



Result Weighting-Based Resnet Feature Pyramid Network Architecture for Surface Defect Detection

Hüseyin ÜZEN^{1,*} , Muammer TÜRKOĞLU² , Davut HANBAY³ 

¹Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 12000, Merkez, BİNGÖL

²Samsun Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 55000, İlkadım, SAMSUN

³İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü 44280, Merkez, MALATYA

Graphical/Tabular Abstract

Article Info:

Research article
Received: 10.11.2021
Revision: 25.11.2021
Accepted: 01.12.2021

Highlights

- Result Weighting
- Encoder-Decoder
- Defect Detection

Keywords

Surface Defect Detection
Pyramid Feature Network
Convolutional Neural
Network,
Segmentation

Automatic surface defect detection in manufacturing systems is very important in terms of providing high-quality products. In this study, a new architecture for pixel-level surface defect detection based on deep learning is proposed. The proposed architecture consists of Encoder, Decoder, and Result Weighting modules. The architecture of the proposed model is presented in Figure A.




Figure A. Schema of the Proposed Architecture

Purpose: Surface defect inspection is one of the most important components of quality control. Since manual inspections have weaknesses such as time-consuming, inefficient, and subjective results, there is a need for automatic surface defect detection systems based on computer vision and machine learning. For this purpose, a deep learning-based method was developed that works with high accuracy for automatic surface defect detection.

Theory and Methods: In this study, Result Weighting-based Resnet Feature Pyramid Network (SA-ROPA) architecture was developed for surface defect detection. The proposed model, pre-trained Resnet50 network architecture based on a transfer learning approach was used to deal with the problem of insufficient samples. In addition, a new approach called Result Weighting (SA), instead of directly combining features from different levels of the FPN architecture, was used. In this approach, four different defect detection results were obtained simultaneously using different levels of feature from the Resnet50 network. Then, the different detection results were combined in the depth dimension and the point convolution process was applied to obtain the final result prediction.

Results: MT, MVTEC-Texture and AITEX surface defect detection datasets were used to test the proposed SA-ROPA architecture. In experimental studies, the mIoU value obtained for the MT, MVTEC-Texture and AITEX datasets using the proposed model was calculated as 79.92%, 76.37%, and 82.72%, respectively. As a result, the proposed model was achieved higher success than the state-of-the-art methods and previous studies.

Conclusion: In the experimental results, it was observed that the surface defects were detected with high performance using the proposed SA-ROPA model. These results showed that the proposed model can be used for automatic surface defect detection in manufacturing systems. In addition, it was envisaged that this study in which extensive experimental studies were carried out, will lead to further work in the field of automatic surface defect detection.



Result Weighting-Based Resnet Feature Pyramid Network Architecture for Surface Defect Detection

Hüseyin ÜZEN^{1,*} , Muammer TÜRKOĞLU² , Davut HANBAY³ 

¹Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 12000, Merkez, BİNGÖL

²Samsun Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 55000, İlkadım, SAMSUN

³İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü 44280, Merkez, MALATYA

Abstract

Surface defect detection is very important in manufacturing systems to ensure high quality products. Unlike manual inspections under human supervision, automatic surface defect detection is both efficient and highly accurate. In this study, a Result Weighting-based Resnet Feature Pyramid Network (SA-ROPA) model has been developed for automatic pixel-level surface defect detection. In the first stage of the proposed model, the pre-trained Resnet50 network was used, and feature maps were extracted from the different levels of this network. In the second stage, Feature Pyramid Model was applied to these feature maps in order to hierarchically share important information in defect detection. In the third stage, 4 different defect detection results were obtained by using these feature maps. In the last stage, four different results obtained using the developed Result Weighting (SA) module were effectively combined. The proposed SA-ROPA model has been tested with MT, MVTEC-Texture and AITEX datasets, which are widely used in defect detection studies. In experimental studies, the mIoU value obtained for the MT, MVTEC-Texture and AITEX datasets using the proposed model was calculated as 79.92%, 76.37%, and 82.72%, respectively. These results have shown that the proposed SA-ROPA model is more successful than other state-of-the-art models.

Makale Bilgisi

Araştırma makalesi
Başvuru: 10.11.2021
Düzeltilme: 25.11.2021
Kabul: 01.12.2021

Keywords

*Surface Defect Detection
Pyramid Feature Network
Convolutional Neural
Network
Segmentation*

Anahtar Kelimeler

*Yüzey Hata Tespiti
Öznitelik Piramit Ağı
Evrişimsel Sinir Ağı
Bölütleme*

Yüzey Hata Tespiti için Sonuç Ağırlıklandırma Tabanlı Resnet Öznitelik Piramit Ağ Mimarisi

Öz


Yüzey hata tespiti, imalat sistemlerinde yüksek kalitede ürün sağlanması açısından oldukça önemlidir. İnsan gözetimi altında yapılan manuel denetimlerin aksine, otomatik yüzey hatası tespiti hem verimli hem de yüksek doğruluktur. Bu çalışmada piksel seviyesinde otomatik yüzey hata tespiti için Sonuç Ağırlıklandırma tabanlı Resnet Öznitelik Piramit Ağ (SA-RÖPA) modeli geliştirilmiştir. Önerilen modelin ilk aşamasında, önceden eğitilmiş Resnet50 ağı kullanılmış ve bu ağın farklı seviyelerinden öznitelik haritaları çıkartılmıştır. İkinci aşamada, hata tespitinde önemli bilgileri hiyerarşik olarak paylaşmak için bu öznitelik haritalarına Öznitelik Piramit Modeli uygulanmıştır. Üçüncü aşamada, bu öznitelik haritaları kullanılarak 4 farklı hata tespit sonucu elde edilmiştir. Son aşamada, geliştirilen Sonuç Ağırlıklandırma (SA) modülü kullanılarak elde edilen 4 farklı sonuç etkili bir şekilde birleştirilmiştir. Önerilen SA-RÖPA modeli, hata tespit çalışmalarında yaygın olarak kullanılan MT, MVTEC-Doku ve AITEX veri kümeleri ile test edilmiştir. Deneysel çalışmalarda, önerilen model kullanılarak MT, MVTEC-Doku ve AITEX veri kümeleri için elde edilen mIoU değeri, sırayla %79,92, %76,37 ve %82,72 olarak hesaplanmıştır. Bu sonuçlar, önerilen SA-RÖPA modelinin diğer son teknoloji modellerine göre daha başarılı olduğunu göstermiştir.

1. GİRİŞ (INTRODUCTION)

İmalat sistemlerinde artan üretim talebini karşılamak için, üretim verimliliğini artırırken aynı zamanda ürünlerin kalitesinin korunması gerekmektedir [1], [2]. Yüzey hata denetimi, kalite kontrolün en önemli bileşenlerinden birisidir. Geleneksel yüzey hata denetimi insan gözetiminde manuel olarak yapılmaktadır [3], [4]. Bu yöntem, fazla zaman harcanması, verimliliğin düşük olması ve öznel sonuçların elde edilmesi gibi dezavantajlara sahiptir [3]. Bu nedenle, imalat sistemlerinde pratik çözümler için gelişen teknolojiyi

kullanan otomatik yüzey hata denetimi, başlıca araştırma konularından biri olmuştur [1], [4], [5]. Günümüzde bilgisayarlı görme, görüntü işleme ve makine öğrenme teknolojisi, otomatik yüzey hata tespit sistemlerine uygulanmış ve başarılı sonuçlar alınmıştır [4], [5]. Fakat otomatik yüzey denetimi, yüzey hata tespitinde karşılaşılan problemlerden dolayı hala araştırmalara konu olmaktadır [3], [6], [7]. Şekil 1’de verildiği gibi, otomatik yüzey hata tespitinde karşılaşılan yaygın problemler şu şekildedir [5], [8]:

1. Aşırı uyum: Yüzeyde bulunan hatalı bölge ile arka plan arasında güçlü benzerlik olması.
2. Değişen hata boyutu: Yüzeyde oluşan hataların boyutlarının belirgin olmaması ve bazı hataların çok küçük boyutta olması.
3. Değişen ortam şartları: Görüntüdeki lekeler, gölgeler ve eşit olmayan aydınlatma gibi dış faktörlerin oluşması.



Şekil 1. Otomatik yüzey hata tespitinde karşılaşılan problemler: a) Aşırı uyum, a,b,c) Değişen hata boyutu, c)Değişen ortam şartları

Otomatik yüzey hata tespit yöntemleri, geleneksel hata tespit yöntemi ve derin öğrenme tabanlı hata tespit yöntemleri olarak ikiye ayrılmaktadır [4], [5]. Geleneksel hata tespit yöntemleri istatistiksel, spektral ve model tabanlı yaklaşımlardır [3]–[5]. Bu yöntemlerde yüzeyde oluşan hatalı bölgelerin tespiti için eşikleme, morfolojik işlemler, Yerel İkili Örüntü (YİÖ) ve Ölçekten Bağımsız Öznitelik Dönüşümü (ÖBÖD) gibi manuel olarak elde edilen öznitelikler kullanılmıştır [3], [6], [9]. Bu yöntemler aydınlatma, arka plan ve kamera açısı değiştiğinde, hata tespit performansı büyük ölçüde etkilenmektedir [5]. Ayrıca, bu yüzey hata tespit problemleri karşısında geleneksel yöntemler oldukça zayıftır. Tüm bu nedenlerden dolayı, bu yöntemlerin başka yüzeylere uygulanması sınırlıdır ve gerçek dünya uygulamaları için kullanışlı değildir [4], [5], [8].

Son zamanlarda, yüzey hata tespiti için derin öğrenme tabanlı Evrişimsel Sinir Ağları (ESA) kullanılarak yüksek performanslar elde edilmiştir [6], [9]. Evrişim, havuzlama ve doğrusal olmayan aktivasyon katmanlarından oluşan ESA, hata tespiti için etkili ve güçlü öznitelikleri otomatik bir şekilde elde etmektedir[1], [10]–[12]. ESA tabanlı yüzey hata tespit yöntemleri, Görüntü-seviyesinde, Bölge-seviyesinde ve Piksel-seviyesinde olmak üzere 3 yöntemden oluşmaktadır [1], [4]. Görüntü-seviyesinde hata tespiti yapan yöntemler, yüzey görüntüsünde hata olup olmama durumuna göre görüntüleri sınıflandırır. Bölge seviyesinde hata tespiti yapan yöntemler, görüntülerdeki hata konumunu dikdörtgen bir bölge ile tespit etmektedir. Bu yöntemlerde, genellikle R-CNN [13], Faster R-CNN [14], SSD [15] ve YOLO [16] gibi yöntemlerin temelleri kullanılmıştır. Son olarak, piksel seviyesinde hata tespiti yapan yöntemler, görüntüdeki hata konumu piksel seviyesinde (segmentasyon) tespit etmektedir. Bu yöntemler hata konumunu net olarak ortaya çıkardığı için popüler bir hale gelmiştir. [1], [4], [5].

Piksel seviyesinde hata tespiti yapan çalışmalar ikiye ayrılmıştır [5]. Bunlardan biri görüntüyü küçük parçalara ayırarak her bir parçanın hatalı olup olmama durumunu kontrol etmektedir. Fakat görüntünün parçalanması ve her bir görüntü parçasının ESA mimarisinden geçirilmesi, zaman alıcı ve maliyetli işlem olarak görülmüştür [5]. Piksel seviyesinde hata tespiti için geliştirilen diğer yöntemler ise Tam Bağlı Evrişim (TBE) modeli kullanarak görüntüyü bir bütün olarak ele almaktadır [4], [5]. Bu yöntemlerin ağ çıktıları, görüntü ile aynı boyutta olan bir hata tespit tahmin haritasıdır. Bunun yanı sıra, geliştirilen modellerde, LinkNet [17], Öznitelik Piramit Ağı (ÖPA, Feature Pyramid Networks) [18] ve U-net [19] gibi Kodlayıcı-Kod çözücü (Encoder-Decoder) modelleri kullanılmıştır. Özellikle ara bağlantılar ile şekil, kenar, renk ve doku gibi mekânsal bilgileri, son katmanlarda bulunan yüksek seviyeli öznitelikler ile birleştiren

U-net [19] ve ÖPA [18] mimarileri hata tespiti için güçlü modeller olmuştur. He ve ark. [20], hata tespiti için U-net mimarisi kullanmışlardır. Ayrıca önerilen modelde hata tespit başarısını artırmak için giriş görüntüsüne görüntü işleme teknikleri uygulanmıştır. Lu ve ark. [21], ray yüzeyindeki kusurların tespiti için U-net tabanlı SCueU-Net mimarisi önermişlerdir. Önerilen modelde SCue yapısı, giriş görüntüsünün hata konumlarını kabaca belirlemek için kullanılmıştır. Dong ve ark. [22], hatalı görüntüleri sınıflandırmak için DVM (Destek Vektör Makineleri) sınıflandırıcısına dayalı UNet modeli geliştirmişlerdir. Önerilen modelde U-net son katmanlarından alınan özneliklere DVM sınıflandırıcısı uygulanmıştır. Dong ve ark. [4] ÖPA mimarisinden esinlenerek hata tespiti için piramit özellikli füzyon modülü önermişlerdir. Benzer bir çalışmada [5] ise ÖPA mimarisine dikkat kapıları ekleyerek hata tespiti yapılmıştır.

Bu çalışmada, yüzey hata tespiti için Sonuç Ağırlıklandırma tabanlı Resnet Öznelik Piramit Ağ (SA-RÖPA) mimarisi geliştirilmiştir. Önerilen bu mimaride, yetersiz örnek problemi ile başa çıkmak için transfer öğrenme yaklaşımına dayalı önceden eğitilmiş Resnet50 ağ mimarisi kullanılmıştır. Buna ek olarak, ÖPA mimarisinin farklı seviyelerinden alınan öznelikleri doğrudan birleştirmek yerine Sonuç Ağırlıklandırma (SA) olarak adlandırılan yeni bir yaklaşım kullanılmıştır. Bu yaklaşımda, temel olarak Resnet50 [23] ağ mimarisinden alınan farklı seviyelerdeki öznelikleri kullanarak eş zamanlı 4 farklı hata tespit sonucu elde edilmiştir. Daha sonra, W ağırlık matrisi kullanılarak hata tespit sonuçlarının toplamı alınmıştır. Önerilen modelde, eğitim boyunca W ağırlık matrisindeki değerler, SA-RÖPA mimarisinin parametreleri ile eş zamanlı olarak güncellenmektedir. Bu sayede W ağırlık matrisi için ayrı bir eğitim şemasına ihtiyaç duyulmamaktadır. Önerilen SA-RÖPA modelinin performansını ölçmek için hata tespiti ile ilgili çalışmalarda yaygın olarak kullanılan MT, MVTec-Doku ve AITEX veri kümeleri kullanılmıştır. Deneysel sonuçlarda, önerilen model, son teknoloji yöntemlere göre daha başarılı olduğu gözlenmiştir.

Çalışmanın devamı şu şekilde organize edilmiştir. Bölüm 2’de, önerilen SA-RÖPA ağı mimarisi ve teorik alt yapısı detaylandırılmıştır. Bölüm 3’te, kullanılan veri kümesi ve uygulama sonuçları sunulmuştur. Son olarak Bölüm 4’te sonuçlar verilmiştir.

2. ÖNERİLEN YÖNTEM (PROPOSED METHOD)

Önerilen SA-RÖPA mimarisi, Kodlayıcı, Kod çözücü ve Sonuç Ağırlıklandırma (SA) olmak üzere 3 modülden oluşmaktadır (Şekil 2). İlk olarak, kodlayıcı biriminde, ResNet50 omurga ağı kullanılarak giriş görüntüsünden düşük ve yüksek seviyeli öznelik haritaları çıkartılmıştır. Düşük seviyeli öznelik haritaları renk, kenar, şekil ve doku gibi mekânsal (spatial) bilgilerini taşıyan öznelikleri barındırırken, yüksek seviyeli öznelik haritaları ise anlamsal (semantic) bilgileri içermektedir [4]. Daha sonra, kod çözücü bölümünde, Öznelik Piramit Ağ (ÖPA) [18] modeli kullanılarak farklı seviyelerden alınan öznelik haritaları arasında bilgi aktarımı yapılmıştır. Önerilen SA-RÖPA ağının son birimi olan SA modülünde, kod çözücü bölümünden elde edilen 4 farklı hata tespit sonucu, W ağırlık matrisi ile çarpılarak ağırlıklandırılmıştır. Son olarak ağırlıklandırılan sonuçlar toplanarak nihai hata tespit sonucu elde edilmiştir.

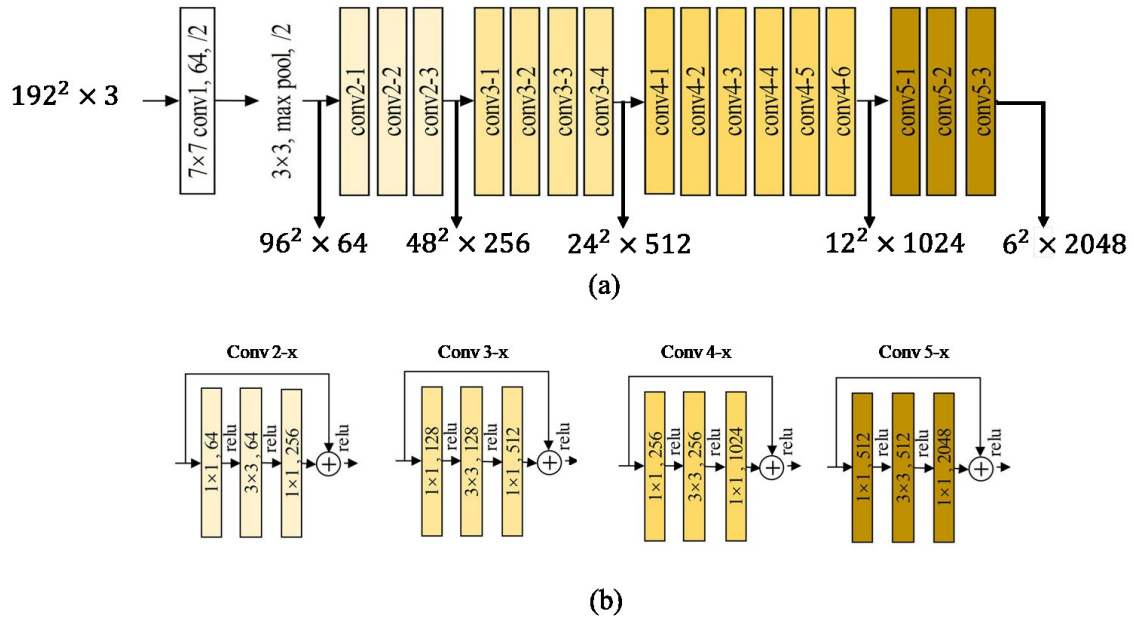


Şekil 2. Önerilen SA-RÖPA mimarisi

2.1. Kodlayıcı (Encoder)

Önerilen SA-RÖPA ağ mimarisinin kodlayıcı bölümünde, omurga ağı olarak önceden eğitilmiş ResNet50 (Şekil 3.a) ağ mimarisi kullanılmıştır. ResNet50 ağ mimarisi artık (residual) bağlantılar (Şekil 3.b) kullanılarak geliştirilmiş bir modeldir [24]. Bu yapı sayesinde, AlexNet, VGGNet gibi ağ mimarilerinden farklı olarak Resnet50 ağ mimarisi, kaybolan gradyan problemine (vanishing gradient problem) takılmadan 50 katmanlı bir yapı olarak geliştirilmiştir [23].

ESA mimarilerinde derin katmanlarına inilmesi ve bu katmanlar arasında bulunan havuzlama katmanlarından dolayı kenar, renk ve doku gibi mekânsal bilgilerinin kaybolmasına sebep olmaktadır. Bunun yanı sıra, doku bilgilerini taşıyan öznetelikler piksel seviyesinde hata tespiti için oldukça önemlidir. Bundan dolayı önerilen SA-RÖPA ağının kodlayıcı bölümünde düşük ve yüksek seviyeli olarak 5 farklı öznetelik haritası (F_{1-5}) çıkartılmıştır. Daha sonra, hata tespiti için elde edilen bu öznetelik haritaları kod çözücü bölümüne aktarılmıştır. Bu çıkartılan öznetelikler Şekil 3.a gösterilmiştir.



Şekil 3. Resnet50 ağ mimarisi (a) ve artık bağlantı modeli (b)

2.2. Kod çözücü (Decoder)

Önerilen SA-RÖPA mimarisinin kodlayıcı bölümünde elde edilen 5 farklı öznetelik haritasının (F_{1-5}) her biri hata tespiti için önemli bilgiler içermektedir. Bu öznetelik haritalarının ilk seviyeleri kenar, renk ve doku bilgileri içerirken, son seviyelerdeki öznetelik haritaları ise anlamsal bilgileri taşıyan zengin özneteliklerden oluşur. Fakat son seviyelerde alınan öznetelik haritalarında ağ mimarisi boyunca uygulanan havuzlama (Max-pooling) ve evrişim katmanları nedeniyle doku bilgileri kaybolmaktadır. SA-RÖPA mimarisinin kod çözücü biriminde bu öznetelikler arasında bilgi aktarımı yapılması için Öznetelik Piramit Ağ (ÖPA) [18] modeli kullanılmıştır. Öznetelik piramit modülünde, hiyerarşik olarak kendinden önceki öznetelik haritasını yeniden boyutlandırılarak eleman bazlı toplama işlemi uygulanır. Bu işlem Denklem 1'de verilmiştir.

$$G_l = \sum_{l=4}^{l=1} E_{cb=1 \times 1}^{fs=256}(F_l) + YÖ(E_{cb=3 \times 3}^{fs=256}(F_{l+1})) \quad (1)$$

Burada G_l , l 'ninci seviyesindeki öznetelik haritalarını ve E evrişim katmanını gösterir. YÖ ise boyut yükseltme (Upsampling) işlemi ifade etmektedir.


Denklem 1'den anlaşılacağı üzere, farklı seviyelerdeki öznitelik haritalarına bir evrişim işlemi ($E_{cb=3 \times 3}^{fs=256}$, filtre sayısı 256 ve çekirdek boyutu 3×3) uygulanmıştır. Daha sonra öznitelik haritaları boyut yükseltme katmanı ile yeniden boyutlandırılarak eleman bazlı toplama işlemi gerçekleştirilmiştir. Bu işlem sonucunda elde edilen 4 farklı öznitelik haritası (G_{1-4}) SA modeline aktarılmıştır.

2.3. Sonuç Ağırlıklandırma Modülü (Result Weighting Module)

Kod çözücü bölümünden elde edilen 4 farklı öznitelik haritalarının her biri, farklı doku ve anlamsal derin özniteliklere sahiptir. Bu öznitelik haritalarını doğrudan birleştirmek bazı önemli verilerin kaybolmasına sebep olabilmektedir. Bu çalışmada bu problemi ele alarak G_{1-4} öznitelik haritasının her biri için ayrı ayrı sonuç üretilmiştir. Daha sonra, bu sonuçlar önerilen Sonuç Ağırlıklandırma (SA) modülü ile birleştirilmiştir. SA modelinin ilk aşamasında, G_{1-4} öznitelik haritaları kullanılarak her bir öznitelik haritası için hata tespit sonucu (p_k) hesaplanmıştır (Denklem 2).

$$p_k = \sigma(E_{3 \times 3}^1(G_k)) \quad (2)$$

Burada p_k , G_k öznitelik haritası kullanılarak elde edilen hata tespit tahmin haritasıdır. $E_{3 \times 3}^1(\cdot)$, 1 filtre ve 3×3 çekirdek boyutuna sahip evrişim katmanıdır. $\sigma(\cdot)$ ise sigmoid aktivasyon fonksiyonunu temsil etmektedir.



Şekil 4. SA modelinde uygulanan noktasal evrişim (a) ve detaylı gösterimi (b)

SA modülünün ikinci aşamasında, sonuçlar birleştirilerek noktasal evrişim (point-wise convolution, şekil 4.a) işlemi uygulanır. Bu işlem, temel olarak şekil 4.b'de gösterildiği gibi farklı tahmin sonuçlarını $W = [w_1, w_2, w_3, w_4]$ ağırlık matrisleri ile ağırlıklandırılır. Daha sonra, elde edilen sonuçlar eleman bazlı toplama işlemi yapılır (Denklem 3).

$$P = \sum_{k=0}^4 w_k \cdot p_k \quad (3)$$

Burada \cdot işareti, w_k ile p_k değerlerinin noktasal çarpımını temsil etmektedir. P ise nihai sonuç haritasını gösterir. Yukarıdaki bahsedilen işlemlere dayalı SA modelinin yapısı Şekil 4'te verilmiştir.

SA-RÖPA mimarisinin eğitiminde The Binary Cross-Entropy loss function kullanılmıştır (Denklem 4).

$$L = - \sum_{i,j} y_{i \times j} \log(P_{i \times j}) + (1 - y_{i \times j}) \log(1 - P_{i \times j}) \quad (4)$$

Burada L , ortalama hata değerini; $y_{i \times j}$ ve $P_{i \times j}$, sırasıyla sonuç haritasındaki $i \times j$ konumundaki pikselin gerçek ile tahmin değerlerini temsil etmektedir.

3. DENEYSSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

Önerilen SA-RÖPA modelinin performansını test etmek için hata tespit görüntülerini içeren MT [20], MVTec-Doku [25] ve AITEX [26] veri kümeleri kullanılmıştır. Deneysel çalışmalarda, önerilen model, literatürde var olan çalışmaların performansları ile karşılaştırılmıştır. Ayrıca, nesne tespiti ve segmentasyon için geliştirilmiş ve yüksek başarımlara sahip olan ÖPA [18], LinkNet [17], PSPNet [27] ve Unet [19] mimarileri, hata tespit görüntülerini için uygulanmıştır ve elde edilen sonuçlar değerlendirilmiştir. Deneysel çalışmalarda tüm ağ modelleri aynı parametreler ile eğitilmiş ve test edilmiştir.

3.1. Veri Setleri (Datasets)

Bu çalışmada, yüzey hata tespiti için MT (Magnetic Tile, Manyetik Karo), MVTec-Doku ve AITEX veri kümeleri kullanılmıştır. MT veri kümesi, motor içinde bulunun mıknatıs yüzeyindeki çatlak, kırılma ve sıyırma gibi yüzey hata görüntülerini içermektedir. Deneysel çalışmalarda kullanılan AITEX, kumaş yüzeyinde oluşan farklı doku hatalarını içeren bir veri kümesidir. MVTec-Doku veri kümesi halı, tel levha, deri, fayans ve odun gibi 5 farklı yüzeyden alınmış görüntülerden oluşur. Bu görüntülerde farklı boyutta ve biçimde oluşan yüzey hataları vardır.

Deneysel çalışmalarda, MT, MVTec-Doku ve AITEX veri setleri için %50'si eğitim seti ve geri kalan ise test seti olarak kullanılmıştır. Eğitim ve test veri kümelerindeki kullanılan hatalı ve hatasız görüntü sayıları Tablo 1'de detaylı olarak verilmiştir. Deneysel çalışmalarda eğitim için yansıma, döndürme ve kırpma gibi veri çoğaltma yöntemleri kullanılarak örnek sayısı 8 katına çıkartılmıştır.

Tablo 1. Deneysel çalışmalarda kullanılan veri kümeleri ve örnek sayıları

Veri Kümesi	Eğitim Örnek Sayısı			Test Örnek Sayısı		
	Hatalı	Hatasız	Toplam	Hatalı	Hatasız	Toplam
MT	193	479	672	193	479	672
MVTec-Doku	190	700	890	190	700	890
AITEX	81	163	244	81	163	244

3.2. Uygulama Detayları (Implementation Details)

Önerilen ESA tabanlı mimarinin eğitimi için adım (epoch) sayısı 100, öğrenme oranı 0.0001, yığın boyutu (batch size) 16 ve Adam optimizasyon yöntemi kullanılmıştır. Tüm deneysel çalışmalar, i9-9900KF işlemci, 32 GB Ram ve 11 GB RTX 2080 Ti GPU donanımına sahip Ubuntu 20.04 işletim sistemi üzerinden gerçekleştirilmiştir. Deneysel çalışmalarda, performans metrikleri için F1-Skor ve mIoU (kesişimlerinin tüm alana oranının ortalaması, Mean intersection over union) metrikleri kullanılmıştır. F1-Skor ve mIoU metrikleri Denklem 5'e göre hesaplanır.

$$\begin{aligned}
 \text{Precision} &= \frac{TP}{TP + FP} \\
 \text{Recall} &= \frac{TP}{TP + FN} \\
 \text{F1 - score} &= \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \\
 \text{mIoU} &= \frac{pr \cap GT}{pr \cup GT}
 \end{aligned} \tag{5}$$

Burada *TP*, *TN*, *FP* ve *FN* sırasıyla doğru tespit edilen kusurlu piksel, doğru tespit edilen hatasız piksel, yanlış tespit edilen kusurlu piksel, yanlış tespit edilen hatasız piksel sayısını gösterir. *GT* Temel doğruluk; *pr* ise yüzey hata tespit tahmin haritasıdır.

3.3. Deneysel Sonuçlar (Experimental Results)

Önerilen SA-RÖPA modeli ile önceden geliştirilmiş derin mimarilerinin sayısal sonuçları Tablo 2’de verilmiştir. MT veri kümesi, aşırı uyum, küçük boyut ve değişen ortam şartları gibi problemleri içeren zor bir veri kümesidir. Önerilen SA-RÖPA modeli, bu problem karşısında üstün performans sağlamış ve bu veri seti için %79,92 mIoU ve %88,84 F1-skor olarak en yüksek skor elde edilmiştir. Bunun yanı sıra, ÖPA ağ mimarisi %75,52 mIoU başarımları sağlamıştır. Ayrıca, PSPNet ve Unet ağları ise yaklaşık olarak %71 mIoU skoru üretmişlerdir. MT veri kümesinde en düşük sonucu LinkNet ağ mimarisi vermiştir.

AITEX, kumaş yüzeyinde oluşan doku hatalarını içeren bir veri kümesidir. Bu veri kümesinde, arka plan ile aşırı uyum gösteren yüzey hatalarının tespit edilmesi oldukça zor olan görüntüler bulunmaktadır. Tablo 2’de verilen sonuçlara göre, bu veri kümesi için en yüksek performans önerilen SA-RÖPA modeli ile %79,92 mIoU olarak elde edilmiştir. Deneysel çalışmalarda kullanılan diğer ÖPA, UNet, LinkNet ve PSPNet ağları ise %80,11-80,78 mIoU arasında yakın sonuçlar vermiştir. En düşük sonuç, PSPNet ağ modeli ile %80,11 olarak hesaplanmıştır.

MVTec-Doku veri kümesi aşırı uyum, küçük boyut ve değişen ortam şartları gibi yüzey hata tespit problemleri içermektedir. Bu veri kümesinin sonuçlarında, MT ve AITEX veri kümesinde olduğu gibi SA-RÖPA modeli %76,37 mIoU ile en yüksek performansı sağlamıştır. ÖPA modeli %75,36 mIoU ile ikinci yüksek performansı elde etmiştir. LinkNet ve PSPNet ağları sırası ile %62,61 ve 66.18 skorları sağlarken Unet ağı ise %73,26 performans sağlamıştır.

Tablo 2. Performans sonuçları (%)

Method	MT		AITEX		MVTec-Doku	
	MIoU	F1-skor	MIoU	F1-skor	MIoU	F1-skor
LinkNet	59,49	74,6	80,31	89,08	62,61	77,00
PSPNet	71,41	83,32	80,11	88,96	66,18	79,65
Unet	71,85	83,62	80,78	89,36	73,26	84,57
ÖPA	75,52	86,05	80,38	89,12	75,36	85,95
Önerilen SA-RÖPA	79,92	88,84	82,72	90,54	76,37	86,60

MT veri kümesine ait örnek görüntüler için elde edilen görsel sonuçlar Şekil 5’te verilmiştir. Şekil 5’te yer alan Ör: 3 ve 5’te verilen yüzey hataları diğer örneklere göre daha belirgindir. Bundan dolayı, bu örnek görüntüler için tüm yöntemler başarılı olmuşlardır. Fakat Ör: 1, 2 ve 4’te küçük boyuta sahip yüzey hatalarını içeren ve farklı ışık ortamında alınmış görüntüler bulunmaktadır. Bu tür problemler karşısında, LinkNet, PSPNet, ÖPA ve Unet yöntemleri düşük sonuçlar vermiştir. Diğer yandan, SA-RÖPA modelinin güçlü ve etkili yapısı sayesinde en yüksek başarı elde edilmiştir. Ör: 6’da verilen görüntüde, arka plan ile aşırı uyum gösteren bir yüzey hatası bulunmaktadır. Bu tip yüzey hatalarında, yüzey hatasını ve arka planı ayıracak önemli özelliklerin çıkartılması gerekmektedir. Önerilen SA-RÖPA modelinin içerdiği önceden eğitilmiş Resnet50 mimarisi ve SA modeli sayesinde bu görüntülerde en yüksek başarıyı sağlamıştır.

	Görüntü	Gerçek Değer (GD)	LinkNet	PSPNet	Unet	ÖPA	SA-RÖPA
Ör: 1		GD	iou:70.96	iou:0.0	iou:70.0	iou:37.77	iou:77.77
Ör: 2		GD	iou:52.0	iou:0.0	iou:9.61	iou:2.55	iou:64.19
Ör: 3		GD	iou:57.59	iou:49.4	iou:55.61	iou:57.63	iou:69.56
Ör: 4		GD	iou:82.64	iou:57.06	iou:18.5	iou:36.56	iou:88.09
Ör: 5		GD	iou:84.07	iou:59.31	iou:89.81	iou:89.01	iou:92.91
Ör: 6		GD	iou:3.78	iou:0.0	iou:6.94	iou:84.94	iou:87.47

Şekil 5. MT veri kümesi için elde edilen görsel sonuçlar

AITEX veri kümesine ait örnek görüntüler için elde edilen görsel sonuçlar Şekil 6'da verilmiştir. MT veri kümesinden olduğu gibi AITEX veri kümesine ait tüm örnek görüntüler için en iyi sonuç, önerilen SA-RÖPA modeli ile elde edilmiştir. Verilen örneklerde Unet ve ÖPA mimarileri, LinkNet ve PSPNet ağlarına göre daha yüksek performans sağlamıştır. Ayrıca, Ör: 2'de PSPnet ve LinkNet ağları hatayı tam olarak tespit edemezken Unet ve ÖPA mimarileri PSPnet ve LinkNet ağlarına göre daha başarılı olarak tespit etmiştir. Ör: 2'deki hatayı en iyi tespit eden SA-RÖPA ağı olmuştur.

	Görüntü	Gerçek Değer (GD)	LinkNet	PSPNet	Unet	ÖPA	SA-RÖPA
Ör: 1		GD	iou:55.46	iou:52.5	iou:56.84	iou:58.34	iou:63.31
Ör: 2		GD	iou:9.05	iou:12.27	iou:43.36	iou:57.47	iou:68.02
Ör: 3		GD	iou:52.52	iou:26.54	iou:61.71	iou:71.7	iou:77.32
Ör: 4		GD	iou:97.85	iou:98.64	iou:96.52	iou:97.26	iou:99.77
Ör: 5		GD	iou:40.58	iou:44.71	iou:62.44	iou:47.77	iou:69.99

Şekil 6. AITEX veri kümesi için elde edilen görsel sonuçlar

MVTec-Doku veri kümesinden alınan örnek görüntüler ve yöntemlerin tahmin sonuçları şekil 7'de sunulmuştur. Burada görüleceği üzere yüzey hatalarını en iyi şekilde SA-RÖPA modeli tespit etmiştir. Özellikle örnek 3'te bulunan yüzey hatasını LinkNet, PSPNet, Unet ve ÖPA modelleri tespit edememişken

SA-RÖPA modeli yüksek doğrula yüzey hatasını tespit etmiştir. Benzer şekilde diğer örneklerde SA-RÖPA modeli diğer yöntemlere göre %10-66 mIoU arasında daha yüksek başarıyla yüzey hatasını tespit etmiştir.

	Görüntü	Gerçek Değer (GD)	LinkNet	PSPNet	Unet	ÖPA	SA-RÖPA
Örnek 1			iou:69.25	iou:58.56	iou:69.7	iou:44.74	iou:83.39
Örnek 2			iou:0.0	iou:77.52	iou:77.88	iou:22.37	iou:86.1
Örnek 3			iou:0.0	iou:0.0	iou:0.0	iou:0.0	iou:74.55
Örnek 4			iou:63.63	iou:46.87	iou:68.18	iou:63.82	iou:74.35
Örnek 5			iou:0.0	iou:0.0	iou:27.52	iou:13.2	iou:50.85

Şekil 7. MVTEc-Doku veri kümesi için elde edilen görsel sonuçlar

TARTIŞMA (DISCUSSION)

Önerilen SA-RÖPA mimarisinin performansı, mevcut çalışmada kullanılan veri kümelerine dayalı yapılmış çalışmalar ile kıyaslanmıştır. Bu karşılaştırmalı performans sonuçları Tablo 3'te verilmiştir.

Tablo 3. Önerilen model ile var olan çalışmaların karşılaştırılması

Veri Kümesi	Model	Metot	mIoU	F1-Score
MT	PGA-Net [4]	VGG16, Feature Fusion and Attention	71,31	-
	DFF [5]	ResNet50, Feature Fusion and Attention	73,70	82,20
	DPAE [28]	Semi-supervised Auto-Encoder	-	78,80
	SA-RÖPA	Resnet50, ÖPA ve Sonuç Ağırlıklandırma Modülü	79,92	88,84
AITEK	VGS [29]	Variational auto-encoder and gaussian mixture	-	81,00
	DCSNet [30]	GAN and Unet	34,20	-
	SA-RÖPA	Resnet50, ÖPA ve Sonuç Ağırlıklandırma Modülü	82,72	90,54

Tablo 3'te görüleceği üzere, MT ve AITEK veri kümeleri için önerilen model kullanılarak diğer çalışmalara kıyasla yaklaşık %7-9 başarımlı (F1-Skor) artışı sağlamıştır. Ayrıca, MT veri kümesi için en iyi ikinci F1-Skor değeri, DFF [24] çalışması ile elde edilirken, AITEK veri kümesi için ise VGS [25] çalışması ile %81,00 F1-Skor değeri elde edilmiştir. Sonuç olarak, önerilen SA-RÖPA model kullanılarak yüzey hata tespitine yönelik yapılan çalışmalara göre üstün performans elde ettiği açıkça gözlenmiştir.

SONUÇ (CONCLUSIONS)

Bu çalışmada yüzey hata tespiti için Sonuç Ağırlıklandırma tabanlı Resnet Öznetelik Piramit Ağ (SA-RÖPA) mimarisi geliştirilmiştir. Önerilen ağ mimarisinin kodlayıcı bölümünde, Resnet50 omurga ağından farklı seviyelerde öznetelikler çıkartılmıştır. ResNet50 ağ mimarisinin ilk katmanlarından alınan düşük seviyeli öznetelik haritaları renk, kenar ve şekil gibi doku bilgileri içerirken, son katmanlardan alınan yüksek seviyeli öznetelik haritaları ise anlamsal bilgilerden oluşmaktadır. Önerilen SA modeli ile bu öznetelik haritalarından ayrı ayrı sonuçlar almış ve bu sonuçları ağırlıklandırarak birleştirmiştir. Bu sayede, farklı seviyelerdeki öznetelik haritalarındaki önemli detaylar etkili bir şekilde kullanmıştır. Önerilen SA-RÖPA mimarisini test etmek için yüzey hata görüntülerini kapsayan MT, MVTec-Doku ve AITEX veri kümeleri kullanılmıştır. Deneysel sonuçlarda, MT, MVTec-Doku ve AITEX veri kümeleri için önerilen mimari kullanılarak sırasıyla %88,84, %86,60 ve %90,54 F1-Skor değerleri elde edilmiştir. Bu sonuçlara göre, önerilen SA-RÖPA mimarisi, son teknoloji yöntemler ve önceki çalışmalara göre daha başarılı olduğu gözlenmiştir. Gelecek çalışmalarda SA-RÖPA mimarisinin SA modelinde, dikkat kapıları (Attention Gate) kullanarak hata tespiti için daha etkili bir yapı oluşturulması hedeflenmiştir.

KAYNAKÇA (REFERENCES)

- [1] D. Zhang, K. Song, J. Xu, Y. He, M. Niu, and Y. Yan, "MCnet: Multiple Context Information Segmentation Network of No-Service Rail Surface Defects," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, 2021, doi: 10.1109/TIM.2020.3040890.
- [2] H. Uzen, M. Turkoglu, and D. Hanbay, "Texture defect classification with multiple pooling and filter ensemble based on deep neural network," *Expert Systems with Applications*, vol. 175, p. 114838, Aug. 2021, doi: 10.1016/j.eswa.2021.114838.
- [3] K. Hanbay, M. F. Talu, and Ö. F. Özgüven, "Fabric defect detection systems and methods—A systematic literature review," *Optik*, vol. 127, no. 24, pp. 11960–11973, Dec. 2016, doi: 10.1016/j.ijleo.2016.09.110.
- [4] H. Dong, K. Song, Y. He, J. Xu, Y. Yan, and Q. Meng, "PGA-Net: Pyramid Feature Fusion and Global Context Attention Network for Automated Surface Defect Detection," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 12, pp. 7448–7458, Dec. 2020, doi: 10.1109/TII.2019.2958826.
- [5] J. Cao, G. Yang, and X. Yang, "A Pixel-Level Segmentation Convolutional Neural Network Based on Deep Feature Fusion for Surface Defect Detection," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, 2021, doi: 10.1109/TIM.2020.3033726.
- [6] H. Y. T. Ngan, G. K. H. Pang, and N. H. C. Yung, "Automated fabric defect detection-A review," *Image and Vision Computing*, vol. 29, no. 7. Elsevier Ltd, pp. 442–458, Jun. 01, 2011. doi: 10.1016/j.imavis.2011.02.002.
- [7] X. Xie, A Review of Recent Advances in Surface Defect Detection using Texture analysis Techniques Figure 1: Example defects on different types of surfaces-from left: Steel, vol. 7, no. 3. 2008, pp. 1–22. Accessed: Jan. 08, 2021. [Online]. Available: <https://www.raco.cat/index.php/ELCVIA/article/view/150223>
- [8] G. Song, K. Song, and Y. Yan, "EDRNet: Encoder-Decoder Residual Network for Salient Object Detection of Strip Steel Surface Defects," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 12, pp. 9709–9719, Dec. 2020, doi: 10.1109/TIM.2020.3002277.
- [9] P. M. Bhatt et al., "Image-Based Surface Defect Detection Using Deep Learning: A Review," *Journal of Computing and Information Science in Engineering*, vol. 21, no. 4. American Society of Mechanical Engineers (ASME), Aug. 01, 2021. doi: 10.1115/1.4049535.

- [10] H. Firat, "3B ESA Tabanlı ResNet50 Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması Classification of Hyperspectral Images Using 3D CNN Based ResNet50," 2021 29th Signal Processing and Communications Applications Conference (SIU), pp. 6–9, 2021, doi: 10.1109/SIU53274.2021.9477899.
- [11] H. Firat and D. Hanbay, "Classification of Hyperspectral Images Using 3D CNN Based ResNet50," 2021 29th Signal Processing and Communications Applications Conference (SIU), pp. 1–4, Jun. 2021, doi: 10.1109/SIU53274.2021.9477899.
- [12] H. Uzen, H. Firat, A. Karci, and D. Hanbay, "Automatic Thresholding Method Developed with Entropy for Fabric Defect Detection," Sep. 2019. doi: 10.1109/IDAP.2019.8875890.
- [13] J. Long, E. Shelhamer, and T. Darrell, "Fully Convolutional Networks for Semantic Segmentation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 4, pp. 640–651, Nov. 2014.
- [14] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [15] W. Liu et al., "SSD: Single Shot MultiBox Detector," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9905 LNCS, pp. 21–37, Dec. 2015, doi: 10.1007/978-3-319-46448-0_2.
- [16] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016-December, pp. 779–788, Jun. 2015.
- [17] A. Chaurasia and E. Culurciello, "LinkNet: Exploiting encoder representations for efficient semantic segmentation," 2017 IEEE Visual Communications and Image Processing, VCIP 2017, vol. 2018-January, pp. 1–4, Feb. 2018, doi: 10.1109/VCIP.2017.8305148.
- [18] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature Pyramid Networks for Object Detection," Dec. 2016, Accessed: May 05, 2021. [Online]. Available: <http://arxiv.org/abs/1612.03144>
- [19] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9351, Springer Verlag, 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.
- [20] Y. Huang, C. Qiu, and K. Yuan, "Surface defect saliency of magnetic tile," *The Visual Computer*, vol. 36, no. 1, pp. 85–96, Jan. 2020, doi: 10.1007/s00371-018-1588-5.
- [21] J. Lu et al., "SCueU-Net: Efficient Damage Detection Method for Railway Rail," *IEEE Access*, vol. 8, pp. 125109–125120, 2020, doi: 10.1109/ACCESS.2020.3007603.
- [22] X. Dong, C. J. Taylor, and T. F. Cootes, "Defect Detection and Classification by Training a Generic Convolutional Neural Network Encoder," *IEEE Transactions on Signal Processing*, vol. 68, pp. 6055–6069, 2020, doi: 10.1109/TSP.2020.3031188.
- [23] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Jun. 2016, vol. 2016-Decem, pp. 770–778. doi: 10.1109/CVPR.2016.90.

- [24] W. Fang et al., “Recognizing Global Reservoirs From Landsat 8 Images: A Deep Learning Approach,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 12, no. 9, pp. 3168–3177, Aug. 2019, doi: 10.1109/JSTARS.2019.2929601.
- [25] P. Bergmann, M. Fauser, D. Sattlegger, and C. Steger, “MVTEC ad-A comprehensive real-world dataset for unsupervised anomaly detection,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Jun. 2019, vol. 2019-June, pp. 9584–9592. doi: 10.1109/CVPR.2019.00982.
- [26] J. Silvestre-Blanes, T. Albero-Albero, I. Miralles, R. Pérez-Llorens, and J. Moreno, “A Public Fabric Database for Defect Detection Methods and Results,” *Autex Research Journal*, vol. Vol. 19, no. 4, 2019, doi: 10.2478/aut-2019-0035.
- [27] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, “Pyramid scene parsing network,” *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, vol. 2017-January, pp. 6230–6239, Nov. 2017, doi: 10.1109/CVPR.2017.660.
- [28] J. Liu, K. Song, M. Feng, Y. Yan, Z. Tu, and L. Zhu, “Semi-supervised anomaly detection with dual prototypes autoencoder for industrial surface inspection,” *Optics and Lasers in Engineering*, vol. 136, p. 106324, Jan. 2021, doi: 10.1016/j.optlaseng.2020.106324.
- [29] Q. Zhou, J. Mei, Q. Zhang, S. Wang, and G. Chen, “Semi-supervised fabric defect detection based on image reconstruction and density estimation,” *Textile Research Journal*, vol. 91, no. 9–10, pp. 962–972, May 2021, doi: 10.1177/0040517520966733.
- [30] W. Yuxiang, M. Shiyi, X. Xiang, and H. Shanshan, “DCSNet: A Surface Defect Classification and Segmentation Model by One-Class Learning,” *Journal of Physics: Conference Series*, vol. 1914, no. 1, p. 012037, May 2021, doi: 10.1088/1742-6596/1914/1/012037.