





## Derinlemesine Özellik Piramit Ağı Kullanarak Yüzey Hata Tespiti Surface Defect Detection Using Depthwise Feature Pyramid Network

Hüseyin ÜZEN<sup>1</sup> , İlhami SEL<sup>2</sup> , Muammer TÜRKOĞLU<sup>3</sup> , Davut HANBAY<sup>2</sup> 

<sup>1</sup>Bilgisayar Mühendisliği Bölümü, Bingöl Üniversitesi, Bingöl, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

<sup>3</sup>Yazılım Mühendisliği Bölümü, Samsun Üniversitesi, Samsun, Türkiye

(huzen@bingol.edu.tr, ilhamisel23@gmail.com, muammer.turkoglu@samsun.edu.tr,  
davut.hanbay@inonu.edu.tr)

Received: Sep.3, 2021

Accepted: Sep.16,2021

Published: Oct.20, 2021

**Özetçe**— Yüzey hata tespiti, imalat sistemlerindeki en önemli kalite kontrol bileşenlerinden biridir. Üretim sistemlerinde otomatik yüzey hata algılama yöntemlerinin uygulanması, yüksek kaliteli ürünlerin sağlanmasında önemli bir etkidir. Bu çalışmada, otomatik yüzey hata tespiti için derinlemesine ayrılabilir evrişim tabanlı Derin Özellikli Piramit Ağ (DÖPA) mimarisi geliştirilmiştir. Bu ağ mimarisinde, önceden eğitilmiş VGG19 ağ mimarisinin öğrenilmiş parametreleri kullanılmıştır. Önerilen modelin performansını test etmek için hata tespit görüntüleri içeren MT veri seti kullanılmıştır. Deneysel çalışmalarda, önerilen DÖPA mimarisi kullanılarak %86,86 F1-skor elde edilmiştir. Bu sonuçlar, önerilen modelin var olan çalışmalardan daha başarılı olduğunu göstermiştir.

**Anahtar Kelimeler:** Yüzey Hata Tespiti; Derinlemesine Ayrılabilir Evrişim; Özellikli Piramit Ağı; Derin Öğrenme.

**Abstract**—Surface defect detection is one of the most important quality control components in manufacturing systems. The application of automatic surface defect detection methods in production systems is an important factor in ensuring high-quality products. In this study, depthwise separable convolution-based Deep Feature Pyramid Network (DÖPA) architecture was developed for automatic surface defect detection. In this network architecture, the learned parameters of the pre-trained VGG19 network architecture were used. MT dataset with defect detection images was used to test the performance of the proposed model. In experimental studies, 86.86% F1-score was obtained using the proposed DOPA architecture. These results showed that the proposed model was more successful than the existing studies.

**Keywords:** Surface Defect Detection; Depthwise Separable Convolution; Feature Pyramid Network; Deep Learning.

### 1. Giriş

Üretilen ürünlerin yüzeyinde bulunan hatalarının tespiti hem maddi kazanç hem de ürün kalitesini artırmayı sağlamaktadır. Bu açıdan imalat sanayisinde yüzey hata denetimi oldukça önemlidir. Günümüzde genellikle yüzey hata denetimi manuel yöntemler ile insan denetiminde yapılmaktadır. Fakat insan doğası gereği uzun ve monoton süren denetimlerde dikkat dağınıklığı meydana gelmektedir. Manuel denetimler %50-65 gibi düşük bir başarıya sahiptir. Bundan dolayı günümüzde otomatik yüzey hata tespiti en önemli araştırma konulardan biridir (Dong vd., 2020; Liu vd., 2021; Uzen vd., 2019, 2021).

Literatürde yüzey hata tespit yöntemleri, derin öğrenme ve geleneksel yöntemler olarak ikiye ayrılmaktadır. Geleneksel yüzey hata tespit yöntemleri eşikleme, morfolojik işlemler ve Fourier gibi geleneksel görüntü işleme yöntemleri kullanarak hata tespiti yapılmaktadır. Bunlarla birlikte önerilen bazı çalışmalarda KNN, SVM ve Random Forest gibi sınıflandırıcılar kullanan çalışmalar vardır. Geleneksel yöntemler, düz ve desensiz yüzeylerde uygulanmıştır. Genellikle bu yöntemler belli bir yüzey için parametreleri manuel ayarlanmaktadır. Bundan dolayı farklı yüzeylerde uygulanması zaman alıcı ve maliyetlidir (Dong vd., 2020; Hanbay vd., 2016; Liu vd., 2021).

Günümüzde yüzey hata tespit alanında en başarılı sonuçları derin öğrenme tabanlı yöntemler vermiştir. Derin öğrenme tabanlı yöntemler içerdiği evrişim, havuzlama, doğrusal olmayan fonksiyonlar ve tam bağlı katmanlar sayesinde probleme özgü ve güçlü öznitelikleri otomatik bir şekilde elde etmektedir. Bu sayede desenli ve desensiz yüzeylerde başarılı sonuçlar vermiştir (Dong vd., 2020; Fırat ve Hanbay, 2021; Fırat ve Alpaslan, 2020; Uzen vd., 2021).

Literatürde Evrişimsel sinir ağları (ESA) kullanılarak geliştirilen yöntemler, çelik yüzeyi (He vd., 2020), LCD panelleri (Yang vd., 2018) ve kumaş (Uzen vd., 2019) gibi yüzeylere başarılı bir şekilde uygulanmıştır. Wang vd. (Wang vd., 2018) imalat sistemleri için çeşitli derin öğrenme tekniklerini gözden geçirmiştir. Ren vd. (Ren vd., 2018) transfer öğrenme ve lojistik regresyon yöntemlerini bir arada kullanarak yüzey hata sınıflandırması yapmıştır. Zhou vd. (Zhou vd., 2019), yüzey kusurlarının sınıflandırılması için VGG16 ağı özniteliklerini geleneksel görüntü işleme teknikleri ile birleştirmiştir. Uzen vd. (Uzen vd., 2021) Önceden eğitilmiş ResNet101 ağını destek vektör makineleri ile birleştirmiştir. Önerilen model TILDA (Computer Vision Group, 1996) kumaş veri kümesine uygulanmış ve başarılı sonuçlar elde etmiştir. Ur Rahman ve Chen (Rahman ve Chen, 2020), güneş panellerinde oluşan yüzey hatalarını tespit etmek için U-Net modelini kullanmıştır. Benzer şekilde Balzategui vd. (Balzategui vd., 2020) güneş panelinden alınan görüntüleri tam evrişimsel ağ kullanarak yüzeyde oluşan çatlakları tespit etmiştir. Huang vd. (Huang vd., 2020) manyetik karolarda yüzey hatası tespiti için U-Net ve geleneksel yapay sinir ağlarını bir arada kullanmıştır.

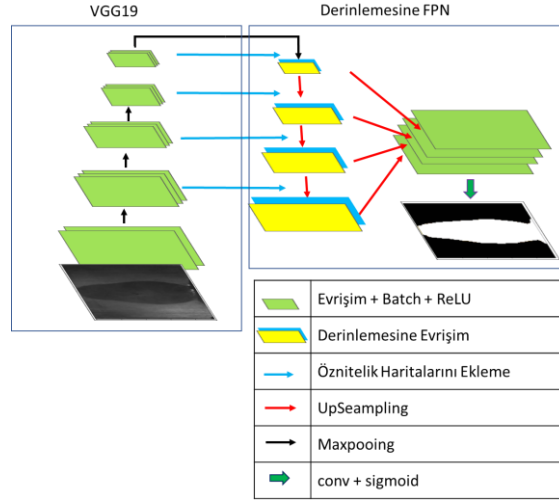
Yüzey hata tespit alanında yapılan çalışmalarda en çok U-Net (Ronneberger vd., 2015) ve Özellik Piramit Ağları (ÖPA) kullanılmıştır. Bunun temel sebebi bu ağları ara katmanları sayesinde yüksek seviyeli öznitelikleri düşük seviyeli öznitelikler ile birleştirerek güçlü bir öznitelik yapısı oluşturmasıdır (Dong vd., 2020; Huang vd., 2020).

Bu çalışmada yüzey hata tespiti için Derinlemesine ayrılabilir evrişim (DAE, depthwise separable convolution) katmanları içeren Derinlemesine Özellik Piramit Ağ (DÖPA, Depthwise Feature Pyramid Network) mimarisi geliştirilmiş ve yüzey hata tespit için uygulanmıştır. Önerilen DÖPA ağının giriş öznitelik haritası için VGG19 ağ mimarisinin öğrenilmiş parametreleri kullanılmıştır. DÖPA ağı MT (Huang vd., 2020) veri kümesine uygulanmış ve başarılı sonuçlar vermiştir.

Çalışmanın kalan kısmı şu şekilde organize edilmiştir. 2. Bölümde VGG19 ve Derinlemesine özellikli piramit ağı (DÖPA, Depthwise Feature Pyramid Network) mimarileri detaylandırılmıştır. Bölüm 3'te deneysel çalışmalar ve Bölüm 4'te sonuçlar verilmiştir.

## 2. MATERYAL VE METOT

Önerilen DÖPA ağı Şekil 1'de verilmiştir. Önerilen mimari VGG19'dan alınan 4 farklı öznitelik haritası Derinlemesine Ayrılabilir Evrişim (DAE, depthwise separable convolution) katmanlarından geçirilmiştir. Hata tespit sonucu elde etmek için DÖPA ağının her katmanından alınan öznitelik haritası yukarı örnekleme (UpSampling) katmanı kullanılarak görüntü ile aynı boyuta getirilmiştir. Daha sonra bu öznitelik haritaları birleştirilmiştir. Son olarak DÖPA ağın çıktısında bu öznitelik haritası bir evrişim ve sigmoid katmanından geçirilerek hata tespit sonucu elde edilmiştir.



**Şekil 1.** Derinlemesine Özellik Piramit Ağ (DÖPA, Depthwise Feature Pyramid Network) Mimarisi

## 2.1. VGG19 Ağ Mimarisi ile Transfer Öğrenme

Yüksek hesaplı bilgisayarların gelişmesi ile ESA mimarileri birçok farklı bilgisayar görü alanında uygulanmış ve yüksek başarılar elde etmiştir. ESA mimarilerinde kullanılan evrişim, havuzlama ve tam bağlı katmanlar sayesinde probleme özgü öznelikleri otomatik bir şekilde elde edebilmektedir. Evrişim katmanı görüntü işlemedeki filtreleme işlemleri ile aynıdır. Fakat en uygun öznelikler elde edilmesi için filtreleme işleminde kullanılan ağırlıklar, eğitim boyunca güncellenir (Dong vd., 2020; Huang vd., 2020).

ESA mimarilerin içerdiği parametreleri en iyi şekilde eğitilmesi için güçlü bir veri kümesine ihtiyaç vardır. Yüzey hata tespiti gibi problemlerde böyle bir veri kümesi genellikle bulunmamaktadır. Düşük sayıda örnek içeren problemlerde derin öğrenme mimarilerinin kullanılabilmesi için transfer öğrenme modeli gelişmiştir. Bu öğrenme modeli önerilen ESA mimarisini sıfırdan eğitmek yerine önceden eğitilmiş bir ağ mimarisinin parametreleri kullanılmaktadır. Daha sonra uygulanan problem için ESA mimarisi yeniden eğitilerek (fine-tuning) mimarinin parametreleri güncellenir (Uzen vd., 2021).

Bu çalışmada yüzey hata tespiti için VGG19 [15] ağ mimarisinin parametreleri kullanılmıştır. VGG19 ağ mimarisi 16 evrişim ve 3 tane tam bağlı katmandan oluşmaktadır. Bunların yanında ayrıca maxpooling, ReLU ve softmax katmanları içermektedir. VGG19 ağ mimarisinin daha fazla detayı için (Simonyan ve Zisserman, 2014) çalışmasına bakılabilir.

## 2.2. Derinlemesine Özellik Piramit Ağı

ESA mimarilerinde çok sayıda evrişim katmanı kullanılması, parametre sayısını artırmak ile beraber işlem maliyetini artırmaktadır. Bunun yanı sıra ağ mimarisinin eğitiminde büyük boyutlu veri kümelerine ihtiyaç duyulmasına sebep olmaktadır. Fakat hata tespitinde genellikle sınırlı sayıda örnek içeren veri kümeleri mevcuttur (Bergmann vd., 2019; Qiu vd., 2019; *Weakly Supervised Learning for Industrial Optical Inspection | Heidelberg Collaboratory for Image Processing (HCI)*, n.d.). Bu çalışmada, bu problemi ele alarak hata tespitinde az sayıda parametre ve katman içeren Derinlemesine Özellik Piramit Ağı (DÖPA) geliştirilmiştir. DÖPA mimarisinde VGG (Simonyan ve Zisserman, 2014), FPN (Lin vd., 2016), PGA (Dong vd., 2020) ve Unet (Ronneberger vd., 2015) mimarilerinde kullanılan geleneksel evrişim katmanları yerine, daha hesaplı olan Derinlemesine Ayrılabilir Evrişim (DAE, Depthwise Separable Convolution) (Howard vd., 2017) katmanları kullanılmıştır.

DAE işlemi Depth-wise evrişim ve Point-wise evrişim olmak üzere iki adımdan oluşur. Depth-wise evrişim işlevi şu şekilde tanımlanır:

$$O_{dw} = \sum_c^M I_c * F_c \quad (1)$$

Burada  $O_{dw}$  Depth-wise evrişim işlem sonucu,  $I_c$  ; I giriş görüntüsünün c kanalını ve  $F_c$ ; c kanalına ait filtreyi göstermektedir. DAE işleminin ikinci aşamasında elde edilen  $O_{dw}$  sonucu Point-wise evrişim işlemine alınır. Point-wise evrişim işlevi şu şekilde tanımlanır:

$$O_{pw} = \sum_c^N O_{dw} * F_{(1 \times 1)} \quad (2)$$

Burada  $O_{pw}$  point-wise evrişim işlem sonucu,  $F_{(1 \times 1)}$ ; 1x1 filtre boyutuna sahip evrişim filtresini göstermektedir.

Standard evrişim işlem maliyeti  $N \cdot M \cdot D_p^2 \cdot D_f^2$  olarak hesaplanmaktadır [16]. Bu durumda iki maliyet kıyaslandığında  $\frac{M \cdot D_f^2 \cdot D_p^2 + N \cdot M \cdot D_p^2}{N \cdot M \cdot D_p^2 \cdot D_f^2} = \frac{1}{N} + \frac{1}{D_f^2}$  sonucu elde edilir. Buda DAE işleminin çok daha az maliyetli olduğunu gösterir.

Şekil 1'de DÖPA mimarisinin detayları verilmiştir. DÖPA mimarisi için VGG19 ağı conv3-128, conv3-256, conv3-512 ve conv3-1024 katmanlarında öznetelik haritaları kullanılmıştır. VGG19 mimarisinden alınan öznetelik haritaları DÖPA bağlantıları ile birleştirilmiştir. Birleştirilen her bir öznetelik haritası DAE işleminden geçirilmiştir. Elde edilen çıktılardan her biri görüntü ile aynı boyuta getirmek için yukarı örnekleme katmanı uygulanmıştır. Daha sonra görüntü ile aynı boyutta olan 4 farklı öznetelik haritası birleştirilerek güçlü bir öznetelik haritası oluşturulmuştur. DÖPA ağı hata tespit çıktısı için elde edilen öznetelik haritası 1x1 çekirdeğe ve 1 filtreye sahip bir evrişim ve sigmoid aktivasyon fonksiyonu uygulanmıştır. İşlemler sonucunda görüntü ile aynı boyuta sahip hata tespit sonucu elde edilmiştir.

### 3. DENEYSEL ÇALIŞMALAR

Derinlemesine özellik piramit ağının (DÖPA) performansını değerlendirmek MT veri kümesi üzerinden deneysel çalışma ve analizler yapılmıştır. Buna ek olarak, önerilen model, MT veri kümesi kullanılarak yapılan önceki çalışmaların performansları ile karşılaştırılmıştır. Ayrıca birçok çalışmada yaygın olarak kullanılan Unet (Ronneberger vd., 2015) mimarisi ile kıyaslanmıştır.

#### 3.1. Uygulama Ayrıntıları

Deneysel çalışmalarda kullanılan MT (Huang vd., 2020) veri kümesi 1800 adet Magnetic Tilla görüntüleri içeren hata tespit veri kümesidir. MT veri kümesinde Blowhole, Crack, Fray, Break, Uneven hata tipini içeren görüntüler ve hatasız-görüntüler olmak üzere 6 sınıf vardır. Her sınıfa ait görüntüler ve görüntülere ait piksel seviyesinde hata konumunu veren gerçek değeri (ground truth) vardır. Bu çalışmada (Dong vd., 2020) nolu çalışmada ile benzer olacak şekilde Blowhole, Crack, Fray, Break, Uneven sınıflarını kullanılmıştır. MT veri kümesi %80 eğitim ve %20 test veri kümesi olarak ayrılmıştır. Eğitim ve test setindeki tüm görüntüler  $192 \times 192$  boyutuna indirgenmiştir.

DÖPA ağının eğitiminde batch size 16 ve epoch sayısı 100 alınmıştır. Ağın parametrelerin optimizasyonu için Adam optimizasyonu kullanılmıştır. Optimizasyon parametreleri olarak beta\_1=0.9, beta\_2=0.9, epsilon=1e-7 ve öğrenme oranı 0.001 olarak alınmıştır.

Yapılan deneysel çalışmalarda hata tespitinde yaygın kullanılan Mean Intersection Over Union (mIoU) ve F1-score metrikleri kullanılmıştır (Dong vd., 2020; Uzen vd., 2021). Kullanılan metriklerin şu şekilde tanımlanır:

$$\begin{aligned} \text{Precision} &= \frac{TP}{TP + FP} \\ \text{Recall} &= \frac{TP}{TP + FN} \\ \text{F1 - score} &= \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \\ \text{mIoU} &= \frac{1}{N} \sum_k^N \left( \frac{pr \cap GT}{pr \cup GT} \right)_k \end{aligned} \quad (3)$$


Burada FN, FP, TP ve TN parametreleri sırasıyla yanlış algılanan hatasız piksel, yanlış algılanan kusurlu piksel, doğru algılanan kusurlu piksel, doğru algılanan hatasız piksel sayısını gösterir. *GT* temel gerçek değerini ve *pr* tahmin değerini gösterir. Son olarak N veri kümesindeki örnek sayısını gösterir.

### 3.2. Uygulama Sonuçları

MT veri kümesi kullanılarak yapılan deneysel çalışma sonuçları Tablo 1’de verilmiştir. Elde edilen sonuçlarda en yüksek başarıyı %76.78 mIoU ve %86.86 F1-skor ile DÖPA mimarisi vermiştir. Literatürde bulunan DFF ve PGA-Net yöntemleri MT veri kümesinde sırasıyla %73.7 ve %71.31 mIoU skoru sağlamıştır. Literatürde bulunan PGA-Net [2] ve DFF [21] modellerin temelinde özellik piramit ağı kullanılmıştır. Bunun yanında önerdiğimiz DÖPA mimarisinde kullanılan Derinlemesine ayrılabilir evrişim katmanları sayesinde bu yöntemden daha yüksek başarı sağlamıştır. En düşük sonuçları Unet mimarisi elde etmiştir. DÖPA ağ mimarisinin önceden eğitilmiş parametreleri kullanılması sıfırdan eğitilen Unet mimarisine göre daha yüksek sonuçlar elde edilmesini sağlamıştır.

**Tablo 1.** MT veri kümesi kullanılarak elde edilen başarı sonuçları

Model	mIoU	F1-Skor
DÖPA (Önerilen)	<b>76.78</b>	<b>86.86</b>
Unet	65.73	79.32
PGA-Net (Dong vd., 2020)	71.31	-
DFF (Cao vd., 2021)	73.7	82.2



**Şekil 2.** MT veri kümesinde elde edilen görsel sonuçları

Şekil 2’de Unet ve DÖPA mimarisi kullanılarak MT test veri kümesinde elde edilen görsel sonuçlar verilmiştir. Verilen örneklerde DÖPA mimarisi %68.04 ile %89.74 arasında mIoU skoru ile tüm hataları tespit edebilmiştir. Bunun yanı sıra Unet ağı %24.69 ile %72.13 arasında daha düşük mIoU skoru elde etmiştir. Özellikle Örnek 1,2 ve 3’te Unet mimarisi ile elde edilen sonuçlarda hata boyutunu ayarlayamamış ve düşük sonuçlar vermiştir. Hata tespit alanında zor bir görüntü olan Örnek 4’te DÖPA

ağı %72.68 mIoU skoru ile hata konumunu doğru vermiştir. Unet mimarisi ise görüntüdeki alt bölgeyi hatalı bölge olarak verdiği için %24.69 mIoU skoru ile düşük sonuç vermiştir.

## Sonuç

Bu çalışmada, otomatik yüzey hata tespiti için Derinlemesine Özellik Piramit Ağ (DÖPA) mimarisi geliştirilmiştir. Önerilen DÖPA mimarisinde VGG19 ağ mimarisinin önceden eğitilmiş parametreleri kullanılmıştır. Ayrıca önerilen mimaride geleneksel evrişim katmanları kullanmak yerine derinlemesine ayrılabilir evrişim katmanları kullanılmıştır. Bu katman modelinin yapısı evrişim sırasında geleneksel evrişim katmanına göre daha düşük bir işlem maliyetine ihtiyaç duyar.

Önerilen DÖPA mimarisi düşük işlem maliyeti gerektiren güçlü bir ağ modeli olmuştur. MT yüzey hata tespit veri kümesi kullanılarak deneysel çalışmalar yapılmıştır. Deneysel çalışmalarda DÖPA mimarisi %86.86 F1-score ile literatürde bulunan diğer yöntemlere göre daha yüksek başarı sağlamıştır.

Gelecek çalışmalarda, yüzey hata tespitinde performansın yükseltilmesi için Derinlemesine Özellik Piramit Ağ mimarisine dayalı transformer modülü kullanılması planlanmaktadır.

## Kaynaklar

- Balzategui, J., Eciolaza, L., & Arana-Arexolaleiba, N. (2020). Defect detection on Polycrystalline solar cells using Electroluminescence and Fully Convolutional Neural Networks. *Proceedings of the 2020 IEEE/SICE International Symposium on System Integration, SII 2020*, 949–953. <https://doi.org/10.1109/SII46433.2020.9026211>
- Bergmann, P., Fauser, M., Sattlegger, D., & Steger, C. (2019). MVTEC ad-A comprehensive real-world dataset for unsupervised anomaly detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2019-June*, 9584–9592. <https://doi.org/10.1109/CVPR.2019.00982>
- Cao, J., Yang, G., & Yang, X. (2021). A Pixel-Level Segmentation Convolutional Neural Network Based on Deep Feature Fusion for Surface Defect Detection. *IEEE Transactions on Instrumentation and Measurement*, 70. <https://doi.org/10.1109/TIM.2020.3033726>
- Computer Vision Group, F. (1996). *TILDA Textile Texture-Database*. <https://lmb.informatik.uni-freiburg.de/resources/datasets/tilda.en.html>
- Dong, H., Song, K., He, Y., Xu, J., Yan, Y., & Meng, Q. (2020). 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>
- Firat, H., & Hanbay, D. (2021). Classification of Hyperspectral Images Using 3D CNN Based ResNet50. *2021 29th Signal Processing and Communications Applications Conference (SIU)*, 1–4. <https://doi.org/10.1109/SIU53274.2021.9477899>
- Firat, H., & Alpaslan, N. (2020). An effective approach to the two-dimensional rectangular packing problem in the manufacturing industry. *Computers and Industrial Engineering*, 148, 106687. <https://doi.org/10.1016/j.cie.2020.106687>
- Hanbay, K., Talu, M. F., & Özgüven, Ö. F. (2016). Fabric defect detection systems and methods—A systematic literature review. *Optik*, 127(24), 11960–11973. <https://doi.org/10.1016/j.ijleo.2016.09.110>
- He, Y., Song, K., Meng, Q., & Yan, Y. (2020). An End-to-End Steel Surface Defect Detection Approach via Fusing Multiple Hierarchical Features. *IEEE Transactions on Instrumentation and Measurement*, 69(4), 1493–1504. <https://doi.org/10.1109/TIM.2019.2915404>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. <http://arxiv.org/abs/1704.04861>
- Huang, Y., Qiu, C., & Yuan, K. (2020). Surface defect saliency of magnetic tile. *The Visual Computer*, 36(1), 85–96. <https://doi.org/10.1007/s00371-018-1588-5>

- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2016). *Feature Pyramid Networks for Object Detection*. <http://arxiv.org/abs/1612.03144>
- Liu, J., Song, K., Feng, M., Yan, Y., Tu, Z., & Zhu, L. (2021). Semi-supervised anomaly detection with dual prototypes autoencoder for industrial surface inspection. *Optics and Lasers in Engineering*, *136*, 106324. <https://doi.org/10.1016/j.optlaseng.2020.106324>
- Qiu, L., Wu, X., & Yu, Z. (2019). A High-Efficiency Fully Convolutional Networks for Pixel-Wise Surface Defect Detection. *IEEE Access*, *7*, 15884–15893. <https://doi.org/10.1109/ACCESS.2019.2894420>
- Rahman, M. R. U., & Chen, H. (2020). Defects Inspection in Polycrystalline Solar Cells Electroluminescence Images Using Deep Learning. *IEEE Access*, *8*, 40547–40558. <https://doi.org/10.1109/ACCESS.2020.2976843>
- Ren, R., Hung, T., & Tan, K. C. (2018). A Generic Deep-Learning-Based Approach for Automated Surface Inspection. *IEEE Transactions on Cybernetics*, *48*(3), 929–940. <https://doi.org/10.1109/TCYB.2017.2668395>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). 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, pp. 234–241). Springer Verlag. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *Information and Software Technology*, *51*(4), 769–784. <http://arxiv.org/abs/1409.1556>
- Uzen, H., Firat, H., Karci, A., & Hanbay, D. (2019, September 1). Automatic Thresholding Method Developed with Entropy for Fabric Defect Detection. *2019 International Conference on Artificial Intelligence and Data Processing Symposium, IDAP 2019*. <https://doi.org/10.1109/IDAP.2019.8875890>
- Uzen, H., Turkoglu, M., & Hanbay, D. (2021). Texture defect classification with multiple pooling and filter ensemble based on deep neural network. *Expert Systems with Applications*, *175*, 114838. <https://doi.org/10.1016/j.eswa.2021.114838>
- Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, *48*, 144–156. <https://doi.org/10.1016/j.jmsy.2018.01.003>
- Weakly Supervised Learning for Industrial Optical Inspection | Heidelberg Collaboratory for Image Processing (HCI)*. (n.d.). Retrieved March 5, 2021, from <https://hci.iwr.uni-heidelberg.de/content/weakly-supervised-learning-industrial-optical-inspection>
- Yang, H., Mei, S., Song, K., Tao, B., & Yin, Z. (2018). Transfer-Learning-Based Online Mura Defect Classification. *IEEE Transactions on Semiconductor Manufacturing*, *31*(1), 116–123. <https://doi.org/10.1109/TSM.2017.2777499>
- Zhou, F., Liu, G., Xu, F., & Deng, H. (2019). A generic automated surface defect detection based on a bilinear model. *Applied Sciences (Switzerland)*, *9*(15), 3159. <https://doi.org/10.3390/app9153159>