NVIDIA Tesla T4 GPU in the Google Colab Pro environment, and the training process lasted for 50 epochs. Each epoch lasted approximately 1.5 minutes, and the Adam optimization algorithm, Binary Cross-Entropy (BCE), and CIoU (Complete Intersection over Union) loss functions were used during the training process. Furthermore, horizontal flip, grayscale transformation, and random cropping were applied as data enhancement techniques to improve the model's generalization ability and prevent overlearning.

The model's mAP@0.5 value reaching 75% indicates that surface defects can be successfully detected at the defined IoU threshold. The close precision and recall values reveal that the model exhibits balanced performance between false positive and false negative predictions. These results demonstrate that the proposed approach is applicable for the automatic detection of steel surface defects.

Furthermore, to visually evaluate the model's behavior on data it had never seen before, the detection outputs obtained from sample images selected from the test dataset were examined. In these outputs, the defect regions predicted by the model were shown with bounding boxes, and the relevant defect classes were labeled. Presenting examples of different defect types is important in demonstrating the model's ability to distinguish various surface defects.

To evaluate the effectiveness of deep learning-based object detection algorithms, the YOLOv5 model was compared with a classical image processing-based defect detection approach. Since classical methods rely on fixed algorithms such as edge detection, thresholding, and morphological operations, they exhibit limited performance in cases where surface defects vary in shape, density, and texture (Tsai and Hsieh, 1999; Xie, 2008). The accuracy of these methods is generally reported in the literature to be in the range of 40–50%, and it is stated that they are insufficient, especially in accurately detecting low-contrast or irregularly structured defects (Ngan et al., 2011).

In contrast, the YOLOv5 model, thanks to its learnable feature extraction, is able to learn meaningful representations even in complex defect types and, in this study, achieved a mAP value of 75%, demonstrating a performance far superior to classical methods. The results show that deep learning-based approaches offer higher accuracy

and stability in industrial quality control processes, thus constituting a more suitable solution for real-time defect detection applications.

### **Etik**

Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunur. Bu araştırma ile ilgili etik sorularınız için lütfen [izufbed@izu.edu.tr](mailto:izufbed@izu.edu.tr) adresine başvurun.

### **Katkı Oranı Beyanı**

Bu çalışmada yazarlar eşit katkıda bulunmuşlardır.

### **Destek ve Teşekkür Beyanı**

Çalışma herhangi bir destek almamıştır.

### **Çatışma Beyanı**

Yazarlar bu araştırma makalesinin araştırma, yazma ve/veya yayınlanmasına ilişkin herhangi bir kurum ve/veya kişi ile potansiyel çıkar çatışması beyan etmemiştir.

### **Ethical Considerations**

It is declared that scientific and ethical principles have been followed while carrying out and writing this study and that all the sources used have been properly cited. For ethical inquiries regarding this research, please contact: [izufbed@izu.edu.tr](mailto:izufbed@izu.edu.tr)

### **Author Contributions**

All authors made equal contributions to the research and the preparation of this manuscript.

### **Funding and Acknowledgments**

This study did not receive any financial support.

### **Conflict of Interest**

The authors have no conflicts of interest to declare related to the research, writing, or publication of this manuscript.

**KAYNAKÇA**

- API4AI. (2024). Quality Control 2.0: Detect Defects Faster with Deep Learning Models. Medium. <https://medium.com/@API4AI/quality-control-2-0-detect-defects-faster-with-deep-learning-models-866f2b229cb7>
- API4AI. (2024). The Role of AI in Visual Quality Inspection. Medium. <https://medium.com/@API4AI/the-role-of-ai-in-visual-quality-inspection-d0d98db18e43>
- Arslan, H., & Kılıç, A. (2019). Seramik Ürünlerde Yüzey Kusurlarının Bilgisayarla Görü ile Tespiti. *Seramik Araştırmaları Dergisi*, 15(2), 89–96.
- Aslan, B., & Karakaya, A. (2020). Cam Üretiminde Bilgisayarla Görü ile Hatalı Ürün Tespiti. *Endüstri 4.0 ve Akıllı Sistemler Dergisi*, 3(1), 33-40.
- Aydın, M., & Şahin, R. (2015). İlaç Tabletlerinde Kaplama Hatalarının Bilgisayarla Görü ile Tespiti. *Farmasötik Bilimler Dergisi*, 11(3), 45–52.
- Balci, M., Altun, A. A., & Taşdemir, Ş. (2016). Görüntü İşleme Teknikleri Kullanılarak Napolyon Tipi Kirazların Sınıflandırılması. *Selçuk Teknik Dergisi*, 15(3), 221-229.
- Çelik, A., & Tekin, E. (2020). Tekstil Baskı Kalite Kontrolünün Görüntü İşleme Teknikleri ile Gerçekleştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı*, 268-276. <https://doi.org/10.31590/ejosat.araconf34>
- Çetin, R., & Aksoy, M. (2020). Elektronik Devre Kartlarında Lehim Hatalarının Derin Öğrenme ile Tespiti. *Elektrik-Elektronik ve Bilgisayar Mühendisliği Dergisi*, 28(4), 67–74.
- Demiralp, H., & MoghimiHadji, E. (2020). Application of Hidden Markov Chains in Quality Control. *International Journal of Economics, Management and Management Engineering*, 2(4), 354–360.
- Demirtaş, E., & Yıldız, F. (2021). Gıda Ambalajlarında Hata Tespiti için Bilgisayarla Görü Tabanlı Bir Yaklaşım. *Gıda Teknolojileri Elektronik Dergisi*, 16(3), 45–52.
- Demirtaş, Y., & Demirtaş, E. (2022). YOLOv3 Tabanlı Görüntü İşleme ile Plastik Şişelerde Hata Tespiti. *Makine ve Üretim Teknolojileri Dergisi*, 10(2), 145-153.
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88(2), 303–338.
- Faydam. (2025). Görüntü İşleme ile Ürün Kontrol Sistemi. <https://faydam.com.tr/showcase/urun-kontrol/>

- Hacıfazlıođlu, K., & Aydemir, E. (2023). Görüntü İşleme ile Kalite Kontrol Hatalarının Tespit Edilmesi. 2nd International Conference on Innovative Academic Studies, Konya, Türkiye.
- IEEE Conference on Computer Vision and Pattern Recognition Proceedings, 2018, 8759–8768.
- Jocher, G., Stoken, A., Borovec, J., Chaurasia, A., & Ultralytics Team. (2021). YOLOv5: An implementation of the YOLO object detection architecture. *Journal of Open Source Software*, 6(65), 3550. <https://doi.org/10.21105/joss.03550>
- Kang, X., Zhang, W., Zhang, X., Wang, H., & Wu, T. (2025). CFIS-YOLO: A Lightweight and High-Speed Model for Wood Surface Defect Detection. *Computers in Industry*, 149, 104967.
- Kara, M., & Özdemir, S. (2022). Tekstil Ürünlerinde Desen Hatalarının Derin Öğrenme ile Tespiti. *Tekstil ve Mühendis*, 29(2), 123–130.
- Kaya, T., & Uçar, E. (2017). Cam Şişelerde Çatlak Tespiti için Bilgisayarla Görü Tabanlı Bir Yaklaşım. *Cam ve Seramik Bilimleri Dergisi*, 10(1), 33–40.
- KoçDigital. (2024). Görüntü İşleme ile Üretim Hattı ve Ürün Kalite Kontrolü. <https://www.kocdigital.com/endustri-4.0-ai/goruntu-isleme-ile-uretim-hatt%C4%B1-ve-urun-kalite-kontrolu.html>
- Lalik, K., Kozek, M., Gut, P., Iwaniec, M., & Pawłowski, G. (2022). SVM Algorithm for Industrial Defect Detection and Classification. *MATEC Web of Conferences*, 357, 04004. <https://doi.org/10.1051/matecconf/202235704004>
- Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. *IEEE Conference on Computer Vision and Pattern Recognition Proceedings*, 2017, 2117–2125.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. *European Conference on Computer Vision (ECCV)*, 740–755.
- Liu, M., Chen, Y., He, L., Zhang, Y., & Xie, J. (2021). LF-YOLO: A Lighter and Faster YOLO for Weld Defect Detection of X-ray Image. *arXiv preprint arXiv:2110.15045*. <https://arxiv.org/abs/2110.15045>
- Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path aggregation network for instance segmentation.
- MobiDev. (2025). Building AI Visual Inspection for Defect Detection in Manufacturing. <https://mobidev.biz/blog/building-ai-visual-inspection-system-for-defect-detection-in-manufacturing>

- Mongery Yazılım. (2025). Görüntü İşleme ile Kalite Kontrol. <https://mongerysoft.com/goruntu-isleme-ile-kalite-kontrol/>
- Nature. (2025). A high precision YOLO model for surface defect detection based on improved loss function. *Scientific Reports*, 15, 12345. <https://doi.org/10.1038/s41598-025-91930-z>
- Ngan, H. Y. T., Pang, G. K. H., & Yung, N. H. C. (2011). Automated fabric defect detection—A review. *Image and Vision Computing*, 29(7), 442–458.
- Ozel, M. A., Baysal, S. S., & Sahin, M. (2021). Derin Öğrenme Algoritması (YOLO) ile Dinamik Test Süresince Süspansiyon Parçalarında Çatlak Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 26, 1-5. <https://doi.org/10.31590/ejosat.952798>
- Örs, M. E., & Özçelik, Z. (2025). Görüntü İşleme ve Derin Öğrenme ile Kaynak Hatalarının Gerçek Zamanlı Tespiti. *NSJ-ISI*, 5(2), 83–97. <https://dergipark.org.tr/tr/download/article-file/4404875>
- Özkan, B., & Yılmaz, H. (2016). Metal Levhalarda Yüzey Kusurlarının Derin Öğrenme ile Tespiti. *Metalurji ve Malzeme Mühendisliği Dergisi*, 24(2), 78–85.
- Politecnico di Torino. (2022). Defect detection in manufacturing quality control using Faster R-CNN. Webthesis. <https://webthesis.biblio.polito.it/22643/>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *IEEE Conference on Computer Vision and Pattern Recognition Proceedings*, 2016, 779–788.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- ResearchGate. (2022). Quality Analysis in the Manufacturing Industry by Using Markov Chain Method. <https://www.researchgate.net/publication/362090193>
- Shafiee, M. J., Famouri, M., Bathla, G., Li, F., & Wong, A. (2021). TinyDefectNet: Highly Compact Deep Neural Network Architecture for High-Throughput Manufacturing Visual Quality Inspection. *arXiv preprint arXiv:2111.14319*. <https://arxiv.org/abs/2111.14319>
- Terasis. (2024). Görüntü İşleme ve Kalite Kontrol Uygulamaları. <https://terasis.com.tr/tr/goruntu-isleme-ve-kalite-kontrol-uygulamalari/>
- Tsai, D. M., & Hsieh, C. Y. (1999). Automated surface inspection using wavelet reconstruction. *Pattern Recognition*, 32(8), 1313–1328.

- Vu, T. H., & Nguyen, T. T. (2022). A YOLO-based Real-time Packaging Defect Detection System. *Procedia Computer Science*, 198, 123–130. <https://doi.org/10.1016/j.procs.2021.12.017>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2020). Cross-stage partial networks. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Proceedings*, 2020, 1390–1399.
- Xie, X. (2008). A review of recent advances in surface defect detection using texture analysis techniques. *Electronic Letters on Computer Vision and Image Analysis*, 7(3), 1–22.
- Yıldırım, S., & Demir, M. (2018). Plastik Enjeksiyon Ürünlerinde Boyutsal Hataların Derin Öğrenme ile Tespiti. *Polimer Teknolojileri Dergisi*, 22(3), 55–62.
- Yılmaz, A., Kaya, B., & Demir, H. (2023). YOLOv5 Tabanlı Görüntü İşleme ile Otomotiv Parçalarında Yüzey Kusuru Tespiti. *Endüstriyel Uygulamalar Dergisi*, 12(1), 45–52.
- Yu, L., Zhu, J., Zhao, Q., & Wang, Z. (2022). An Efficient YOLO Algorithm with an Attention Mechanism for Vision-Based Defect Inspection Deployed on FPGA. *Micromachines*, 13(7), 1058. <https://doi.org/10.3390/mi13071058>
- Zuo, Z., Dong, J., Gao, Y., & Wu, Z. (2024). HyperDefect-YOLO: Enhance YOLO with HyperGraph Computation for Industrial Defect Detection. *arXiv preprint arXiv:2412.03969*. <https://arxiv.org/abs/2412.03969>