

## Gerçek Zamanlı Kusur Tespiti: LPG Tüplerinin Yüzeylerinde Kirlilikleri Tanımlama için Görüntü İşleme ve Makine Öğrenimi Teknikleri ile Yenilikçi Bir Yaklaşım

\*Makale Bilgisi / Article Info

Alındı/Received: 21.09.2023

Kabul/Accepted: 07.03.2024

Yayımlandı/Published: 29.04.2024

### Real-Time Defect Detection: An Innovative Approach to Identifying Surface Impurities on LPG Cylinders Using Image Processing and Machine Learning Techniques

Hikmetcan ÖZCAN<sup>1\*</sup>, Tuğrul Hakan GENÇTÜRK<sup>1</sup>, Gülay GENÇ<sup>1</sup>, Taha Erdem YILDIRIM<sup>2</sup>, Fatih DURMUŞ<sup>2</sup>, Atakan GÜRLEYEN<sup>2</sup>

<sup>1</sup> Kocaeli Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye.

<sup>2</sup> Aygaz Anonim Şirketi, Türkiye

© Afyon Kocatepe Üniversitesi

#### Öz

Kusur tespiti yapan sistemlerin tasarımındaki en büyük zorluklardan biri tasarlanan sistemin ne tür kusurlar üzerinde kullanılacağı ve hangi görüntü işleme yöntemlerini kullanacağı belirsizliğidir. Çizik çeşitleri, farklı türde yüzey aşınmaları ve gerçek zamanlı işleme ihtiyacı görüntü işleme ile yapılan kusur tespitinin önündeki zorlayıcı etmenlerden bazılarıdır. Tipik olarak, kusur analizi problemlerini ele almak için istatistiksel, spektral ve model tabanlı yaklaşımlar kullanılabilir. Model tabanlı tekniklerin güçlü bir alt kümesi olan makine öğrenimi, kusur analizinde giderek daha popüler hale gelmiştir. Bu çalışmada LPG dolum tesislerinde kullanılan LPG tüplerinin yüzeylerinde meydana gelen bozulmaların ve kusurların tespit edilmesi amaçlanmıştır. Meydana gelen bozulmalar tüplerin okunabilirliğini azalttığı gibi tüp okuma işlemlerinin doğruluğunu da azaltmaktadır bu sebeple bu bozulmaların tespit edilmesi sistemin doğruluğu açısından büyük önem taşımaktadır. Gerçek zamanlı çalışma hızına sahip olması amacıyla görüntü işleme ve makine öğrenmesi algoritmaları kullanılan yöntem bu yönüyle literatürdeki diğer çalışmalardan ayrılmaktadır. Yöntem, fabrika ortamında oluşturulan veri seti üzerinde uygulanmıştır. Çalışmamızda, temiz olarak tanımlanan LPG tüpleri için kirlilik oranı 2%'den düşük bulunmuştur ve bu tüplerin doğruluk değerlerinin standart sapması ortalama 0.27'dir. Buna karşılık, kirliliği olarak tanımlanan tüplerde ortalama kirlilik oranı 18% olarak tespit edilmiş ve bu tüplerin standart sapması 2.03 olarak hesaplanmıştır.

**Anahtar Kelimeler** Gerçek zamanlı kusur tespiti; Görüntü İşleme; LPG Tüpü; Makine öğrenmesi

#### Abstract

One of the primary challenges in designing defect detection systems lies in the uncertainty surrounding the types of defects the system will address and the image processing methods to be employed. Challenges such as variations in scratches, different kinds of surface wear, and the requirement for real-time processing often complicate defect detection via image processing. Typically, defect analysis can be approached using statistical, spectral, or model-based methods. Among these, machine learning a robust subset of the model-based techniques has gained significant traction in defect analysis. This study aims to identify deteriorations and defects on the surfaces of LPG cylinders used at LPG filling stations. Such deteriorations not only diminish the readability of these cylinders but also adversely affect the accuracy of cylinder reading operations. Consequently, detecting these imperfections is crucial for maintaining system accuracy. Uniquely, our method incorporates both image processing and machine learning algorithms to achieve real-time operational speeds, setting it apart from other literature. This methodology was tested on a dataset generated in an industrial setting. In our study, the dirtiness rate for LPG cylinders identified as clean was below 2%, and the average standard deviation of accuracy values for these cylinders was 0.27. In contrast, the average dirtiness rate for cylinders identified as dirty was 18%, with a higher standard deviation of 2.03.

**Keywords** Real time defect detection; Image processing; Gas cylinder; Machine learning

#### 1. Giriş

Teknolojinin gelişmesine paralel olarak, fabrikalarda büyük miktarda ürünün kısa zamanda üretilmesini

sağlayan seri üretim sistemleri kurulmuştur. Dolayısıyla seri üretim yapan sistemlerdeki ürünlerin kalite kontrolü çok önemli hale gelmiştir (Yorgos et al. 1999). Endüstriyel

ürünlerin kalite denetimi için otomatik hata tespit sistemlerine ihtiyaç duyulmaktadır. Hata kontrol sistemlerinde, kusurlu yüzeylerin görüntü işleme yöntemleri ile tespit edilmesi son zamanlarda popüler hale gelmiştir. Geleneksel görüntü işleme teknikleri belirli bir problem sınıfını çözmeye faydalıdır ancak bu görüntü işleme teknikleri gürültüyü, aydınlatma koşullarındaki değişiklikleri ve karmaşık dokulara sahip arka planları ele almaz. Günümüzde kusurların yoğunluk, şekil ve boyut gibi birçok değişkeni bulunduğundan geniş varyasyonlara uyum sağlayan yöntemlerin geliştirilmesi ihtiyacı ortaya çıkmıştır (Prahari et al. 2021).

Görüntü işleme yönteminin seçilmesi, kusur tespiti yapan sistemlerin tasarımındaki en büyük zorluklardan biridir. Çizik çeşitleri, farklı türde yüzey aşınmaları ve gerçek zamanlı işleme ihtiyacı görüntü işleme ile yapılan kusur tespitinin önündeki zorlayıcı etmenlerden bazılarıdır. Tipik olarak, kusur analizi problemlerini ele almak için istatistiksel, spektral ve model tabanlı yaklaşımlar kullanılabilir. Model tabanlı tekniklerin güçlü bir alt kümesi olan makine öğrenimi, kusur analizinde giderek daha popüler hale gelmiştir. Makine öğreniminin amacı, sonraki işlemler için doğru yargılarda veya tahminlerde bulunmak amacıyla verileri değerlendirmek ve onlardan öğrenmektir. Bu yaklaşım yassı çelik yüzeylerde kusur tanımlama için de önerilmiştir (Ajay 2008).

Demir çelik sektörüne hâkim olan ve tüm ürünlerin 65% inden fazlasını oluşturan yassı çelik, mimari, uçak, makine, otomobil vb. birçok endüstrinin önemli bir bileşenidir. Ana malzemesi yassı çelik olan LPG tüp endüstrisi, üretim ve otomasyon aşamalarında yenilikçi yaklaşımlarıyla dinamikliğini koruyan bir sektördür.

Bu çalışma, çelik LPG tüplerinin üzerindeki kirli bölgelerin tespiti ve bu bölgelerin kirlilik oranının hesaplanması amaçlanmaktadır. Bu amaçla görsel kusur olarak nitelendirilen kirliliği tanımlamadaki en son teorik ve algoritmik yöntemlere odaklanmaktadır. Çalışmanın uygulanacağı ortamı ve kurulan sistemin gereksinimleri göz önünde bulundurularak hızlı ve düşük maliyetli bir algoritmaya ihtiyaç olması sebebiyle literatürde yer alan derin öğrenme yöntemleri yerine hibrit şekilde makine öğrenme yöntemleri tercih edilerek yenilikçi bir yaklaşım ortaya çıkarmak istenmiştir. Belirlenen yöntemlerin uygulanacağı görüntüler fabrika ortamında gerekli koşulları sağlayan sabit bir kamera kullanılarak elde edilmiştir. Görüntüler ilk yaklaşım olan SURF Algoritmasından geçerek bir çıktı oluşturur. Bu çıktıyı ikinci yaklaşım olan DBSCAN Algoritması, girdi olarak alır.

Sonuç olarak almış olduğumuz görüntüler üzerinde iki farklı yaklaşımın ortak ürünü olarak bir kirlilik oranına ulaşılmış olunur. Literatürdeki yöntemler bir sonraki başlık altında incelenmiştir. Kullandığımız yöntemler ayrıntılı olarak metod başlığı altında açıklanmıştır. Deneysel sonuçlar adlı başlıkta yapılan çalışmada elde edilen verilerin ayrıntılarına yer verilmiştir. Tartışma ve sonuç başlığı altında bu çalışmayla ilgili tartışma ve elde edilen sonuçlar sunulmuştur.

## **2. Literatür Taraması**

Mevcut literatürde kusur tespiti için kullanılan yöntemler, esas olarak geleneksel yaklaşımlar ve derin öğrenme tabanlı yaklaşımlar olmak üzere iki ana kategoriye ayrılır (Luo et al. 2020).

### **2.1. Geleneksel yaklaşımlar**

Geleneksel kusur tespit yaklaşımları, genellikle önceden belirlenmiş algoritmalar ve kurallar setine dayanır. Bu yaklaşımlar, belirli bir kusur türünü tanımak için özelleştirilmiş matematiksel ve istatistiksel teknikler kullanır. Geleneksel teknikler arasında kenar tespiti, doku analizi, morfolojik işlemler ve filtreleme yöntemleri bulunur. Bu teknikler, görüntü işleme ve sinyal işleme alanlarında yaygın olarak kullanılır (Luo et al. 2020).

#### **2.1.1. İstatistiksel**

Domen et al. (2020), yüzey bozulmalarını tespit etmek ve bunları bölümlere ayırmak için segmentasyon tabanlı yeni bir yöntem önermişlerdir. Bu yöntem, örnek olarak yüzey çatlaklarının tespiti probleminin çözümü için uygulanmıştır. Önerdikleri yöntem, diğer derin öğrenme yöntemlerinden farklı olarak az sayıda veri ile eğitilerek yüksek doğruluk değerlerine ulaşabilmektedir. Mimarının doğrulanması için bir açık kaynak veri seti kullanılmıştır ve sonuç olarak güncel metotlardan daha iyi bir doğruluk değeri elde edilmiştir. Doğrulama eğitimi sırasında az sayıda kusurlu görüntü örneği ile oluşturulan model kullanılmıştır.

Guifang et al. (2008) sıcak haddelenmiş çelik şeritlerin zamanla artan üretim hızının sonucunda şeritler üzerindeki kusurların insan gözüyle görme zorluğu problemi üzerine görüntü işleme yöntemlerini kullanarak bir çözüm önermişlerdir. Yöntem, ortalama 88.18% gibi bir başarı elde etmiştir. Algoritmanın zorlandığı durumlar olması sebebiyle üzerine geliştirme yapılması gerektiği açıklanmıştır.

Mohammad et al. (2008) çelik yüzeylerinde bulunan delik, çizik, kırılma ve pası tespit etmek ve sınıflandırmak için görüntü işleme yöntemlerini kullanarak bir yöntem önermiştir. Elde edilen sonuçlar incelendiğinde yöntemin ortalama 86.77% doğrulukla tespit ettiğini göstermiştir. Kullanılan veri setinin çok az miktarda veri içermesi sebebiyle bu çalışmanın yeterli doğruluğu vermediği görülmüştür.

### 2.1.2. Spektral

Yorgos et al. (1999) yaptıkları çalışma, seri üretim sistemlerindeki en iyi denetim senaryosunu ele almıştır. Bu çalışmada, bir insanın gözünün mevcut kusurların sadece %60'ını tespit edebileceği vurgulanmıştır. Bu bağlamda, tipik bir LPG tüp dolum hattının genişliği 410 mm'dir ve 0.2 ile 0.25 m/s hız aralığında hareket eder. Bu hat üzerinden alınan görüntülerin çözünürlüğü, denetim sonuçlarının kalitesini doğrudan etkileyebilir. Yüksek çözünürlüklü görüntüler kullanılarak, insan gözünün kaçırabileceği kusurların daha etkin bir şekilde tespit edilmesi mümkün olabilir.

Sakhare et al. (2015), kumaş kusur tespiti için insan maliyetini ve zaman kaybını azaltmak için güçlü ve etkin kumaş kusur tespit algoritmalarına ihtiyaç duyulduğunu belirtmiştir. Makalede, kumaş kusurlarını tespit etmek için Spektral alan yaklaşımı Hızlı Fourier Dönüşümü (FFT), Ayrık Kosinüs Dönüşümü (DCT), dalgacık ve Gabor filtresinifiltresi, morfolojik işlemler ve istatistiksel işlemleri kullanmışlardır. Bu yaklaşımların, geleneksel insan görsel muayenesine kıyasla daha etkin, maliyet açısından daha verimli ve zaman kaybının azaltıldığını vurgulamışlardır.

### 2.1.3. Model Tabanlı

Fernando et al. (2006) karmaşık şekilli metalik yüzeylerin otomatik görsel tanıma üzerine Temel Bileşen Analizine (TBA) dayalı bir görünüm tabanlı yöntem önermiştir. Bu yöntemin eksikliği, TBA yöntemlerinde önemli çevrim dışı maliyetler ortaya çıkmasından kaynaklanmaktadır.

Ayed et al. (2006) Weibull dağılımını denetimsiz görüntü bölütleme ve sınıflandırmada kullanmıştır. Yöntem SAR ve gerçek görüntüler üzerinde uygulanmıştır. Yöntem ortalama 94.99% doğru sınıflandırılmıştır fakat bu yöntemin gerçek zamanlı uygulanabilir olması tartışılmaktadır.

Heying et al. (2017) çelik yüzey kusurlarını denetimsiz bir şekilde tespit etmek için yeni bir Haar-Weibull-Varyans

(HWV) modeli önermiştir. Önerilen yöntemin homojen görüntüler üzerinde ortalama 96.2% doğru tespit oranı sunmuştur fakat görüntü çeşidinin artırılması gerekmektedir.

### 2.1.4. Makine Öğrenmesi

Hongwen et al. (2020) yüzey kusurlarının tespiti için otomatik bir kusur tespit ağı önermiştir. Yöntemin uygulandığı veri sayısının ve çeşitliliğinin sınırlı olması nedeniyle bazı kusurlar yanlış tespit edilmiştir. Bu yöntem gerçek zamanlı uygulamak için yeterli değildir.

Waleed et al. (2019) sıcak haddelenmiş çelik şeritlerin yüzey kusurlarını tespit etmek için ayrık shearlet dönüşümü (DST) ve gri seviye birlikte oluşum matrisinin (GLCM) kullanımını birleştiren bir yöntem sunmuştur. Önerilen yöntem, gri tonlamalı görüntülerden oluşan veri seti üzerinde ortalama 96% oranında doğrulukla tespit etmiştir.

### 2.1. Derin öğrenme tabanlı yaklaşımlar

Derin öğrenme tabanlı yaklaşımlar, büyük veri setleri üzerinde eğitilen yapay sinir ağlarına dayanır. Bu yöntemler, özellik çıkarımını ve kusur tespitini otomatik olarak gerçekleştirir. Evrimsel sinir ağları (CNN), geri beslemeli sinir ağları (RNN) ve otomatik kodlayıcılar gibi teknikler yer alır. Bu yöntemler, genellikle görüntü ve video analizi, ses tanıma ve doğal dil işleme gibi alanlarda kullanılır. Derin öğrenme tabanlı yöntemler, karmaşık ve değişken veri setlerini işleyebilir ve yeni kusur türlerine karşı daha esnek olabilir. Bununla birlikte, büyük miktarda eğitim verisi gerektirir ve modelin karar verme süreci geleneksel yöntemlere göre daha az şeffaf olabilir (Luo et al. 2020).

Jakob et al. (2021) kusurlu görüntüler üzerindeki kullanılabilir değişkenler ile endüstriyel kalite kontrol problemlerine faydalı olacak bir derin öğrenme yöntemi üzerinde çalışmıştır. Bu yöntemin mimarisi kusur bölütleme ve sınıflandırma sonuçları veren iki alt ağdan oluşmaktadır. Yöntem, iki farklı açık kaynak veri seti üzerinde denenmiş olup buna ek olarak çeşitli kusurları içeren yeni bir veri seti sunulmuştur. Üzerinde durulan yöntemin tam denetimli ve az denetimli ortamlarda iyi sonuç verdiğini gözlemlemişlerdir. Seçilen bir veri setinde en yüksek 98.74% doğruluk oranına ulaşırken diğer veri setlerinde 100% doğruluk oranı görüldüğü belirtilmiştir. Bu oranların oldukça yüksek ve gerçekçi olmaması sebebiyle güven vermemektedir.

Xing et al. (2020) veri kümelerine dayalı kusur tespitinde olumlu sonuçlar veren bir öğrenme tabanlı yöntem üzerinde çalışmıştır. Wasserstein Üretken Düşman Ağları (WGAN'lar), özellik çıkarma tabanlı transfer öğrenme teknikleri ve çok modellenli topluluk modelleriyle çalışılan yöntemde dengesiz ve nadir ortaya çıkan kusurlar üzerinde başarılı sonuçlar verdiği görülmüştür. Yapılan tespit çalışmalarında 93.37% doğruluk oranına ulaşırken geleneksel bilgisayarlı görü yöntemleri aynı koşullar altında daha kötü sonuçlar vermiştir.

Ling et al. (2020) yüzeylerdeki kusur tespiti için Mask R-CNN'in bir geliştirilmiş hali olan görüntü piramidi ve konvolüsyonel sinir ağının birleştirilmiş modeli üzerine çalışmıştır. Model eğitimi için bir açık kaynak veri seti kullanılmıştır. Yapılan çalışmalar küçük bir veri seti kullanılarak yüksek hassasiyet ve duyarlılık değerleri ile başarıya ulaşılmıştır. Son teknoloji yöntemlerle yapılan karşılaştırma sonucu IPCNN'in umut verici sonuçlar göstermiştir fakat veri setinin küçüklüğü sebebiyle güvenilir bir sonuç olduğunu göstermemektedir.

Daniel et al. (2016) CNN kullanarak görsel kusur tespitinde bir yaklaşım önermiştir. Verilen yöntem, ortalama 97.6% doğru tespit oranına ulaşmıştır. Derin bir mimaride büyük miktarda eğitim verisi gerektiğinden bu yöntemin dezavantajı maliyetli olmasıdır.

Je-Kang et al. (2016) otomatik yüzey kusur tespiti için CNN tabanlı bir yöntem önermiştir. Yöntem, kusur tespitinde belirli yüzeylerde 98% oranında başarı göstermiştir. Farklı çeşit yüzeylerde bu oran düşmektedir ve veri sayısı azlığından dolayı gerçek zamanlı uygulanmasını zorlaştırmaktadır.

Young-Jin et al. (2017) beton yüzeyindeki çatlak kusurlarını tespit etmek için CNN mimarisi tabanlı bir yöntem önermiştir. Kullanılan yöntem oluşturulan veri seti üzerinde 97.95% oranında doğru tespit bulunmuştur. Fakat bu yöntem veri sayısının azlığı ve gerçek zamanlı tespit için yeterli hızda olmaması sebebiyle yeterli bulunmamıştır.

Makaledeki yöntem, derin öğrenme yerine geleneksel görüntü işleme ve makine öğrenmesi tekniklerini kullanarak gerçek zamanlı çalışma hızına ulaşmayı başarmıştır. Derin öğrenme modelleri, genellikle büyük miktarda veri ve yoğun hesaplama kaynakları gerektirir, bu da gerçek zamanlı uygulamalar için pratik olmamaktadır. Buna karşılık, makalede kullanılan geleneksel makine öğrenmesi yöntemleri, daha az hesaplama kaynağı gerektirmekte ve genellikle daha hızlı olmaktadır. Bu özellikler, gerçek zamanlı uygulamalar için

daha uygundur. Yöntem, kümeleme algoritmaları aracılığıyla özellik çıkarımını içermektedir ve bu özellikler kusur tespiti için kullanılmaktadır. Bu yöntemin avantajı, daha az sınıflandırılmış veriye ihtiyaç duyması ve eğitim sürecini hızlandırmasıdır. Ayrıca, maliyet ve zaman açısından daha verimlidir, çünkü derin öğrenme modellerinin eğitimi ve uygulanması genellikle daha pahalı ve zaman alıcıdır. Bu özellikler, makaledeki yöntemin literatürdeki diğer yöntemlerden farklılaşmasını sağlamaktadır.

### 3. Metod

Bu çalışmada LPG tüplerinin üzerindeki kirli bölgelerin tespiti ve bu bölgelerin kirlilik oranının hesaplanmasında hızlı ve düşük maliyetli bir algoritmaya ihtiyaç olması sebebiyle makine öğrenme yöntemleri tercih edilmiştir. Çalışmada, kendi oluşturduğumuz veri seti kullanılmıştır. Belirlenen yaklaşımlara girdi olarak alınacak görüntülerin elde edilmesi için 5 MP, CMOS, 2448x2048 çözünürlük, monochrome, 22 fps özelliklere sahip bir kamera seçilmiştir ve LPG tüplerinin geçtiği tablalı konveyör hattının üzerine 90° açıyla LPG tüp yüzeyinden 380 mm uzaklığa sabitlenmiştir. Çapı 360 mm olan LPG tüpü tabla üzerinde 110° açısal hızla döndürülürken 60° aralıklarla anlık olarak görüntüler alınmıştır. Her LPG tüpü, hattın üzerinde yatay bir pozisyonda 5 tur döndürülmüş ve toplamda 840 adet tüp yüzey görüntüsü elde edilmiştir. Bu görüntüler ile oluşturulan veri seti Şekil 1'de gösterilmiştir.



Şekil 1. Veri Seti Örneği

Makalede incelenen tüp görüntülerinin elde edildiği hat sistemi, tesisin günlük operasyonlarının bir parçası değildir. Ar-Ge merkezinde yer alan özel bir geliştirme hattında gerçekleştirilmektedir. Bu özel hattın kullanımı, test sürecinin tesisin genel iş akışını etkilememesi için uygulanmıştır. Testlerin hızlı ve verimli bir şekilde tamamlanması gerekmektedir, çünkü Ar-Ge hattının akıcı ve kesintisiz çalışması önemlidir. Bu bağlamda, önerilen yöntemin hız ve verimlilik açısından tesisin mevcut işleyişi ile uyumlu olup olmadığını değerlendirmek önem taşımaktadır. Geliştirdiğimiz sistem, gerçek zamanlı çalışma yeteneğine sahip olduğundan Ar-Ge merkezindeki

geliştirme hattında uygulanması için elverişlidir. Bu özellik sistemin, hattın akıcı ve verimli işleyişine müdahale etmeden tüp yüzeyindeki kusurları etkin bir şekilde tespit etmesini sağlamaktadır. Bu; sistemin, tesisin mevcut iş akışına entegre edilebileceğini ve verimli bir şekilde çalışabileceğini göstermektedir.

Hat üzerinden elde edilen LPG tüplerinin görüntüleri, alt ve üst kısım olarak ele alınması için görüntü kesme işlemi uygulanmıştır. Kesme işlemi sonrasında elde edilen her bir görüntü için ayrı ayrı kirlilik oranı elde eden algoritmalar aşağıda ayrıntılı olarak açıklanmıştır. Çalışma 24GB RAM GTX1060 6GB GPU ve i7-4770k işlemciye sahip bir sunucu kullanılarak yapılmıştır. Geliştirme dili olarak Python tercih edilmiştir.

### 3.1. SURF algoritması

Bay et al. (2006) tarafından geliştirilen SURF (Speeded Up Robust Features) algoritması, görüntülerde yerel özelliklerin tespiti, benzerliklerin belirlenmesi ve görüntüler arasında karşılaştırma yapılması için kullanılan hızlı ve etkili bir yöntemdir. Bu algoritma, özellikle Hessian matrisi yaklaşımını ve kutu filtrelerini kullanarak hızlı hesaplamalar yapabilme kapasitesine sahiptir. Bu özellikleri sayesinde, SURF algoritması nesne tespiti ve nesne takibi gibi gerçek zamanlı uygulamalar için idealdir. Diğer özellik tespit algoritmaları olan SIFT (Scale-Invariant Feature Transform) ve ORB (Oriented FAST and Rotated BRIEF) ile kıyaslandığında, SURF endüstriyel kusur tespitinde belirgin avantajlar sunar. Özellikle, 'hessianThreshold' parametresi sayesinde SURF, daha fazla ve daha kaliteli özellikleri tespit edebilir. Yüzey kusurlarının çeşitliliği ve karmaşıklığı dikkate alındığında bu özellik önemlidir. Ayrıca, SURF'un yüksek hızı ve düşük hafıza gereksinimi, büyük veri setleri ve gerçek zamanlı uygulamalar için ideal kılar. Bu avantajlar, özellikle hızlı hareket eden nesnelerin tespiti ve kusurların doğru bir şekilde sınıflandırılması gereken durumlar için kritik öneme sahiptir.

Çalışmamızın ilk aşaması olan kirliliğin tespitinde hızı ve ayırt etmedeki yüksek performansı sebebiyle bu algoritma kullanılmıştır. SURF dedektörü ile LPG tüpü üzerinde bozulmaya uğramış  $X = (x,y)$  noktasının Hessian matrisi (1) formülündeki gibi oluşturulur:


$$H(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix} \quad (1)$$

SURF algoritması integral görüntüsü kavramını ortaya koyar ve görüntü piramidinin yerini almak için değişken boyutta kutu filtreleme kullanır. Görüntü bulanıklığının

kaynağı, görüntünün ortalama veya integral işleminden kaynaklandığından, görüntüde herhangi bir yönde uzanan kenarları ve bulanık konturları SURF algoritması ile tespit edilebilmektedir. Şekil 2'de görüldüğü üzere kirliliğin bir tüp görüntüsündeki bozulmuş noktalar SURF algoritması ile tespit edilebilmektedir. Görüntü özellik noktalarını seçmek için, orijinal görüntü her pikselin Hessian matrisi kullanılarak değiştirilmelidir. Ağırlık, yaklaşım kaynaklı sapmayı azaltır ve diskriminant (2) formülündeki gibidir:

$$\det(H_{approx}) = L_{xx}L_{yy} - (0.9L_{xy})^2 \quad (2)$$

Noktanın bir ilgi noktası olup olmadığına 3. Denklemin pozitif ve negatif sonuçlarına göre karar verilmektedir. İlgili noktanın büyüklüğü ile üç boyutlu alanındaki çeşitli ölçek uzaylarının çevresinde bulunan diğer 26 noktanın büyüklükleri arasında bir karşılaştırma yapılır. Eğer ilgili nokta en büyük özdeğere sahip komşuluktaki nokta ise, o zaman bölgedeki özellik noktası olarak kabul edilir. Bulunan noktalar literatürdeki kümeleme algoritmaları ile kümelenecek ve bu kümelerin oluşturduğu konveks alanlar kullanılarak bir kirlilik oranı hesaplanacaktır.



Şekil 2. Kirliliğin bir LPG tüpü görüntüsünde SURF algoritması tarafından tespit edilen özellik noktaları.

### 3.1. DBSCAN algoritması

DBSCAN (Density Based Spatial Clustering of Applications with Noise), Ester et al. (1996) tarafından geliştirilen, veri madenciliği ve makine öğreniminde yaygın olarak kullanılan popüler bir veri kümeleme algoritmasıdır. DBSCAN, uzaklık ölçümü ve belirlenen minimum nokta sayısına dayanarak birbirine yakın olan noktaları gruplandırır. Çalışmamızda, SURF algoritması ile işaretlenmiş alanların kümelenebilmesi için DBSCAN Algoritması tercih edilmiştir. Bu algoritma, veri noktalarının yoğunluğuna dayalı olarak kümeler oluşturur ve önceden belirlenmiş bir küme sayısına ihtiyaç duymaz. Bu özellik, özellikle standart dışı şekil ve boyutlardaki kusurların tespiti için oldukça önemlidir. DBSCAN ayrıca gürültüye ve aykırı değerlere karşı dayanıklıdır, bu da endüstriyel ortamlarda sıkça karşılaşılan zorlu veri koşullarında büyük bir avantaj sağlar. K-means ve benzeri

yöntemler lineer kümeleme yaparken, DBSCAN, değişken veri yapıları ve daha karmaşık modellerle daha iyi çalışır. Bu, çeşitli endüstriyel uygulamalar için esnek ve etkili çözümler sunar.

Algoritmanın başlangıç noktası görüntü üzerindeki herhangi bir işaretlenmiş noktadır. Bir sonraki adım bu noktaya Epsilon ( $\epsilon$ ) uzaklıkta olan noktaları bulmaktır. Amaç (3) formülüne dayalı  $N\epsilon(p)$  komşuluk yarıçapı içindeki toplam veri noktası sayısını elde etmektir:

$$N\epsilon(p) = \{q \in D \mid \text{dist}(p, q) \leq \epsilon\} \quad (3)$$

$N\epsilon(p)$  ve MinPts arasında yapılan karşılaştırma, MinPts >  $N\epsilon(p)$  ise p'yi gürültü olarak algılayacak şekilde veri noktalarının durumunu belirlemek içindir. Ve eğer MinPts  $\leq N\epsilon(p)$  ise, o zaman işaretlenen noktayı başka bir kümeye ayıracaktır. Bu yöntem, tüm küme noktaları tespit edilene kadar p'nin komşuluğundaki tüm noktalar için devam edecektir.

Bu kümelemeden sonra, tüm noktalar Şekil 2'de görüldüğü gibi etiketlenene kadar algoritmaya devam edilir. Bu algoritmada iki nokta arasındaki mesafe Öklid mesafesine göre hesaplanır. Bir önceki adımdaki özellik seçimine göre, bu aşağıdaki (4) formülünden elde edilir:


$$\text{dist}(p, q) = \sqrt{(q_t - p_t)^2 + (q_h - p_h)^2 + (q_v - p_v)^2} \quad (4)$$

DBSCAN'ın parametreleri Epsilon ve MinPts'dir. DBSCAN'ın doğruluğu girdi parametrelerine bağlıdır. Yoğunluk tabanlı teknikle, anomalileri tanımlamak için en az iki kümeye ihtiyacımız vardır (Mohammad and Davud 2014). Bu kümeler: kümenin içindeki noktalar (çekirdek noktalar) ve kümenin sınırındaki noktalardır (sınır noktaları). Genelde bir sınır noktası komşu sayısı çekirdek noktasının komşu sayısından daha az olmaktadır. Bu sebeple aynı kümeye ait tüm noktaları bir kümede toplamak için minimum nokta sayısının düşük tutulması gerekmektedir. Optimum DBSCAN giriş parametresi yapılan hesaplamalar sonucunda SURF Algoritmasının çıktısının anahtar nokta sayısı tespit edilen eşik değeri olan 375'ten fazla ise ( $\epsilon = 40$ , MinPts = 3) düşük ise denklem (5)'te gösterildiği gibi ( $\epsilon = 20$ , MinPts = 3) olarak belirlenmiştir.

$$\begin{cases} \epsilon = 20, S > 375 \\ \epsilon = 40, S \leq 375 \end{cases} \quad (5)$$

Denklemden verilen S değişkeni, SURF çıktısından elde edilen anahtar nokta sayısını ifade etmektedir. Şekil 3'te

DBSCAN algoritmasından elde edilen kümeleme sonuçları gösterilmektedir.




Şekil 3. LPG Tüpü Görüntüsü Kümeleme Örnek Çıktısı

Kirli bölgelerin konveks çokgenler halinde bulunabilmesi için DBSCAN algoritmasından elde edilen kümelerin her birinde ilk olarak minimum ve maksimum x ve y koordinatlarına sahip noktalar hesaplanır ve bu noktalar birleştirilerek kirli bölgenin içinde bulunduğu bir sınırlayıcı çokgen tanımlanır. Örnek çerçevelenen çokgen bölge Şekil 4'te gösterilmiştir.

Çerçevelenen bölgelerin görüntü üzerinde hesaplanan alanları toplanmıştır ve elde edilen toplamın görüntünün tamamına oranı hesaplanarak bir kirlilik değeri elde edilmiştir.

Açıklanan yöntemlerin kullanımını özetleyecek olursak; LPG tüp dolmuş hattı üzerine yerleştirilen düzenek marifeti ile LPG tüpünün 360° döndürülmesi ve her 60° bir 6 tane görüntünün alınması sağlanmıştır. Her bir LPG tüpü ilgili düzende 5 tur döndürülerek 5x6 = 30 tane görüntü alınması ile bir veri seti elde edilmiştir.

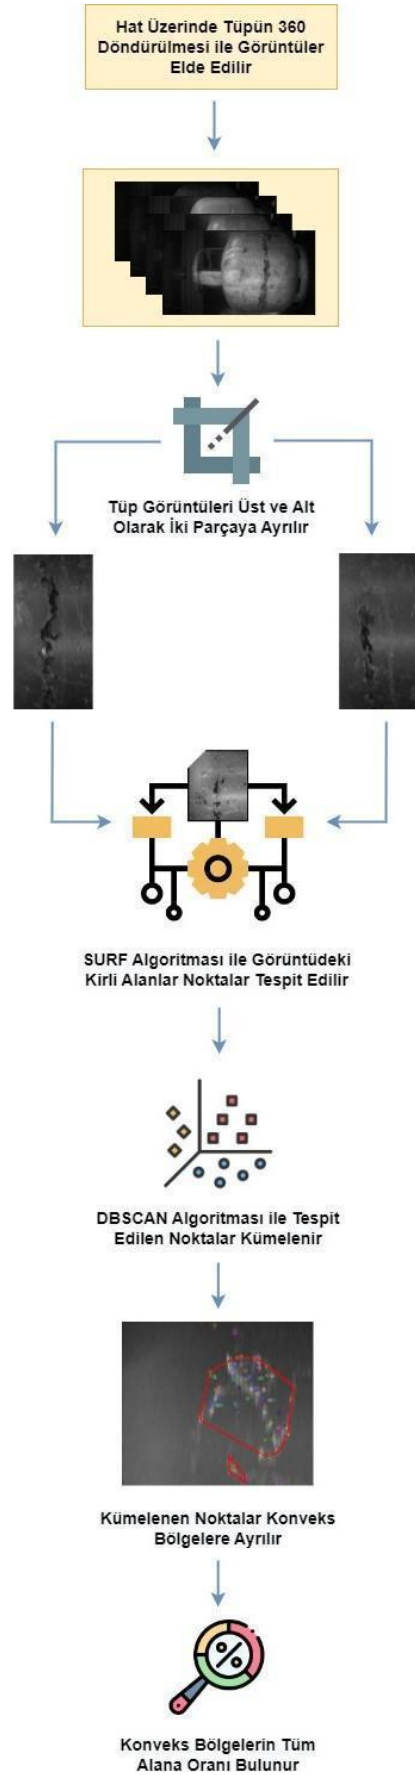


Şekil 4. Çerçevelenen Çokgen Bölgeler Örnek Çıktısı

Bir LPG tüpünden alınan görüntü alt üst olarak ikiye bölünerek algoritmanın kullanacağı formata çevrilmektedir. Tüm görüntüler öncelikle SURF algoritmasından geçirilerek görüntü üzerindeki kusurlu noktalar belirlenmiştir. Daha sonra bu noktaların çerçevesi için DBSCAN algoritması kullanılarak kümeleme işlemi gerçekleştirilmiştir. Son olarak çerçevesi bölünerek bir kirlilik oranı elde edilmiştir. Böylece kümeleme algoritması kullanılarak kusur tespiti yapan yeni bir yöntem geliştirilmiştir. Yukarıda anlatılan akışın tüm aşamaları Şekil 5'te özet olarak verilmiştir.

#### 4. Deneysel Sonuçlar

Elde edilen veri seti üzerinde SURF ve DBSCAN yöntemlerinin hibrit olarak kullanılması sonucunda kirlilik bölgeleri hesaplanmıştır. Önerilen yöntemde resimlerdeki tüplerin konumlandırılması sabit tutulmuş ve görüntü işleme aşamasında yalnızca tüpü içeren resim kısımları kullanılmıştır. Bu yaklaşım, görüntü işleme algoritmalarının doğruluğunu ve verimliliğini artırmak için kritik öneme sahiptir, çünkü bu yöntemle arka plan edil-



Şekil 5. Yöntemin Akış Şeması

mesinin önüne geçilmiştir. Bu sayede, tüp yüzeyindeki kusurların tespiti daha hassas ve hedef odaklı bir şekilde

gerçekleştirilmiştir. Kirli olarak tespit edilen bölgelerin alanı tüm tüp yüzey alanına bölünür ve kirlilik oranı bulunur.

Temiz LPG tüplerinden elde edilen kirlilik oranları Çizelge 1'de gösterilmiştir. Görüldüğü üzere temiz olarak etiketlenmiş LPG tüplerindeki kirlilik oranı [0%, 2%] aralığında değer almaktadır. Önerilen yöntem ile temiz LPG tüpleri tespit edilebilmektedir.

**Çizelge 1.** Temiz LPG Tüplerinin Ortalama Kirlilik Oranı

LPG Tüpü Numarası	Elde Edilen Ortalama Kirlilik Oranı
T1	0.43
T2	1.95
T3	0.52
T4	1.88

Çizelge 1'de listelenen LPG tüpleri arasından seçilen T1 LPG tüpü, geliştirme hattına 5 tur boyunca yerleştirilerek geliştirme hattında test edilmiştir. Her bir tur için algoritma tarafından hesaplanan kirlilik oranları, Çizelge 2'de sunulmuştur.

**Çizelge 2.** Farklı Koşullarda Temiz Bir LPG Tüpü ile Elde Edilen Kirlilik Oranları

LPG Tüpü Numarası	Elde Edilen Ortalama Kirlilik Oranı
T1	0.53
T1	0.53
T1	0.47
T1	0.28
T1	0.33

Elde edilen kirlilik oranlarının standart sapması oldukça düşüktür. Geliştirilen yöntem kirli ve temiz tüplerde aynı kirlilik oranlarını vermemektedir ancak sonuçlar incelendiğinde algoritmadan alınan verimin ve algoritmanın kararlılığının temiz LPG tüpleri için son derece yüksek olduğu gözlemlenmektedir.

Temiz LPG tüplerinin aksine Çizelge 3'te kirli olarak etiketlenmiş LPG tüplerinin kirlilik oranına bakıldığında oldukça büyük değerler elde edilmiştir. Yöntem içerisinde verilecek eşik değeri ile kirli ve temiz LPG tüpleri rahatlıkla ayırt edilebilmektedir. Aynı zamanda kirli olarak sınıflandırılan LPG tüplerinin kirlilik dereceleri de belirlenmektedir.

Çizelge 3'te belirtilen LPG tüpleri arasından seçilen K1 LPG tüpü, geliştirme hattından 5 tur geçirilmiştir. Bu sürecin

sonucunda elde edilen ortalama kirlilik oranları, Çizelge 4'te sunulmuştur.

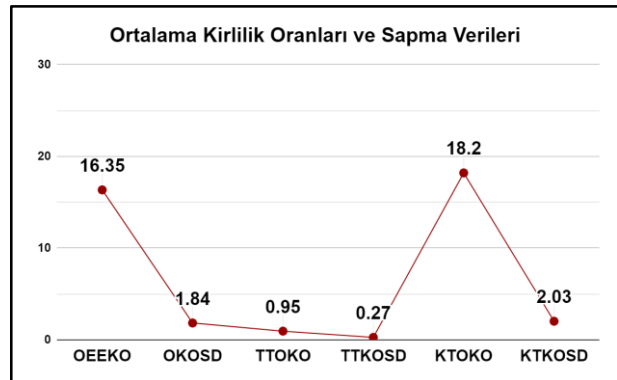
**Çizelge 3.** Kirli LPG Tüplerinin Ortalama Kirlilik Oranı

LPG Tüpü Numarası	Elde Edilen Ortalama Kirlilik Oranı
K1	31.45
K2	26.44
K3	27.76
K4	23.48

**Çizelge 4.** Farklı Koşullarda Kirli Bir LPG Tüpü ile Elde Edilen Kirlilik Oranları

LPG Tüpü Numarası	Elde Edilen Ortalama Kirlilik Oranı
K1	33.65
K1	33.27
K1	29.02
K1	32.53
K1	28.79

Gerçeklenen algoritmadan alınan verim, koşullara bağlı olarak değişmektedir. Kirli LPG tüplerinde tespit edilen bölgelerin orana etkisi çok daha büyük olmaktadır. Bu sebeple K1 LPG tüpü için her tur elde edilen ortalama kirlilik oranları arasında sapmanın temiz LPG tüplerine oranla daha fazla çıktığı görülmüştür. Algoritmadan elde edilen ortalama veriler Grafik 1'de gösterilmiştir. Grafikteki OEEKO: Ortalama Elde Edilen Kirlilik Oranı, OKOSD: Ortalama Kirlilik Oranı Sapma Değeri, TTOKO: Temiz Tüplerde Ortalama Kirlilik Oranı, TTKOSD: Temiz Tüplerde Kirlilik Oranı Sapma Değeri, KTOKO: Kirli Tüplerde Ortalama Kirlilik Oranı, KTKOSD: Kirli Tüplerde Kirlilik Oranı Sapma Değeri anlamına gelmektedir.



**Grafik 1.** Ortalama kirlilik oranları ve sapma verileri

Grafiğe bakıldığında ortalama kirlilik sapma değeri oldukça düşük çıkmıştır. Sapmanın düşük çıkması algoritmanın kararlı yapıda olduğunu ve veriminin yüksek olduğunu göstermektedir. Önerilen yöntem ile hat



üzerinden geçen LPG tüplerinin kirlilik oranı başarı ile tespit edilebilmektedir.

Kullanıcılar tarafından daha kolay uygulanabilir olması için bir arayüz tasarlanmıştır. Bu arayüz üzerinden kirlilik tespitinin hassasiyetini belirleyen bir eşik değeri sistemin çalışacağı kuruluş tarafından girilmektedir. Eşik değeri, kirli olarak etiketlenen tüplerin kirlilik oranları arasından minimum olan değerden daha küçük bir değer seçilerek kirli tüplerin tamamını ayırt etmeyi amaçlamaktadır. Bu eşik değeri taban kirlilik oranı olarak kabul edilmektedir. Bu taban değer üzerinde kirlilik oranına sahip tüpler, kirli tüp olarak kabul edilip Şekil 6'da görüldüğü gibi arayüz üzerinde kırmızı renkte gösterilmektedir. Eşik değerinin altında çıkan değerler ise temiz kabul edilip Şekil 6'da görüldüğü gibi arayüzde yeşil renkte gösterilmektedir. Bu renklendirme ile kirlilik tespitinin okunması kolaylaştırılmıştır. Arayüz üzerinde kirli olarak belirlenen tüpler, hattan çıkarılarak ait olduğu firmaya bu tüpün revizyonu için rapor edilmektedir.



Şekil 6. Kirli bir LPG tüpünün arayüzdeki görüntüsü



Şekil 7. Temiz bir LPG tüpünün arayüzdeki görüntüsü

Arayüz üzerinde LPG tüpüne ait ortalama kirlilik değeri, kaynak altı kirlilik ve kaynak üstü kirlilik olarak farklı üç değer gösterilmektedir. LPG tüplerinin üst kısımlarının görsel olarak daha dikkat çeken bir konumda bulunması nedeniyle kirlilik değerinin alt kısmına oranla daha önemli olduğu durumlar olmaktadır. Bu nedenle arayüzde bu iki durum ayrı ayrı hesaplanarak verilmektedir.

## 5. Tartışma ve Sonuç

Bu makale kapsamında bir LPG dolum tesisinde kontrol hattından geçirilen LPG tüplerinin üzerindeki kirli

bölgelerin tespiti ve kirlilik oranının bulunması amacıyla denetimsiz çalışan hibrit bir yöntem geliştirilmiştir. Yöntemin geliştirilmesi ve testi için LPG dolum hattı üzerine yerleştirilen bir kameradan alınan görüntülerden elde edilmiş veri kümesi kullanılmıştır. Yöntem denetimsiz bir şekilde çalıştığından dolayı kararlılığının tespit edilmesi için her bir LPG tüpü, hat üzerinden farklı zamanlarda 5 kez geçirilmiştir ve her bir geçiş için kirlilik oranı hesaplanmıştır.

Bu çalışmada, kirlilik tespiti amacıyla SURF özellik çıkarım yöntemi ve DBSCAN kümeleme algoritması kullanılmaktadır. Çalışmada kullanılan veri seti kesin olarak etiketlenmemiş bir veri kümesidir. Bu, verinin doğasından kaynaklanan bir kısıtlamadır ve dolayısıyla, kirlilik durumunu deterministik bir biçimde sınıflandırmak yerine, bir olasılık oranı hesaplamamıza yol açmaktadır. Bu oran, önceden belirlenmiş bir eşik değerine göre 'kirli' veya 'temiz' olarak sınıflandırılmaktadır. Ancak, bu yöntem, geleneksel sınıflandırma algoritmalarının kullandığı standart performans ölçütleri olan Yanlış Pozitif Oranı (FPR) ve Doğru Pozitif Oranı (TPR) gibi değerlerin hesaplanmasını olanaksız hale getirmektedir. FPR ve TPR, net sınıflandırılmış ve kesin etiketlenmiş veriler üzerinde hesaplanır ve gerçek pozitif ve negatif sonuçları temel alır. Bu nedenle, çalışmamızda bu tür geleneksel performans metriklerini kullanmak yerine, veri setimizin özgün yapısına ve uygulanan analiz metodolojilerine uygun alternatif değerlendirme yöntemleri kullanılmıştır.

Çalışma sonuçları incelendiğinde, LPG dolum tesisi tarafından temiz olarak tanımlanan bir LPG tüpü için kirlilik oranı değeri 2%'den düşük çıkmaktadır. Temiz olarak tanımlanan LPG tüplerinin farklı geçişleri karşılaştırıldığında doğruluk değerlerinin ortalama standart sapması 0.27 bulunmuştur. Dolum tesisi tarafından kirli olduğu belirtilen LPG tüplerinin kirlilik oranı ortalama 18% olarak bulunmaktadır. Daha büyük değişimlere sahip oldukları için kirli LPG tüplerinin standart sapması, temiz LPG tüplerinden daha yüksek şekilde 2.03 olarak hesaplanmıştır. Geliştirilen yöntemin LPG dolum tesisi içerisinde çalışanların kullanılabilirliği adına bir arayüz tasarlanmıştır. Bu arayüzde kullanıcı tarafından belirlenen eşik değerine göre kirli ve temiz LPG tüpü sınıflandırması başarılı bir şekilde yapılmıştır. Kirlilik eşik değerinin 10% seçilmesi durumunda fabrika LPG dolum tesisi tarafından etiketlenen tüm LPG tüpleri doğru sınıflandırılmıştır. Çalışma sonucunda, geleneksel yöntemler hibrit bir şekilde kullanılarak endüstriyel ürünlerdeki kusur tespitine başarılı yeni bir çözüm yöntemi önerilmiştir.

## Etik Standartlar Bildirgesi

Yazarlar tüm etik standartlara uyduklarını beyan ederler.

## Yazarlık Katkı Beyanı

Yazar 1: Kavramsallaştırma, Metodoloji, Araştırma, Deneysel Tasarım, Analiz ve yorumlama, Yazma – orijinal taslak Görselleştirme, Yazma – orijinal taslak, Yazma/inceleme ve düzenleme

Yazar 2: Metodoloji, Araştırma, Deneysel Tasarım, Biçimsel analiz, Doğrulama, Veri iyileştirme, Yazma – orijinal taslak

Yazar 3: Araştırma, Yazma – orijinal taslak görselleştirme, Yazma – orijinal taslak

Yazar 4: Fikir Sahibi, Proje Yönetimi, Kaynak sağlama, Doğrulama, Analiz ve yorumlama

Yazar 5: Fikir Sahibi, Deneysel tasarımı, Kaynak sağlama, Doğrulama, Analiz ve yorumlama

Yazar 6: Fikir Sahibi, Deneysel tasarımı, Kaynak sağlama, Doğrulama, Analiz ve yorumlama

## Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

## Verilerin Kullanılabilirliği

Veri seti, firma içerisinde özel bir Ar-Ge hattında oluşturulmuştur. Bu sebeple, doğrudan veri setinin kendisi makaleye dahil edilememiştir. Ancak, bu veri seti üzerinde yapılan analizler ve elde edilen bulgular, incelenen makalede detaylı bir şekilde sunulmuştur.

## Teşekkür

Aygaz A.Ş. firmasına, araştırmamız için gerekli veri setini hazırlamaları ve Ar-Ge laboratuvarlarında çalışma imkânı sağlamaları nedeniyle teşekkür ederiz. Bu destekler, çalışmamızın başarısında önemli bir rol oynamıştır. Ek olarak bu çalışmanın hazırlanmasında emeği geçen ve değerli katkılarıyla makalemizi zenginleştiren saygıdeğer hakemlerimize en içten teşekkürlerimizi sunarız. Bilimsel titizlikleri, kıymetli yorum ve önerileri, makalemizin kalitesini artırmada büyük bir rol oynamıştır. Çalışmamızın alanımıza katkı sağlamasındaki payları büyüktür.

## 6. Kaynaklar

Ashour M.W., Khalid F., Abdul Halin A., Abdullah L.N. and Darwish S.H., 2019. Surface defects classification of hot-rolled steel strips using multi-directional shearlet features. *Arabian Journal for Science and Engineering*, **44**, 2925-2932.

<https://doi.org/10.1007/s13369-018-3329-5>

Ayed I.B., Hennane N. and Mitiche A., 2006. Unsupervised variational image segmentation/classification using a Weibull observation model. *IEEE transactions on Image processing*, **15(11)**, 3431-3439.

<https://doi.org/10.1109/TIP.2006.881961>

Bay H., Tuytelaars T., Van Gool L., 2006. SURF: Speeded Up Robust Features. *Computer Vision – ECCV 2006*, 404–417.

[https://doi.org/10.1007/11744023\\_32](https://doi.org/10.1007/11744023_32)

Bhatt P.M., Malhan R.K., Rajendran P., Shah B.C., Thakar S., Yoon Y.J., Gupta S.K., 2021. Image-Based Surface Defect Detection Using Deep Learning: A Review. *Journal of Computing and Information Science in Engineering*, **21**, 040801.

<https://doi.org/10.1115/1.4049535>

Božič J., Tabernik D., Skočaj D., 2021. Mixed supervision for surface-defect detection: from weakly to fully supervised learning. *Computers in Industry*, **129**, 103459.

<https://doi.org/10.1016/j.compind.2021.103459>

Cha Y.J., Choi W. and Büyüköztürk O., 2017. Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, **32(5)**, 361-378.

<http://dx.doi.org/10.1111/mice.12263>

Dong H., Song K., He Y., Xu J., Yan Y. and Meng Q., 2019. PGA-Net: Pyramid feature fusion and global context attention network for automated surface defect detection. *IEEE Transactions on Industrial Informatics*, **16(12)**, 7448-7458.

<https://doi.org/10.1109/TII.2019.2958826>

Ester M., Kriegel H.P., Sander J., Xu X., 1996. A density-based algorithm for discovering clusters in large spatial databases with noise. *Kdd*, **96**, 226–231.

Gayubo F., Gonzalez J.L., de la Fuente E., Miguel F. and Perán J.R., 2006. On-line machine vision system for detect split defects in sheet-metal forming processes. *In 18th International Conference on Pattern Recognition (ICPR'06)*, **1**, 723-726.

<https://doi.org/10.1109/ICPR.2006.902>

Karayiannis Y.A., Stojanovic R., Mitropoulos P., Koulamas C., Stouraitis T., Koubias S., Papadopoulos G., 1999. Defect detection and classification on web textile fabric using multiresolution decomposition and neural networks. *ICECS'99. Proceedings of ICECS '99. 6th IEEE International Conference on Electronics, Circuits and Systems*, **2**, 765–768.

<https://doi.org/10.1109/ICECS.1999.813221>

Karimi M.H., Asemani D., 2014. Surface defect detection in tiling Industries using digital image processing methods: Analysis and evaluation. *ISA Transactions*, **53**, 834–844.

<https://doi.org/10.1016/j.isatra.2013.11.015>

Kumar A., 2008. Computer-Vision-Based Fabric Defect Detection: A Survey. *IEEE Transactions on Industrial Electronics*, **55**, 348–363.

- <http://dx.doi.org/10.1109/TIE.1930.896476>
- Le X., Mei J., Zhang H., Zhou B., Xi J., 2020. A learning-based approach for surface defect detection using small image datasets. *Neurocomputing*, **408**, 112–120. <http://dx.doi.org/10.1016/j.neucom.2019.09.107>
- Li X., Wang C., Ju H., Li Z., 2022. Surface Defect Detection Model for Aero-Engine Components Based on Improved YOLOv5. *Applied Sciences*, **12**, 7235. <https://doi.org/10.3390/app12147235>
- Liu K., Wang H., Chen H., Qu E., Tian Y. and Sun H., 2017. Steel surface defect detection using a new Haar–Weibull-variance model in unsupervised manner. *IEEE transactions on instrumentation and measurement*, **66(10)**, 2585-2596. <https://doi.org/10.1109/TIM.2017.2712838>
- Lu Q., Lin J., Luo L., Zhang Y., Zhu W., 2022. A supervised approach for automated surface defect detection in ceramic tile quality control. *Advanced Engineering Informatics*, **53**, 101692. <https://doi.org/10.1016/j.aei.2022.101692>
- Luo Q., Fang X., Liu L., Yang C., Sun Y., 2020. Automated Visual Defect Detection for Flat Steel Surface: A Survey. *IEEE Transactions on Instrumentation and Measurement*, **69(3)**, 626-644. <https://doi.org/10.1109/TIM.2019.2963555>
- Park J.K., Kwon B.K., Park J.H. and Kang D.J., 2016. Machine learning-based imaging system for surface defect inspection. *International Journal of Precision Engineering and Manufacturing-Green Technology*, **3**, 303-310. <https://doi.org/10.1007/s40684-016-0039-x>
- Sakhare K., Kulkarni M., Kumbhakarn M., Kare N., 2015. Spectral and spatial domain approach for fabric defect detection and classification. *2015 International Conference on Industrial Instrumentation and Control (IIC)*, Pune, India, 640-644. <http://dx.doi.org/10.1109/IIC.2015.7150820>
- Sharifzadeh M., Amirfattahi R., Sadri S., Alirezaee S. and Ahmadi M., 2008. Detection of steel defect using the image processing algorithms. *In The International Conference on Electrical Engineering ICEENG 2008*, 1-7. <https://doi.org/10.21608/iceeng.2008.34372>
- Tabernik D., Šela S., Skvarč J., Skočaj D., 2020. Segmentation-based deep-learning approach for surface-defect detection. *Journal of Intelligent Manufacturing*, **31**, 759–776. <https://doi.org/10.1007/s10845-019-01476-x>
- Uzen H., Turkoglu M., Hanbay D., 2023. Multi-dimensional feature extraction-based deep encoder–decoder network for automatic surface defect detection. *Neural Computing and Applications*, **35**, 3263–3282. <https://doi.org/10.1007/s00521-022-07885-z>
- Wang Z., Zhu H., Jia X., Bao Y., Wang C., 2022. Surface Defect Detection with Modified Real-Time Detector YOLOv3. *Journal of Sensors*, **2022**, e8668149. <https://doi.org/10.1155/2022/8668149>
- Weimer D., Scholz-Reiter B. and Shpitalni M., 2016. Design of deep convolutional neural network architectures for automated feature extraction in industrial inspection. *CIRP annals*, **65(1)**, 417-420. <https://doi.org/10.1016/j.cirp.2016.04.072>
- Wu G., Kwak H., Jang S., Xu K. and Xu J., 2008. Design of online surface inspection system of hot rolled strips. *In 2008 IEEE International Conference on Automation and Logistics*, 2291-2295. <https://doi.org/10.1109/ICAL.2008.4636548>
- Xiao L., Wu B., Hu Y., 2020. Surface Defect Detection Using Image Pyramid. *IEEE Sensors Journal*, **20**, 7181–7188. <https://doi.org/10.1109/JSEN.2020.2977366>
- Xing J., Jia M., 2021. A convolutional neural network-based method for workpiece surface defect detection. *Measurement*, **176**, 109185. <http://dx.doi.org/10.1016/j.measurement.2021.109185>