

Çelik Yüzeylerdeki Kusurların Tespiti için Topluluk Öğrenme Tabanlı Gelişmiş Segmentasyon Yöntemi

Emre GÜÇLÜ¹, İlhan AYDIN², Erhan AKIN³

¹ Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

² Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

³ Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

✉: eguclu@firat.edu.tr ¹ 0000-0002-4566-7517 ² 0000-0001-6880-4935 ³ 0000-0001-6476-9255

Geliş (Received): 23.05.2024

Düzeltilme (Revision): 10.07.2024

Kabul (Accepted): 02.08.2024

ÖZ

Bu çalışmada, çelik yüzeylerdeki kusurların tespiti için topluluk öğrenme tabanlı bir gelişmiş segmentasyon yöntemi sunulmuştur. Günümüzde, çelik üretim süreçlerinde kalite kontrolün önemi artmakta ve kusur tespiti teknolojilerine olan ihtiyaç hızla büyümektedir. Bu bağlamda, çeşitli çelik yüzey kusurlarını doğru bir şekilde tespit edebilen ve bölütlelebilen güçlü bir modele ihtiyaç vardır. Önerilen sistem, derin öğrenme tabanlı çoklu model yaklaşımlarını topluluk öğrenme ile birleştirerek, segmentasyon doğruluğunu önemli ölçüde artırmaktadır. Kullanılan topluluk öğrenme stratejisi, farklı mimarilere sahip birden fazla derin öğrenme modelinin güçlü yönlerini bir araya getirerek, sistemimizin genel performansını iyileştirmekte ve çeşitli kusur türlerine karşı daha duyarlı hale getirmektedir. Bu yaklaşım, geniş bir veri seti üzerinde test edilmiş ve %77,98 mIoU oranı elde ederek mevcut tekil model tabanlı yöntemlere kıyasla önemli bir performans artışı göstermiştir. Sonuçlar, önerilen topluluk öğrenme tabanlı segmentasyon yönteminin, çelik yüzeylerdeki kusurların tespiti konusunda etkili bir çözüm sunduğunu ve endüstriyel kalite kontrol süreçlerinde potansiyel uygulamalara sahip olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Çelik Yüzey Kusur Tespiti, Topluluk Öğrenme, Gelişmiş Segmentasyon Yöntemleri.

Ensemble Learning Based Advanced Segmentation Method for Detecting Defects on Steel Surfaces

ABSTRACT

In this study, an ensemble learning-based advanced segmentation method is presented for the detection of defects on steel surfaces. Nowadays, the importance of quality control in steel production processes is increasing and the need for defect detection technologies is growing rapidly. In this context, a powerful model that can accurately detect and segment various steel surface defects is needed. The proposed system significantly increases segmentation accuracy by combining deep learning-based multi-model approaches with ensemble learning. The ensemble learning strategy used combines the strengths of multiple deep learning models with different architectures, improving the overall performance of our system and making it more susceptible to various types of defects. This approach has been tested on a large dataset and achieved a mIoU rate of 77.98%, demonstrating a significant performance improvement over existing single model-based methods. The results reveal that the proposed ensemble learning-based segmentation method offers an effective solution for detecting defects on steel surfaces and has potential applications in industrial quality control processes.

Keywords: Steel Surface Defect Detection, Ensemble Learning, Advanced Segmentation Methods.

GİRİŞ

Çelik sektörünün kritik bileşenlerinden biri olan çelik filmaşınlar, genelde ince ve esnek, şerit ya da bant formunda bir çelik türüdür. Bu filmaşınların kalınlığı, kullanım alanına ve amaca göre değişiklik gösterebilir. Esnek ve dayanıklı yapılarıyla çelik filmaşınlar, otomotivden inşaat ve yapı malzemelerine, endüstriyel uygulamalara kadar geniş bir yelpazede tercih edilir. Özellikle yüksek dayanıklılık gerektiren uygulamalarda popüler olan çelik filmaşın, sağlam ve uzun ömürlü bir

ürün olmasını zorunlu kılar. Bununla birlikte, üretim aşamasında meydana gelebilecek çeşitli kusurlar, bu malzemelerin performansını ve güvenilirliğini olumsuz etkileyebilir.

Sıcak haddelenmiş çelik şeritlerin üretiminde, mekanik gerilimler, yüksek sıcaklıklar ve hızlı üretim koşulları nedeniyle filmaşın yüzeylerinde kusurlar oluşabilir. Bu durum, ürünün dayanıklılığını ve kalitesini tehlikeye sokabilir. Bu sebeple, endüstride çelik filmaşın yüzey kusurlarının tespiti büyük önem taşır. Yaygın olarak karşılaşılan kusurlar arasında yüzey çizikleri,

çatlaklar, delinmeler ve pürüzler bulunur. Bu tür kusurları önlemek için üretim sürecinde etkin bir kalite kontrol sisteminin uygulanması şarttır. Bu kapsamda, üretim sırasında malzemenin yüzey kalitesinin sürekli izlenmesi ve herhangi bir sorun tespit edildiğinde hızlıca müdahale edilmesi önem taşır. Ayrıca, işleme ve ısıl işlem süreçlerinin doğru şekilde gerçekleştirilmesi, üretim ekipmanlarının düzenli bakımı ve kaliteli malzeme seçiminin yapılması, çelik filmaşın üretimindeki kusurları minimize etmek için kritik öneme sahiptir. Bu yaklaşımlar, çelik filmaşınların daha güvenilir ve dayanıklı olmasını sağlayarak, endüstriyel uygulamalarda verimliliği ve güvenliği artırır.

Teknolojik ilerlemelerle, çelik üretiminde hata tespiti ve denetiminin otomasyonunu giderek daha önemli hale getirmiştir. Geçmişte manuel yöntemlerle gerçekleştirilen görsel kalite kontrol süreçleri, günümüzde gelişen makine görüşü teknolojileri sayesinde otomatize edilmektedir. Bu modern yaklaşımlarda, endüstriyel kameralar aracılığıyla incelenen yüzeyler detaylı bir şekilde taranır ve elde edilen görüntüler, kusurları tespit etmek için geliştirilen algoritmalara aktarılır. Bu otomatik kusur tespit sistemleri, endüstriyel ürünlerin çeşitli yüzeylerindeki deforme bölgelerin doğru bir şekilde tespit edilmesini hedefler ve ürün kalitesi ile güvenliğinin sağlanmasında önemli bir rol oynar. Ancak, endüstriyel kusur tespiti sürecinde karşılaşılan bazı zorluklar vardır. Bunlar arasında, yetersiz numunelerden dolayı veri toplamanın zorluğu önemli yer tutar. Ayrıca, kusurlar genellikle düşük kontrasta, benzer dokulara ve yüksek görsel karmaşıklığa sahip küçük alanlarda bulunur, bu da tespitlerini zorlaştırır. Bu zorluklar, endüstriyel ürünlerin doğasından kaynaklanmaktadır. Özetle, gerçek endüstriyel veri setlerinin bulunmaması da bu zorlukları daha da artırır.

Geleneksel yapay görme sistemleri, görüntü analizinde kenarlar, köşeler, dokular gibi özelliklere dayalı teknikler kullanır. Bu teknikler arasında yerel ikili desenler (Local Binary Patterns - LBP), Gabor filtreleri ve Ölçekten Bağımsız Özellik Dönüşümü (Scale-Invariant Feature Transform - SIFT) bulunur. Ancak, bu yöntemler görüntüdeki özellikleri manuel olarak belirlemek için bir dizi parametreyi ayarlamayı gerektirir, bu da uzmanlık ve zaman gerektirir ve bazen hesaplama açısından verimsiz sonuçlar doğurabilir. Buna ek olarak, Geleneksel yöntemlerin bir diğer sınırlılığı, değişken koşullara ve karmaşık senaryolara adaptasyon yeteneklerinin sınırlı olmasıdır. Örneğin, farklı ışık koşulları, gölgeleme veya gürültü seviyeleri, bu yöntemlerin doğruluğunu ve güvenilirliğini önemli ölçüde etkileyebilir. Bu tür durumlarda, yöntemlerin ekstra ince ayar gerektirmesi ve ek parametre ayarlamaları yapılması gerekir.

Geleneksel yöntemler, sınırlı genelleştirme yetenekleri ve düşük doğruluk oranları nedeniyle yerlerini daha etkili olan derin öğrenme tabanlı sistemlere bırakmıştır. Derin öğrenme tabanlı sistemlerin otomatik kusur tespit süreçlerinde tercih edilmesinin başlıca nedenleri arasında yüksek doğruluk oranları ve

güvenilirlik bulunmaktadır. Bu modeller, karmaşık veri setlerinden çıkarılan özellikleri kullanarak, görüntülerdeki hassas detayları ve desenleri etkin bir şekilde tanıyabilir ve bu sayede kusur tespitinde yüksek başarı oranlarına ulaşır. Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN) gibi derin öğrenme modelleri, çeşitli ışıklandırma, gölgeleme ve gürültü koşullarında bile etkili bir şekilde çalışabilir ve daha geniş uygulama senaryolarına uyum sağlayabilir. Ayrıca, derin öğrenme modellerinin esnekliği de önemli bir avantajdır. Farklı türdeki ve karmaşıklığındaki veri setlerine uyum sağlayabilen bu modeller, çeşitli endüstriyel üretim ortamlarında ve farklı kusur türlerinin tespitinde etkili olarak kullanılabilir. Geleneksel yöntemlere kıyasla daha hızlı, maliyet etkin ve güvenilir sonuçlar sunan derin öğrenme modelleri, otomatik denetim, görüntü bazında sınıflandırma, kusur tespiti ve görüntü segmentasyonu gibi farklı alanlarda başarıyla kullanılabilir.

Sonuç olarak, derin öğrenme tabanlı sistemlerin otomasyon süreçlerindeki bu rolü, çelik üretiminde kalite kontrol ve güvenliğin artırılmasına büyük katkı sağlamaktadır. Bu teknolojiler, geleneksel manuel yöntemlerin yerini alarak, üretim süreçlerinin verimliliğini ve ürün kalitesini önemli ölçüde iyileştirmektedir.

Günümüzde, üretim süreçlerindeki hata tespitinin otomatikleştirilmesi, giderek daha fazla önem kazanan bir unsur olmuştur [1-3]. Endüstriyel çelik sektöründe, yüzey hatalarını belirlemek için kullanılan teknikler arasında manyetik akı kaçağı, kızılötesi algılama ve görüntü işleme yöntemleri yer almaktadır. Manyetik akı sızıntısı tespiti, çelik şerit yüzeyi üzerine manyetik alan uygulayarak çalışır. Herhangi bir yüzey kusuru, sızıntı yoluyla algılanabilecek manyetik alanın bozulmasına neden olur. Bu yöntem kullanılarak büyük kusurlar tespit edilebilir. Ancak bu yöntem, aşırı ince çatlaklar gibi küçük kusurların tespiti konusunda sınırlı bir kapasiteye sahiptir [4]. Yüzey kusurlarının tespitinde kullanılan bir diğer yöntem ise kızılötesi tabanlı tespit yöntemleridir [5]. Bu yöntem, çelik yüzeylerindeki kusurları sıcaklık dalgalanmaları üzerinden algılar. Kusurlar, çelik şeridin yüzeyinde ısı dağılımını etkileyerek, kızılötesi kameralar tarafından algılanabilir sıcaklık farklılıkları oluşturur. Ancak bu yöntemin bir dezavantajı, çelik şeridin kızılötesi ışık emilimi değişkenliğinin tespit doğruluğunu etkileyebilmesidir. Son yıllarda kullanımı önemli ölçüde artan bir diğer yöntem ise makine görmesine dayalı yöntemlerdir. Makine görmesi algoritmaları, ışığa duyarlı sensörler ve gelişmiş bilgisayar algoritmaları kullanarak çelik yüzeylerindeki kusurları tespit eder. Bu yöntem, yüzey kusurlarının yüksek çözünürlüklü görüntüleri kullanılarak, ince çatlaklar ve diğer küçük kusurlar dahil olmak üzere geniş bir kusur yelpazesinin tespit edilmesini mümkün kılar. Bu sistemler, basit yapıları, genişletilebilirlikleri ve yüksek doğruluk oranları nedeniyle son yıllarda birçok araştırmanın konusu olmuştur. Özellikle, derin öğrenme yöntemlerinin görsel tanıma alanında gösterdiği başarının artışıyla birlikte

kusur tespit sistemlerinde derin öğrenme tabanlı tespit yöntemleri geniş bir kullanım alanı bulmuştur [6-7].

Derin öğrenme tabanlı kusur tespit sistemleri, temel olarak sınıflandırma, nesne tespiti ve nesne segmentasyonu olmak üzere üç temel kategoriye ayrılır [8]. Bu sistemler, malzemelerin yüzeyindeki hataları doğru bir şekilde belirlemek için görüntüler üzerinden karmaşık analizler gerçekleştirir. Sınıflandırma, hataların türlerine göre sıralanmasını sağlarken [9]; nesne tespiti, hataların yerlerini belirler [10]. Nesne segmentasyonu ise, hataların sınırlarını daha detaylı bir şekilde çıkararak, boyut ve şekil gibi özelliklerinin incelenmesine olanak tanır [11]. Bu üçlü yaklaşım, kusur tespit süreçlerinin etkinliğini ve doğruluğunu artırarak endüstriyel kalite kontrol çalışmalarını önemli ölçüde iyileştirir.

Segmentasyon tabanlı yöntemler, diğer kusur tespit tekniklerine göre, görüntülerdeki nesnelere veya kusurları çok daha detaylı bir şekilde analiz etme avantajına sahiptir. Bu yöntemler, bir görüntüdeki ilgili nesnelere veya kusurların sınırlarını belirleyerek, onları arka plandan ayırt eder. Bu ayrıştırma sayesinde, nesnelere veya kusurların boyutu, şekli ve diğer özellikleri üzerinde daha kesin ölçümler yapılabilir. Bu durum, özellikle karmaşık yüzeylerdeki ince kusurların belirlenmesinde ve analiz edilmesinde büyük bir fark yaratır, böylece daha doğru ve güvenilir tespitler yapılmasına olanak tanır. Segmentasyon tabanlı yöntem için birçok model önerilmiştir. Yang vd. [12], piksel düzeyinde hassas derin bölümlenme sağlamak amacıyla, bir kodlayıcı-kod çözücü mimarisi kullanarak otomatik bir kusur segmentasyon ağı önermiştir. Bu model, kusurları tespit etmek ve uçtan uca bir segmentasyon modeli oluşturmak üzere tasarlanmıştır. Zhou vd. [13], U-Net mimarisinden ilham alarak yeni bir ağ tasarımı geliştirmiştir. PSD U-Net modeli, resim detaylarını maksimum düzeyde korumak için orijinal evrişim yerine delikli evrişim ve HDC tasarımını benimsemektedir. Çalışmada, U-Net, Mask R-CNN ve yeniden tasarlanmış PSD U-Net olmak üzere üç farklı model üzerinden deneysel bir karşılaştırma sunulmuştur. Aydın vd. [14], eğitim sürecinde sadece sağlıklı görüntü örneklerinden yararlanarak, hatalı bölgeleri belirlemiştir. Omurga olarak Resnet18 ve EfficientNet modelleri tercih edilip piksel düzeyinde hata tespitinde %98,7 gibi yüksek bir başarı oranına ulaşılmıştır. Xu vd. [15], kendi kendini denetleyen öğrenme stratejisi kullanarak yüksek verimlilik sunan Kendi Kendini Denetleyen Verimli Hata Dedektörü (SEDD) adında bir kusur tespit yöntemi sunmuştur. Önerilen bu yöntem, üretim hattında kusurlu örnekler için ek açıklamalara gerek kalmadan kusur tespiti gerçekleştirebilmektedir.

Bu çalışmanın amacı, topluluk öğrenme yaklaşımının tek başına kullanılan modellere kıyasla daha yüksek doğruluk oranı sağlayıp sağlamadığını araştırmaktır. Ayrıca, farklı derin öğrenme modellerinin bir araya getirilmesiyle elde edilen tahminlerin ağırlıklı ortalamasının kusur tespitinde daha güvenilir sonuçlar sunup sunmadığını incelemektir.

Bu çalışma, çelik yüzey kusurlarının tespiti için topluluk öğrenme stratejisini benimseyen bir yaklaşımı

sunmaktadır. Topluluk öğrenme, segmentasyon tabanlı kusur tespit yöntemlerinde Intersection over Union (IoU) metriğini artırmada etkili bir yaklaşımdır. Bu yöntem, birden fazla modelin bir araya gelerek ortak bir karar verdiği bir süreçtir. Her model, farklı özellikleri ve hataları algılayarak toplam doğruluğu artırır. Bu sayede, kusurların daha doğru bir şekilde tespit edilmesi sağlanır. IoU, tahmin edilen segmentasyon alanı ile gerçek segmentasyon alanının kesişiminin, bu iki alanın birleşimine bölünmesiyle elde edilir. Topluluk öğrenme, bu metriği artırarak daha güvenilir ve hassas kusur tespiti sağlar, böylece üretim süreçlerinin kalitesini yükseltir. Çalışmada önerilen yöntem, endüstriyel görüntüler üzerinde segmentasyon doğruluğunu artırmak için bu topluluk öğrenme prensibini uygular. Her bir model, farklı birer derin öğrenme mimarisi kullanılarak eğitilir ve ardından elde edilen tahminlerin ağırlıklı ortalaması alınarak nihai tahminleme yapılır. Bu yaklaşım, çelik kusur tespiti için etkili bir çözüm sunar ve endüstriyel kalite kontrol süreçlerinde önemli uygulama potansiyeline sahiptir. Piksel Düzeyinde İkili Rehberlik (PBG), sırasıyla ön plan ve arka plan özellik haritalarının birbirine ve kendine bağımlılığını modellemek için iki tamamlayıcı dal (ön plan ve arka plan) içeren etkileşimli bir özellik yeniden ağırlıklandırma şemasını benimser.

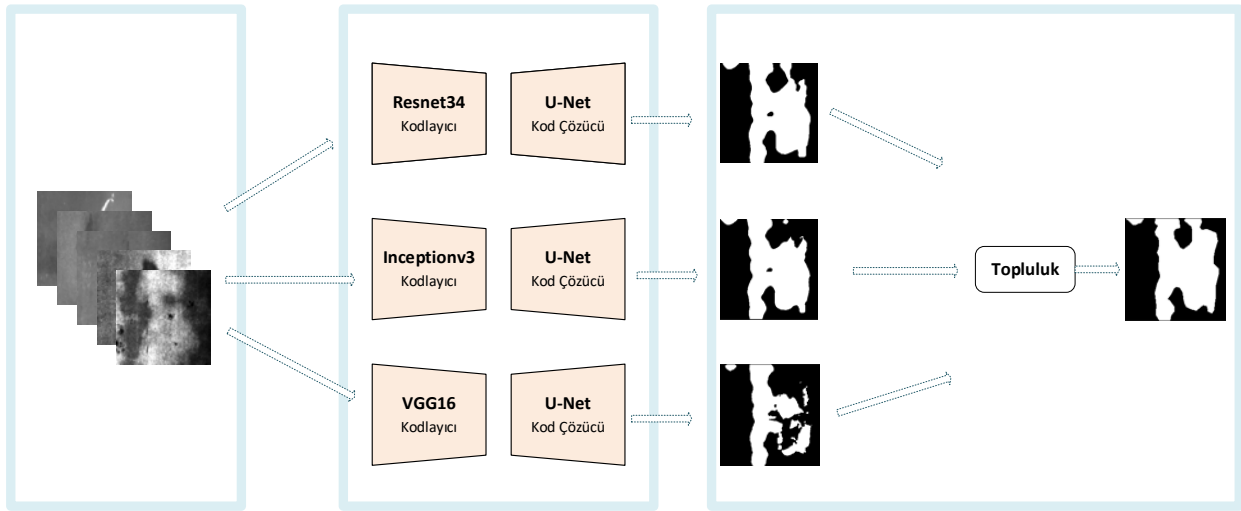
Çalışmamızın katkıları şu şekilde özetlenmektedir:

- Topluluk öğrenme, çelik yüzey kusurlarının segmentasyon görevinde başarıyla kullanılmıştır. Bu yöntem, farklı derin öğrenme modellerinin bir araya getirilerek çelik tel yüzeylerindeki kusurların doğru bir şekilde tespit edilmesini sağlamıştır.
- Literatürde yaygın olarak kullanılan SD-Saliency 900 veri kümesi üzerinde, çeşitli kusur segmentasyon algoritmaları deneyerek kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Bu deneyler, önerilen yöntemin diğer segmentasyon algoritmalarına kıyasla üstün performans sergilediğini göstermiştir.

MATERYAL ve YÖNTEM

Topluluk öğrenme, birden fazla modelin bir araya getirilerek bir problem üzerinde çalışmasını içeren bir yaklaşımdır. Bu yöntem, bireysel modellerin hatalarını dengeler ve genel performansı artırır. Bu çalışmada, segmentasyon için topluluk öğrenme temelli bir yöntem geliştirilmiştir. Bu yöntem, farklı CNN modellerinin güçlü yönlerinden yararlanarak, veri temsili öğreniminde daha etkili bir yol sunar.

Önerilen segmentasyon yöntemi, çeşitlilik ve kapsamlılık açısından zengin bir veri seti üzerinde eğitilen bir dizi CNN modelinden oluşur. Bu modeller, her biri veri setinin farklı özelliklerini yakalayabilecek şekilde tasarlanmıştır. Ardından, topluluk öğrenme mekanizması, bu modellerin çıktılarını birleştirerek, her bir modelin zayıflıklarını birbirinin güçlü yönleriyle dengeleyerek nihai segmentasyon sonucunu elde eder. Bu yaklaşım hem veri temsili kalitesini artırır hem de eğitim sürecinde gereken hesaplama kaynaklarının miktarını azaltır.



Şekil 1. Önerilen derin öğrenme mimarisinin genel yapısı

Bu, özellikle karmaşık ve heterojen veri setlerinde, segmentasyon performansının önemli ölçüde iyileştirilmesini sağlar.

Sonuç olarak, önerilen topluluk öğrenme tabanlı segmentasyon yöntemi, kaynak kısıtlı ortamlarda bile yüksek kaliteli segmentasyon sonuçları elde etmeyi mümkün kılar. Bu yöntem, özellikle tıbbi görüntüleme, uzaktan algılama ve sanayi otomasyonu gibi alanlarda, etkili ve verimli bir çözüm sunar. Bu çalışma, segmentasyon problemlerine yönelik yeni ve kaynak dostu bir yaklaşımın kapılarını aralar ve derin öğrenmenin potansiyelini daha geniş bir kullanıcı kitlesine açar.

Bu çalışmada, çelik yüzeylerindeki kusurları ayırt etmek ve bunları detaylı bir şekilde segmentasyonu için, UNet [16] mimarisi temel alınarak üç ayrı özelleştirilmiş bir derin sinir ağı modeli oluşturulmuştur. Bu modellerde kodlayıcı olarak ResNet34, Inceptionv3 ve VGG16 kullanılırken kod çözücü olarak U-net yapısı kullanılmıştır. Veri ön-işleme adımları kapsamında, tüm görüntüler ve maskeler 256x256 boyutlarına yeniden boyutlandırılmış, maskelerdeki kusur etiketleri sayısal değerlere dönüştürülmüş ve veri seti %80 eğitim, %20 test olacak şekilde bölünmüştür. Modeller, 256x256x3 ölçülerindeki bir çelik yüzey görüntüsünden başlayarak, 256x256x2 boyutlarında, kusurlu ve kusursuz bölgeleri tanımlayan bir segmentasyon haritası üretir. Bu harita, her sınıf için piksel bazında olasılıklar sunar, kusur varlığını ve yokluğunu belirten iki matristen oluşur. Softmax aktivasyon fonksiyonunun kullanımı ile, kusurlu bölgelerin olasılıkları, 256x256 boyutunda tek bir matris formunda sunulur. Bu metodoloji, çelik yüzeylerdeki kusurların doğru ve etkili bir şekilde tespiti ve sınıflandırılması için tasarlanmıştır, böylece endüstriyel kalite kontrol süreçlerinde önemli bir gelişme sağlamayı hedefler.

Şekil 1'de, sunulan modelin genel mimarisi verilmiştir. İlk adımda, çeşitli endüstriyel çelik yüzey veri kümelerinden kusur içeren görüntüleri topluyoruz. Ardından, bu orijinal çelik yüzey görüntülerine, görüntü

kırpma ve renk kanalı ayıklama gibi ön işleme adımlarını uyguluyoruz. Görüntü çevirme ve ölçeklendirme gibi yaygın artırma tekniklerini de entegre ederek veri setimizin çeşitliliğini artırıyoruz.

Daha sonraki aşamada, bağımsız temel modelin çelik yüzey kusurlarını tahmin etmesi için üç adet evrişimli görüntü transformatörü tabanlı ağ kullanıyoruz. Bu bağımsız temel ağların, kusur segmentasyonu için bir piramit görüş transformatörü ile birleştirildiğini belirtmek önemlidir. Bu işlemten sonra, üç farklı temel modelden elde edilen özellik haritalarını, kusur segmentasyon sonuçlarını elde etmek için kullanılan son sınıflandırıcı olarak birleştiren birkaç evrişim katmanını kullanıyoruz.

Bu metodoloji, çeşitli model mimarilerini bir araya getirerek ve topluluk öğrenme stratejisini kullanarak temel modelin segmentasyon kabiliyetini geliştirmeyi amaçlamaktadır. Bireysel segmentasyon modellerinin kısıtlamaları, diğer temel modeller tarafından telafi edilir, bu da tek bir temel modele kıyasla daha ileri düzeyde bir segmentasyon başarısı sağlar. Geliştirdiğimiz model yapısı, topluluk sınıflandırıcısının detayları, kullanılan veri kümeleri, değerlendirme ölçütleri ve uygulama yöntemi sonraki bölümlerde detaylı bir şekilde açıklanacaktır. Bu yaklaşım, çelik yüzey kusur tespiti ve segmentasyonu alanında, yüksek doğruluk ve güvenilirlik sunan, yenilikçi bir metodolojinin kapılarını aralamaktadır.

Kodlayıcı (Encoder)

ResNet34, derin residual ağların bir örneğidir ve derin öğrenme modellerindeki eğitim zorluğunu aşmak için tasarlanmıştır. Residual bloklar, modelin daha derin katmanlarda bile öğrenme yeteneğini korumasını sağlar. Kodlayıcı olarak ResNet34'ü kullanmak, modelimize, segmentasyon için gerekli olan zengin özelliklerin derinlemesine çıkarılmasında büyük bir avantaj sağlar.

InceptionV3, çok çeşitli ölçeklerdeki özellikleri etkili bir şekilde yakalayabilen bir yapıya sahiptir. Bu model, farklı boyutlardaki filtrelerin paralel olarak

kullanılmasıyla karakterize edilir. InceptionV3'ü kodlayıcı olarak kullanmak, modelimizin farklı çözünürlüklerdeki özellikleri algılama kapasitesini artırır, bu da çeşitli boyutlardaki kusurların daha doğru bir şekilde tespit edilmesine olanak tanır.

VGG16, basit ve derin bir mimariye sahiptir. Model, tekrar eden evrişim katmanları ve max pooling katmanlarından oluşur. Kodlayıcı olarak VGG16'nın kullanılması, modelimize güçlü bir özellik çıkarma ve görsel temsil yeteneği kazandırır. Bu, özellikle yüzey kusurlarının tespiti gibi görevlerde önemli bir avantajdır.

Kod Çözücü (Decoder)

Kodlayıcı kısmı, kodlanmış özellikleri kullanarak bir son segmentasyon haritası üretmeyi hedefleyen bir yapıdadır. Kodlayıcı ile eşit sayıda bloğa sahip bu yapı, her bir kod çözücü bloğu ile özellik kanallarının sayısını azaltırken mekansal çözünürlüğü artırır. Bu süreç, çift doğrusal yukarı örnekleme yöntemiyle gerçekleştirilir ve elde edilen çıktı, kodlayıcının karşılık gelen bloğundan gelen çıktı ile birleştirilerek zengin detayların korunmasını sağlar. kodlayıcı blokları arasındaki atlama bağlantıları, kodlayıcıdan alınan özelliklerin doğrudan kod çözücü katmanlarına iletilmesini sağlar. Bu yaklaşım, özellikle detayların korunması ve yüksek çözünürlüklü segmentasyon haritalarının üretilmesi açısından kritik öneme sahiptir.

Ölçüm Mertikleri

Bu çalışmada kullanılan değerlendirme metrikleri, doğruluk, duyarlılık, özgünlük ve ortalama Birlikte Bölüşümün Kesişimi (mIoU) olarak belirlenmiştir. Doğruluk, modelin doğru tahmin ettiği pozitif ve negatif örneklerin toplam tahmin sayısına oranıdır ve modelin genel performansını ölçer. Duyarlılık, doğru pozitif tahminlerin toplam gerçek pozitif örneklere oranıdır ve modelin pozitif sınıfları ne kadar iyi tespit ettiğini gösterir. Özgünlük, doğru negatif tahminlerin toplam gerçek negatif örneklere oranıdır ve modelin negatif sınıfları ne kadar iyi tespit ettiğini gösterir. mIoU, her bir sınıf için Birlikte Bölüşümün Kesişimi (Intersection over Union, IoU) değerlerinin ortalamasıdır ve modelin segmentasyon performansını değerlendirir

$$\text{Doğruluk} = \frac{DP + DN}{DP + YN + YP + DN} \quad (1)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (2)$$

$$\text{Özgünlük} = \frac{DP}{DP + YP} \quad (3)$$

$$mIoU = \frac{1}{k+1} \sum_{a=0}^k \frac{p_{aa}}{\sum_a p_{ab} + \sum_b p_{ba} - p_{aa}} \quad (4)$$

TARTIŞMA


Bu çalışmada, segmentasyon amaçlı üç farklı modelin karşılaştırılmasına yönelik deneysel sonuçlar sunulmaktadır. Çalışmada, semantik segmentasyon için bir U-Net modelini kullanarak çeşitli model ve parametre ayarlarıyla bir topluluk öğrenme yöntemi uygulanmıştır. Bu yöntemde ResNet34, InceptionV3 ve VGG16 omurgalarına sahip U-Net modelleri kullanılır. Modellerin performansı ağırlıklı ortalama yöntemiyle birleştirilir ve en iyi performansı sağlayan ağırlıklar belirlenir. Tablo 1'de, bu çalışmada kullanılan bazı önemli parametre ayarları sunulmuştur. Giriş görüntü boyutları, segmentasyon işlemi için gerekli detayı sunarken hesaplama maliyetlerini dengede tutacak şekilde 256x256 piksel olarak belirlenmiştir. Mini-yığın boyutu (batch size) olarak 8 değeri tercih edilmiş, bu seçim, eğitim sürecinin verimliliğini ve modelin genelleme kabiliyetini optimize etme amacı taşır. Model optimizasyonu için, adaptif öğrenme oranları sayesinde hızlı ve etkili yakınsama sunan Adam optimizasyon algoritması kullanılmıştır. Bu algoritma, derin öğrenme alanında yaygın olarak tercih edilir ve eğitim sürecini iyileştirir. Toplamda 50 eğitim döngüsü (epoch) gerçekleştirilmiş, bu sayede modellerin eğitim veri seti üzerinde yeterli öğrenmeyi gerçekleştirmesi sağlanmıştır. Öğrenme oranı olarak seçilen 0.001 değeri, modelin ağırlık güncellemelerinde dengeli bir yaklaşım sunar. Topluluk öğrenme yönteminde ağırlıklar şu şekilde belirlenmiştir: ResNet34 için 0.3, InceptionV3 için 0.5 ve VGG16 için 0.2.

Tablo 1. Model için parametreler

| Parametre | Değer |
|---------------------|-----------------------------------|
| Resim Boyutu (X, Y) | 256, 256 |
| Sınıf Sayısı | 2 |
| Öğrenme Oranı (LR) | 0.0001 |
| Optimizatör | Adam |
| Kayıp Fonksiyonu | DiceLoss +CategoricalFocalLoss |
| Eğitim Seti Boyutu | 80% |
| Test Seti Boyutu | 20% |
| Eğitim Epoch Sayısı | 100 |
| Batch Boyutu | 8 |

Model geliştirme süreçleri, Keras kütüphanesinin sunduğu araçlar kullanılarak, PyCharm geliştirme

Tablo 2. Sd-Saliency-900 veri kümesinde görselleştirme sonuçları




ortamında yürütülmüştür. Eğitim işlemleri, güçlü bir ekran kartı olan NVIDIA RTX3060 ile donatılmış ve Windows işletim sistemi altında çalışan bir bilgisayar üzerinde gerçekleştirilmiştir.

Modellerin segmentasyon performansının değerlendirilmesinde, model kalitesi ve etkinliği hakkında kapsamlı bilgi sağlayan bir dizi performans metriği kullanılmıştır. Bu metrikler arasında ortalama kesişim üzeri birleşme oranı (mIoU), doğruluk (accuracy), hatırlama oranı (recall), kesinlik (precision) ve F1 skoru bulunmaktadır. Bu metrikler, modellerin segmentasyon kabiliyetlerinin detaylı bir şekilde analiz edilmesine ve karşılaştırılmasına olanak tanır.

Modelin geliştirilmesi sürecinde, performansının doğru bir şekilde ölçülmesi için kullanılan veri setinin kalitesi ve uygunluğu büyük önem taşır. Bu açıdan bakıldığında, SD Saliency-900 veri seti, çelik yüzeylerdeki kusurların tespit edilmesinde model performansını değerlendirmek için iyi bir kaynaktır. Bu veri seti, kalıntılar, yamalar ve çizikler olmak üzere üç ana kusur sınıfını içermekte ve bu kusurların farklı şekil, boyut ve görünümelerini sergilemektedir.

SD Saliency-900, çelik yüzeylerdeki kusurların derinlemesine analizi için özel olarak hazırlanmıştır. Veri setindeki her bir kusur sınıfı, endüstriyel üretim süreçlerinde karşılaşılan gerçek dünya senaryolarını yansıtmakta ve bu kusurların otomatik tespiti için zorluklar sunmaktadır. Örneğin, kalıntılar genellikle yüzeyde düzensiz birikintiler şeklinde görülürken, yamalar yüzeydeki lokalize renk değişikliklerini, çizikler ise ince ve uzun yüzey bozulmalarını temsil eder.



Şekil 2. SD-Saliency-900 veri kümesinin örnek görüntüleri sırasıyla (a) inclusion (b) patches ve (c) scratches

Veri setindeki kusurların çeşitliliği, Şekil 2'de görselleştirilmiştir. Bu görselleştirme, kusur tespitinde karşılaşılan zorlukları ve çeşitli kusur türlerinin doğru bir şekilde sınıflandırılması ve segmentasyonu için gereken detay düzeyini vurgular. SD Saliency-900, bu kusurların derin öğrenme modelleriyle nasıl etkili bir şekilde tespit edilebileceğine dair değerli içgörüler sunar.

Tablo 2'de gösterilen performans metriklerine göre, önerilen topluluk öğrenmesi tabanlı model, Basnet ve Deeplabv3+ modellerinden daha yüksek sonuçlar elde etmiştir.

Tablo 2. Karşılaştırma sonuçları

| Model | Doğruluk (%) | Özgünlük (%) | Duyarlılık (%) | mIoU (%) |
|----------------------------|--------------|--------------|----------------|--------------|
| BasNet [17] | 84,66 | 96,99 | 97,09 | 68,39 |
| DeepLab v3+(Xception) [18] | 85,86 | 96,51 | 98,38 | 64,77 |
| Önerilen Model | 97,47 | 98,01 | 97,65 | 77,98 |

Çalışmanın Avantajları ve Dezavantajları

Bu çalışmanın avantajları arasında topluluk öğrenme yaklaşımının kullanılması sayesinde daha yüksek doğruluk oranları elde edilmesi ve modelin genel performansının artması yer almaktadır. Farklı derin öğrenme modellerinin bir araya getirilmesi, her modelin güçlü yönlerinin birleşmesini sağlayarak kusur tespitinde daha güvenilir sonuçlar sunar. Ayrıca, ağırlıklı ortalama yöntemi ile model kombinasyonlarının optimize edilmesi, segmentasyon performansını en üst düzeye çıkarır. Ancak, çalışmanın dezavantajları arasında, topluluk öğrenme yaklaşımının hesaplama maliyetinin yüksek olması ve model eğitim sürecinin uzun sürmesi bulunmaktadır. Ayrıca, farklı modellerin entegrasyonu ve ağırlık optimizasyonu karmaşık bir süreç olup, uzmanlık gerektirir. Bu faktörler, özellikle kaynakları sınırlı olan ortamlarda uygulamayı zorlaştırabilir.

SONUÇ

Bu çalışmada, çelik yüzey kusurlarının segmentasyon işlemi için özel olarak eğitilmiş, son teknoloji görüntü bölümlenme ağlarının karşılaştırmalı bir analizi sunulmaktadır. Derin öğrenme tabanlı çeşitli görüntü bölümlenme yöntemlerinin mevcut olduğu bilinmesine rağmen, bu yöntemlerin çelik yüzey kusurlarını bölümlenme görevi üzerindeki performansları, segmentasyon doğruluğu, işlem hızı ve hesaplama karmaşıklığı açısından detaylı bir şekilde değerlendirilmemiştir. Bu boşluğu doldurmak amacıyla, çeşitli segmentasyon ağlarının ve çoklu özellik çıkarım omurgalarının performansını kapsamlı bir şekilde inceledik ve segmentasyon performansını artırmak için topluluk öğrenme tabanlı bir yöntem önerilmiştir.

Tablo 1’de gösterilen deneysel sonuçlar, analiz edilen çeşitli segmentasyon yöntemlerinin segmentasyon doğruluğu açısından (ortalama Kesişim üzeri Birleşim - mIoU) karşılaştırılabilir performans sergilediğini göstermiştir. Ancak, topluluk öğrenme tabanlı yöntem, BasNet ve DeepLabv3+ modelleri dahil olmak üzere diğer tüm yöntemlerden daha üstün sonuçlar elde etmiştir. Bu yöntem, değişken ölçeklerde, farklı şekillerde ve düşük kontrastlı kusurları bölümlenmekte özellikle etkili bulunmuştur. Sınıf bazında bölümlenme performansının detaylı analizi, belirli kusur türlerini bölümlenmenin, özellikle düşük kontrast ve karmaşık şekiller söz konusu olduğunda, zor olabileceğini göstermektedir.

Sonuç olarak, bu çalışma, çelik yüzey kusurlarını tespit etmek ve bölümlenmek için derin öğrenmeye dayalı yöntemlerin kapsamlı bir karşılaştırmasını sunmaktadır. Topluluk öğrenme tabanlı yöntemin, özellikle zorlu bölümlenme görevlerinde, mevcut en gelişmiş modellerden daha iyi performans sergilediği gözlemlenmiştir. Bu bulgular, endüstrideki uygulamalar için önemli iyileştirmeler sunmakta ve gelecekteki araştırmalar için yeni yollar açmaktadır.

TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TUBITAK) tarafından 5210082 numaralı proje ile desteklenmiştir.

KAYNAKÇA

- [1] Sime, D. M., Wang, G., Zeng, Z., & Peng, B. (2024). Deep learning-based automated steel surface defect segmentation: a comparative experimental study. *Multimedia Tools and Applications*, 83(1), 2995-3018.
- [2] Wang, G. Q., Zhang, C. Z., Chen, M. S., Lin, Y. C., Tan, X. H., Kang, Y. X., ... & Zhao, W. W. (2024). A high-accuracy and lightweight detector based on a graph convolution network for strip surface defect detection. *Advanced Engineering Informatics*, 59, 102280.
- [3] Tang, B., Chen, L., Sun, W., & Lin, Z. K. (2023). Review of surface defect detection of steel products based on machine vision. *IET Image Processing*, 17(2), 303-322.
- [4] Long, Y., Zhang, J., Huang, S., Peng, L., Wang, W., Wang, S., & Zhao, W. (2022). A novel crack quantification method for ultra-high-definition magnetic flux leakage detection in pipeline inspection. *IEEE Sensors Journal*, 22(16), 16402-16413.
- [5] Santoro, L., Sesana, R., Molica Nardo, R., & Curá, F. (2023). Infrared in-line monitoring of flaws in steel welded joints: a preliminary approach with SMAW and GMAW processes. *The International Journal of Advanced Manufacturing Technology*, 128(5), 2655-2670.
- [6] Akhyar, F., Lin, C. Y., Muchtar, K., Wu, T. Y., & Ng, H. F. (2019, September). High efficient single-stage steel surface defect detection. In *2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)* (pp. 1-4). IEEE.
- [7] Qu, Y., Wan, B., Wang, C., Ju, H., Yu, J., Kong, Y., & Chen, X. (2023). Optimization algorithm for steel surface defect detection based on PP-YOLOE. *Electronics*, 12(19), 4161.
- [8] Akhyar, F., Liu, Y., Hsu, C. Y., Shih, T. K., & Lin, C. Y. (2023). FDD: a deep learning-based steel defect detectors. *The International Journal of Advanced Manufacturing Technology*, 126(3-4), 1093-1107.
- [9] Shao, Y., Fan, S., Sun, H., Tan, Z., Cai, Y., Zhang, C., & Zhang, L. (2023). Multi-Scale Lightweight Neural Network for Steel Surface Defect Detection. *Coatings*, 13(7), 1202.
- [10] Hussain, M. (2023). YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines*, 11(7), 677.
- [11] Üzen, H., Turkoglu, M., Aslan, M., & Hanbay, D. (2023). Depth-wise Squeeze and Excitation Block-based Efficient-Unet model for surface defect detection. *The Visual Computer*, 39(5), 1745-1764.
- [12] Yang, L., Xu, S., Fan, J., Li, E., & Liu, Y. (2023). A pixel-level deep segmentation network for automatic defect detection. *Expert Systems with Applications*, 215, 119388.
- [13] Zhou, G., & Sun, H. (2020, June). Defect detection method for steel based on semantic segmentation. In *2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC)* (pp. 975-979). IEEE.
- [14] Aydın, I., Güçlü, E., & Akin, E. (2023, November). An Improved Unsupervised Convolutional Neural Networks for Detection of Steel Wire Defects. In *2023 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)* (pp. 402-407). IEEE.
- [15] Xu, R., Hao, R., & Huang, B. (2022). Efficient surface defect detection using self-supervised learning strategy and segmentation network. *Advanced Engineering Informatics*, 52, 101566..
- [16] Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015*,

- proceedings, part III 18 (pp. 234-241). Springer International Publishing..
- [17] Qin, X., Fan, D. P., Huang, C., Diagne, C., Zhang, Z., Sant'Anna, A. C., ... & Shao, L. (2021). Boundary-aware segmentation network for mobile and web applications. arXiv preprint arXiv:2101.04704.
- [18] Goncalves, J. P., Pinto, F. A., Queiroz, D. M., Villar, F. M., Barbedo, J. G., & Del Ponte, E. M. (2021). Deep learning architectures for semantic segmentation and automatic estimation of severity of foliar symptoms caused by diseases or pests. *Biosystems engineering*, 210, 129-142.