



## InceptionV3 based enriched feature integration network architecture for pixel-level surface defect detection

Hüseyin Üzen<sup>1\*</sup>, Muammer Türkoğlu<sup>2</sup>, Ali Arı<sup>3</sup>, Davut Hanbay<sup>3</sup>

<sup>1</sup>Department of Computer Engineering, Faculty of Engineering and Architecture, Bingöl University, 12000, Bingöl, Türkiye

<sup>2</sup>Department of Software Engineering, Faculty of Engineering, Samsun University, 55420, Samsun, Türkiye

<sup>3</sup>Department of Computer Engineering, Faculty of Engineering, İnönü University, 44280, Malatya, Türkiye

### Highlights:

- Extraction of powerful features from InceptionV3 architecture for surface defect detection.
- Combining low-level and high-level features with the FPN module.
- Strengthening important details from feature maps with Squeeze and Excitation blocks

### Keywords:

- Pixel-level surface defects detection
- Convolutional neural network
- Squeeze and Excitation Block
- Feature Pyramid Networks

### Article Info:

Research Article

Received: 16.11.2021

Accepted: 21.03.2022

### DOI:

10.17341/gazimmfd.1024425

### Acknowledgement:

This study was supported by Inonu University Scientific Research Projects Coordination Unit (Project Number: FDK-2021-2725)

### Correspondence:

Author: Hüseyin Üzen

e-mail:

hnuzen@bingol.edu.tr

phone: +90 426 216 0033 / 1922

### Graphical/Tabular Abstract

Surface defects detection in manufacturing systems is very important for product quality. Early detection of surface defects with high accuracy can prevent waste of sources and time. Manual controls, which are widely used today, are less efficient in terms of time and accuracy. In this study, InceptionV3 based Enriched Feature Integration Network (Figure A) architecture with high performance has been developed for automatic surface defect detection at pixel level.

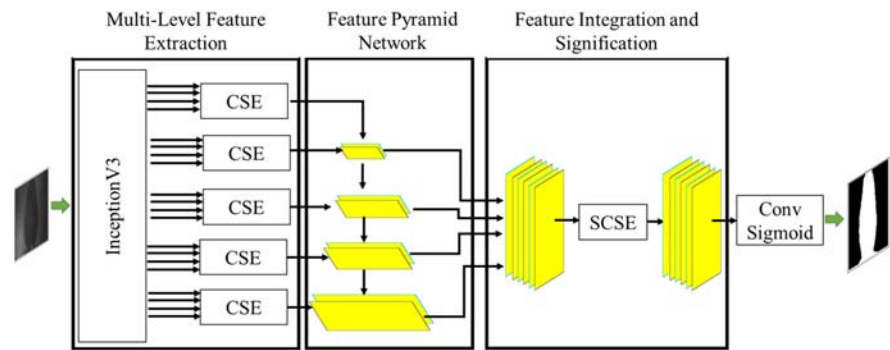


Figure A. Framework of the proposed model

**Purpose:** The main purpose of this study is to develop a novel deep architecture based on extracting powerful and effective features for automatic surface defect detection at pixel level.

**Theory and Methods:** In the proposed InceptionV3 based Enriched Feature Integration Network (Inc-EFIN), low-level and high-level features are taken from each level of the InceptionV3 network. Features with the same height and width are merged. As a result of merging, 5 feature maps of different sizes were obtained. Channel-based Squeeze and Excitation (CSE) block has been applied to reveal important details in these feature maps. Then, information from high-level feature maps containing semantic information was transferred to low-level feature maps containing spatial information such as edge color and texture with the Feature Pyramid Network module. Then, for the final feature map in the proposed architecture, the output feature maps of the FPN module were combined in the Feature Integration and Signification module. The combined feature map is passed through the Spatial and Channel based Squeeze and Excitation (SCSE) block to best strengthen the spatial and semantic information that may be important for defect detection. The defect detection result is obtained by applying convolution and sigmoid layers to the feature map strengthened in the last layer of the Inc-EFIN architecture.

**Results:** Experimental studies were carried out on MT, MVTEC-Texture, and DAGM datasets to measure the pixel-level defect detection success of the Inc-EFIN. In experimental studies, Inc-EFIN provided the highest performances with 77.44% mIoU, 81.2% mIoU, and 79.46% mIoU in MT, MVTEC-Texture, and DAGM datasets, respectively.

**Conclusion:** Experimental results showed that the proposed model outperformed the state-of-the-art approaches. In addition, Squeeze and Excitation models have been found to be effective in enhancing features. This study will guide the development of effective deep models for automatic surface defect detection in manufacturing systems.



## Piksel seviyesinde yüzey hata tespiti için inceptionV3 tabanlı zenginleştirilmiş öznetelik entegrasyon ağ mimarisi

Hüseyin Üzen<sup>1\*</sup>, Muammer Türkoğlu<sup>2</sup>, Ali Arı<sup>3</sup>, Davut Hanbay<sup>3</sup>

<sup>1</sup>Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 12000, Bingöl, Türkiye

<sup>2</sup>Samsun Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 55420, Samsun, Türkiye

<sup>3</sup>İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 44280, Malatya, Türkiye

### Ö N E Ç İ K A N L A R

- Yüzey hata tespiti için InceptionV3 mimarisinden güçlü özneteliklerin çıkarımı
- ÖPA modülü ile düşük seviyeli ve yüksek seviyeli özneteliklerin birleştirilmesi
- Sıkıştırma ve uydurma blokları ile öznetelik haritalarından önemli ayrıntıları güçlendirilmesi

### Makale Bilgileri

Araştırma Makalesi

Geliş: 16.11.2021

Kabul: 21.03.2022

### DOI:

10.17341/gazimmfd.1024425

### Anahtar Kelimeler:

Piksel seviyesinde yüzey kusurları algılama, evrişimsel sinir ağı, sıkma ve uyarma bloğu, özellik piramit ağı

### ÖZ

Bu çalışmada, otomatik yüzey hata tespiti için InceptionV3 tabanlı Zenginleştirilmiş Öznetelik Entegrasyon Ağ (Inc-ZÖEA) mimarisi geliştirilmiştir. Önerilen mimaride, InceptionV3 mimarisinin her seviyesindeki öznetelikler çıkartılmış ve aynı yükseklik ve genişliğe sahip öznetelikler birleştirilmiştir. Birleştirme sonucunda 5 öznetelik haritası elde edilmiştir. Bu öznetelik haritalarındaki önemli detayları ortaya çıkartmak için Kanal Bazlı Sıkma ve Uyarlama bloğu uygulanmıştır. Öznetelik Piramit Ağ (ÖPA) modülünde mekânsal detayları içeren düşük seviyeli öznetelik haritalarındaki bilgiler, anlamsal detayları içeren yüksek seviyeli öznetelik haritalarına aktarılmıştır. Daha sonra önerilen mimaride nihai öznetelik haritası için Öznetelik Entegrasyon ve Anlamlandırma (ÖEA) modülü kullanılarak öznetelik haritaları birleştirilmiştir. ÖEA modülünde birleştirilen öznetelik haritası, Mekânsal ve Kanal Bazlı Sıkma ve Uyarlama bloğundan geçirilmiştir. Inc-ZÖEA mimarisinin son katmanında evrişim ve sigmoid katmanları kullanılarak hata tespit sonucu elde edilmiştir. Inc-ZÖEA mimarisinin piksel seviyesinde hata tespit başarısını ölçmek için MT, MVTec-Doku ve DAGM veri setleri kullanılmıştır. Deneysel çalışmalarda, MT, MVTec-Doku ve DAGM veri setlerinde sırası ile Inc-ZÖEA mimarisi %77,44 mIoU, %81,2 mIoU ve %79,46 mIoU başarımlarıyla literatürde yer alan son teknolojilere göre daha yüksek başarımlar sağlamıştır.

## InceptionV3 based enriched feature integration network architecture for pixel-level surface defect detection

### H I G H L I G H T S

- Extraction of powerful features from InceptionV3 architecture for surface defect detection
- Combining low-level and high-level features with the FPN module
- Strengthening important details from feature maps with Squeeze and Excitation blocks

### Article Info

Research Article

Received: 16.11.2021

Accepted: 21.03.2022

### DOI:

10.17341/gazimmfd.1024425

### Keywords:

Pixel-level surface defects detection, convolutional neural network, squeeze and excitation block, feature pyramid networks

### ABSTRACT

In this study, InceptionV3 based Enriched Feature Integration Network (Inc-EFIN) architecture was developed for automatic detection of surface defects. In the proposed architecture, features of all levels of the InceptionV3 architecture are extracted and the features with the same height and width are combined. As a result of merging, 5 feature maps were obtained. Channel-Based Squeeze and Excitation block has been applied to reveal important details in these feature maps. In Feature Pyramid Network module, information from low-level feature maps containing spatial details were transferred to high-level feature maps containing semantic details. Then, for the final feature map, features were combined using the Feature Integration and Signification (FIS) module. The feature map combined in the FIS module was passed through the Spatial and Channel-based Squeeze and Excitation block. Defect detection results were obtained by using convolution and sigmoid layers in the last layer of the Inc-EFIN architecture. MT, MVTec-Texture, and DAGM datasets were used to calculate the pixel-level defect detection success of the Inc-EFIN architecture. In experimental studies, Inc-EFIN architecture achieved higher performance than the latest technologies in the literature with 77.44% mIoU, 81.2% mIoU and 79.46% mIoU performance results in MT, MVTec-Texture and DAGM datasets, respectively.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*huzen@bingol.edu.tr, muammer.turkoglu@samsun.edu.tr, ali.ari@inonu.edu.tr, davut.hanbay@inonu.edu.tr / Tel: +90 426 216 0033 /1922

## 1. Giriş (Introduction)

İmalat sistemlerinde yüzey hatalarının tespit edilmesi, maddi kayıpları önleyerek yüksek kalite ürün sağlanması açısından oldukça önemlidir. Yüzey hataları yalnızca ürünün görünümünü etkilemekle kalmaz, aynı zamanda üretim performansını ve ürün güvenliği üzerinde uzun vadeli olumsuz etkilere de sebep olur. Manuel denetimlerin uzun vadede yüksek doğruluk sağlamadığı görülmüştür [1]. Gelişen teknolojiyle beraber bilgisayarlı görü ve makine öğrenme tabanlı otomatik yüzey hata tespiti, manuel denetimlere göre yüksek doğruluk, devamlılık ve güvenilirlik açısından daha etkili olduğu ispatlanmıştır [1, 2].

Otomatik yüzey hata tespiti için görüntü işleme ve makine öğrenme yöntemleri kullanılarak birçok yöntem geliştirilmiştir. Bu yöntemler geleneksel hata tespit yöntemleri ve derin öğrenme tabanlı yöntemler olarak ikiye ayrılmaktadır. Geleneksel hata tespit yöntemlerinde eşikleme, morfolojik işlemler ve Fourier Dönüşüm gibi görüntü işleme yöntemleri kullanılarak hata tespiti yapılmıştır [1]. Bunun yanında, gelişmiş birçok yöntem, görüntü işleme yöntemleri ile Destek Vektör Makineleri (DVM), k-En Yakın Komşu (k-EYK) ve Yapay Sinir Ağları (YSA) gibi geleneksel makine öğrenme yöntemlerini birleştirerek güçlü bir yapı oluşturmuşlardır [3]. Aghdam vd. [4] çelik yüzeyindeki hataları tespit etmek için Karar Ağaçları ve Yerel İkili Örtüntü (YİÖ) yöntemlerini kullanmışlardır. Önerilen modelde performansı artırmak için özneteliklere Temel Bileşen Analizi (TBA) ve Bootstrap Aggregation yöntemleri uygulanmıştır. Tsanakas vd. [5] fotovoltaiik yüzeydeki kusurları tespit etmek için termal görüntüleri filtreleme işlemleri ve Canny kenar algılama yöntemlerini kullanmışlardır [6]. Mik vd. Gabor dalgacık dönüşümü kullanarak kumaşın doku özelliklerini çıkarmışlardır. Önerilen modelde elde edilen doku öznetelikleri morfolojik işlemler ve eşikleme uygulanarak kumaş hata tespiti yapılmıştır. Bai vd. [7] elektronik çiplerdeki hataları bulmak için Fourier dönüşümü ve yerel uyarlamalı eşik kullanmışlardır. Liu ve Zheng [8], iki boyutlu entropi ve hiper-karmaşık Fourier dönüşümüne dayalı denetimsiz bir kumaş hata tespit yöntemi önermişlerdir. Önerilen modelde temel olarak hatasız kumaş yüzeyinin düzgün dağılımı elde edilmiştir. Bunun yanı sıra kumaş hatası içeren görüntülerde bu dağılıma uygun olmayan bölgeler hatalı bölge olarak kabul edilmiştir. Dong vd. [9] X-ışını görüntülerindeki hataları tespit etmek için görüntü işleme tekniklerini kullanan Rastgele Orman tabanlı bir şema önermişlerdir. Bu modelde öncelikle görüntüdeki her pikselin hatalı olup olmadığına karar verilmiştir. Ardından, kusurlu pikseller birleştirilerek hatanın tam konumu tespit edilmiştir. Geleneksel hata tespit yöntemlerinde genellikle temel görüntü işleme, yönlendirilmiş gardiyan histogramı (histogram of oriented gradient), ölçek bağımsız öznetelik dönüşümü (scale-invariant feature transform) ve YİÖ gibi manuel öznetelik çıkartma yöntemleri kullanılmıştır. Ayrıca, bu yöntemler genellikle desensiz ve belirli bir yüzey için uygulanmıştır. Bu yöntemlerin temel parametreleri, yüzey görüntüsüne bağlı olarak manuel ayarlandığından, farklı desenli yüzeylere uygulanması maliyetlidir. Buna kıyasla, günümüzde gelişen teknolojiyle beraber derin öğrenme tabanlı yüzey hata tespit yöntemleri, farklı yüzey ve desenlerde daha yüksek başarımlar sağlamıştır [2, 10, 11].

Derin öğrenme tabanlı yüzey hata tespit yöntemleri görüntü seviyesinde hata tespiti, bölge seviyesinde hata tespiti ve piksel seviyesinde hata tespiti olarak ayrılmaktadır. Görüntü seviyesinde hata tespit yöntemleri, yüzey görüntüsünde hata olup olmama durumuna göre görüntüleri sınıflandırmaktadır. Yi vd. [12] çelik yüzey kusurlarını sınıflandırmak için, uçtan uca bir Evrişimsel Sinir Ağ (ESA) mimarisi geliştirmişlerdir. Önerilen mimaride, evrişim ve havuzlama katmanlarından sonra tam bağlı katmanlar uygulanmıştır. Ağ mimarisinin çıktısı, 7 farklı görüntü hatasını kategorize edecek şekilde ayarlatılmıştır. Jain vd. [13] hatalı görüntüleri sınıflandırmak

için bir ESA mimarisi tasarlamışlardır. Bu mimaride yüksek performans sağlamak için veri setindeki görüntüler Çekişmeli Üretken Ağ (Generative Adversarial Networks) mimarisi ile çoğaltılmıştır. Bölge seviyesinde hata tespiti, görüntülerdeki hata konumunu kabaca dikdörtgen bir bölge ile gösteren yöntemlerdir. Bu yöntemlerde genellikle R-CNN [14], Faster R-CNN [15], SSD [16] ve YOLO [17] gibi yöntemlerin temelleri kullanılmıştır. He vd. [18], çelik kusur tespiti için Bölge Teklif Ağı kullanarak uçtan uca bir ESA mimarisi tasarlamışlardır. Bu tasarımda ESA'nın farklı katmanlarından gelen öznetelikleri birleştirmek için çok düzeyli bir öznetelik füzyon ağı kullanılmıştır. Yanan vd. [19], ray yüzeyindeki hatalarının tespiti için YOLOv3 [20] modeli ile görüntünün S×S boyutundaki parçalarının hatalı olup olmadığı tahmin edilmiştir. Tahmin puanını elde etmek için lojistik regresyon kullanılmıştır. Yuan vd. [21], MobileNetV2 [22] ve YOLOv3 ağ mimarilerini birleştirerek MOLO ağ mimarisini önermişlerdir. Önerilen modelde, Omurga (Backbone) ağı olan MobileNetV2 ağ mimarisinden alınan öznetelik haritaları YOLOv3 ağ yapısı ile birleştirilmiştir.

Piksel seviyesinde hata tespiti için geliştirilen yöntemler arasında en popüler ve seçkin hata tespit yapan yöntemlerdir. Bu yöntemlerde, görüntüdeki hata konumu piksel seviyesinde (segmentasyon) tespit edilmektedir. Piksel seviyesinde yüzey hata tespiti yapan yöntemlerde genellikle, LinkNet [23], Öznetelik Piramit Ağı (ÖPA, Feature Pyramid Networks) [24] ve U-net [25] gibi Kodlayıcı-Kod çözücü (Encoder-Decoder) segmentasyon ağları kullanılmıştır. Bu ağ mimarilerinin içerdiği ara bağlantılar kenar, renk ve doku gibi mekânsal (spatial) bilgiler içeren düşük seviyeli öznetelikleri, anlamsal (semantic) bilgiler içeren yüksek seviyeli öznetelikler ile birleştirmiştir. Bu sayede arka plan ile aşırı uyum gösteren hataları ve küçük hataları daha iyi tespit edebilmiştir. Benzer şekilde dinamik (karmaşık veya kompleks) arka plana sahip görüntülerde mekânsal bilgiler son katmana taşındığı için piksel seviyesinde hata tespiti daha iyi yapılmıştır. Huang vd. [26], manyetik karo yüzey hatalarının tespiti için U-net tabanlı MCuePush U-Net mimarisini tasarlamışlardır. Önerilen mimari MCue, U-Net ve Push ağ bileşenlerinden oluşmaktadır. Geleneksel görüntü işleme yöntemi olan MCue, giriş görüntüsünün hata konularını kabaca belirlemek için kullanılmıştır. Daha sonra, piksel seviyesinde hata konumu için U-Net mimarisi uygulanmıştır. U-net çıktısını desteklemek için tam bağlı iki katmandan oluşan bir Push ağı oluşturulmuştur. Benzer bir çalışmada [27], ray yüzeyindeki kusurların tespiti için SCueU-Net mimarisi önerilmiştir. U-net ağ mimarisi kullanılarak yapılan başka bir çalışmada [28], hatalı görüntüleri sınıflandırmak için U-net'in kodlayıcı bölümünden alınan özneteliklere DVM sınıflandırıcısı uygulanmıştır. Dong vd. [2], piksel düzeyinde yüzey kusurlarının tespiti için VGG16 ağ mimarisinin katmanlarından beslenen bir piramit özellik füzyonu ve küresel bağlam dikkat ağı önermişlerdir. VGG16'dan elde edilen özellikleri birleştirmek için piramit özellik füzyon modülü kullanılmıştır. Küresel bağlam dikkat modülü, farklı seviyelerden alınan düşük ve yüksek seviyeli öznetelikleri etkili bir şekilde birleştirilmesini sağlamıştır. Başka bir çalışmada ise [10] önceden eğitilmiş Resnet50 ağ mimarisi kullanılmıştır. Bu yöntemlere ek olarak literatürde Auto-Encoder (Oto-Kodlayıcı) tabanlı denetimsiz yüzey hatası algılama yöntemleri geliştirilmiştir. DifferNet [29] modelinde, önceden eğitilmiş AlexNet mimarisinden çok ölçekli bir özellik çıkarıcı modülü ile anlamlı öznetelikler çıkarılmıştır. Tahmini bir hata konumu elde etmek için bu özelliklere Normalleştirme Akışı yöntemi kullanılmıştır. Liu vd. [30] 2 kodlayıcı ve bir kod çözücü yapısı olan bir Oto-kodlayıcı mimarisi tasarlamıştır. Önerilen modelde giriş görüntüsü sırasıyla kodlayıcı-1, kod-çözücü ve kodlayıcı-2 yapılarından geçirilmiştir. Her kodlayıcı çıkışında elde edilen latent (gizli) vektörler karşılaştırılarak hata tespit sonucu elde edilmiştir. Defard vd. [31] denetimsiz hata tespiti için PaDiM modelini önermişlerdir. Önerilen modelde, yüzey hatası bulunan

görüntüler ile hatasız görüntüleri ayırt etmek için önceden eğitilmiş ESA mimarisinden öznetelikler çıkarılmıştır. Görüntünün her bir pikseli için alınan öznetelikten gömme (embedding) vektörleri elde edilmiştir. Gömme vektörlerinin boyutu Temel Bileşen Analizi kullanılarak küçültülmüştür. Son olarak, bir anormallik (anomaly) skoru atamak için Mahalanobis mesafesi kullanılmıştır. Tan vd. [32], Oto-kodlayıcı'nın aşırı genelmesini önlemek için bellek güncelleme modeli önermişlerdir. Bu yapı, görüntülerin kod çözümü ile yeniden oluşturmayı daha güvenilir hale getirmiştir. Önerilen modelde, görüntüler arasındaki farkı belirlemek için Mekânsal Algısal Mesafe (MAM) modeli kullanılmıştır. Wang vd. [33], sınırlı öznetelik, dinamik arka plan ve gürültü içeren görüntülerde yüzey hata tespiti için Dışbükey Olmayan Toplam Varyasyon Düzenliliğine (Non-convex Total Variation Regularized) dayalı KRPCA-NTV modeli önermiştir. Önerilen modelde, Çekirdek Kanonik Korelasyon Analizi (Kernel Canonical Correlation Analysis) ile öznetelikler çıkarılmıştır. Daha sonra Konveks Olmayan Toplam Varyasyon (Nonconvex Total Variation) ile arka plan ve hatalı bölge ayrılmıştır. Son olarak, Belirginlik Atama (Saliency Assignment) modeli ile hatalı bölgeler gürbüz bir şekilde tespit edilmiştir.

Derin öğrenme yöntemlerinin geleneksel yöntemlere göre birçok güçlü yönleri vardır [34]. Fakat az sayıda örnek içeren problemlerde bu yöntemler zayıf kalabilmektedir. Birçok araştırmacı, bu problem ile başa çıkmak için veri çoğaltma ve Transfer Öğrenme (TÖ, Transfer Learning) yöntemleri kullanmışlardır. Yüzey hata tespit için TÖ modelini kullanan kodlayıcı-kod çözümü tabanlı yöntemlerde [2, 35, 36] önceden eğitilmiş ağ mimarisinin genellikle boyut düşürme katmanından önce gelen belirli katmanlarını kullanmışlardır. Bu çalışmalarda geliştirdikleri kodlayıcı-kod çözümü ağ mimarilerine "Ön işlemde geçirilmiş görüntü verme" [26, 37], "Ağ çıkışının güçlendirilmesi (Multi-Output)" [38, 39], "Dikkat Kapıları (Attention Gates)" [2, 10] ve "Sıkıştırma-Uyarılma (Squeeze and Excitation)" [40-42] gibi modeller ekleyerek hata tespit başarısını artırmışlardır.

Bu çalışmada, piksel seviyesinde yüzey hata tespiti için önceden eğitilmiş InceptionV3 tabanlı Zenginleştirilmiş Öznetelik Entegrasyon Ağ (Inc-ZÖEA) mimarisi geliştirilmiştir. Önerilen bu mimarinin temel amacı, önceden eğitilmiş ağ mimarisinden olabildiğince fazla öznetelik çıkartılması ve bu özneteliklerden anlamlı bilgilerin güçlendirilmesidir. Önerilen Inc-ZÖEA mimarisi, Çok Seviyeli Öznetelik Çıkartma (ÇSÖÇ), Öznetelik Piramit Ağ (ÖPA), Öznetelik Entegrasyon ve Anlamlandırma (ÖEA) modüllerinden oluşmaktadır. ÇSÖÇ modülü InceptionV3 ağ mimarisi ve KSU (Kanal bazlı Sıkma ve Uyarılma, Channel based Squeeze and Excitation) bloğundan oluşmaktadır [41]. Öncelikle, ÇSÖÇ modülünde InceptionV3 ağ mimarisinin her seviyesindeki öznetelikler çıkarılmıştır. Daha sonra bu öznetelikler aynı yükseklik ve genişliğe sahip özneteliklerle birleştirilmiştir. Birleştirme sırasında önemli verileri ortaya çıkarmak için KSU bloğu uygulanmıştır. Bu sayede InceptionV3 mimarisinden alınmış öznetelikler arasında hata tespiti için önemli detaylar ortaya çıkartılmıştır. Inc-ZÖEA mimarisinin ikinci bölümünde elde edilen öznetelik haritalarına ÖPA modülü uygulanmıştır. Bu modül sonucunda, farklı boyutlara sahip olan 4 öznetelik haritası elde edilmiştir. Bu öznetelik haritalarını için Öznetelik Entegrasyon ve Anlamlandırma (ÖEA) modülünde birleştirilmiştir. Birleştirilmiş öznetelik haritalarından kanal bazlı bilgilerin yanında mekânsal bilgileri de en iyi şekilde çıkartılması ve güçlendirilmesi için KSU yerine Mekânsal ve Kanal bazlı Sıkma ve Uyarılma (MKSU, Spatial and Channel based Squeeze and Excitation) [41] bloğu uygulanmıştır. MKSU bloğunun sonunda hata tespit sonucu için nihai öznetelik haritası elde edilmiştir. Son olarak, 1x1 evrişim katmanı ve sigmoid işlemi kullanılarak hata tespit sonucu elde edilmiştir. Deneysel çalışmalarda, MT, MVTEC-Doku ve DAGM veri setleri kullanılmıştır. Sonuç olarak, önerilen Inc-ZÖEA mimarisi var olan çalışmalara ve son teknoloji modellerine göre daha yüksek performans sağlamıştır.

Bu çalışma beş bölüm halinde detaylandırılmaktadır. Önerilen model Bölüm 2'de bahsedilmiştir; Bölüm 3'te yapılan deneysel çalışmalar, karşılaştırmaları ve doğruluk sonuçları verilmiştir. Bölüm 4'te tartışmalar ve Bölüm 5'te sonuç kısmı yer almaktadır.

## 2. Önerilen Yöntem (Proposed Method)

Yüzey hata tespiti için önerilen Inc-ZÖEA mimarisi Şekil 1'de verilmiştir. Önerilen model, Çok Seviyeli Öznetelik Çıkartma (ÇSÖÇ), ÖPA ve Öznetelik Entegrasyon ve Anlamlandırma (ÖEA) olmak üzere 3 modülden oluşmaktadır. Önerilen Inc-ZÖEA mimarisinin akışı aşağıda verilmiştir:

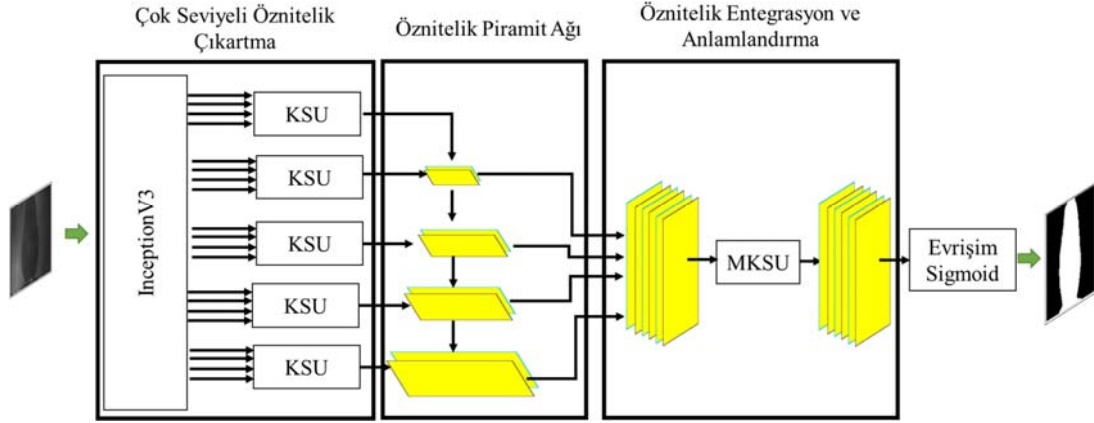
- ÇSÖÇ modülü, InceptionV3 mimarisinin katmanlarından çok seviyeli öznetelik haritaları çıkartılmasına dayalıdır. Mevcut çalışmada, bu mimarinin her seviyesindeki öznetelik haritaları ( $I_{0-19}$ ) kullanılmıştır.
- ÇSÖÇ modülünden elde edilen aynı yükseklik ve genişliğe sahip öznetelik haritaları birleştirilmiştir. Daha sonra birleştirilen öznetelik haritalarına KSU bloğu uygulanmıştır. Böylece, hata tespiti için önemli olabilecek öznetelikler kanal bazında güçlendirilmiştir. Bu işlem sonucunda, 5 farklı öznetelik haritası ( $F_{1,2,3,4,5}$ ) elde edilmiştir.
- ÇSÖÇ modülünde elde edilen 5 farklı öznetelik haritası ( $F_{1,2,3,4,5}$ ) derinlik olarak yeniden boyutlandırılmak ve ilişkilendirilmek için ÖPA modülü kullanılmıştır. ÖPA modülünde öznetelik haritaları bir evrişim katmanından geçirilerek derinlik olarak yeniden boyutlandırılmıştır. Daha sonra mekânsal bilgilere sahip olan öznetelik haritalarına ekleme stratejisi uygulanarak anlamsal bilgiler eklenmiştir. Bu işlem sonucunda 4 farklı öznetelik haritası ( $H_{l=1,2,3,4}$ ) elde edilmiştir.
- ÖEA modülünde, nihai öznetelik haritası elde etmek için derinlik olarak aynı boyutta olan  $H_{l=1,2,3,4}$  öznetelik haritaları Yukarı Örneklem (YÖ, Upsampling) katmanı ile aynı yüksekliğe ve genişliğe getirilmiş ve ardından birleştirilmiştir. Daha sonra, bu öznetelik haritasında en yüksek hata tespit başarısını yakalamak için MKSU bloğu uygulanmıştır. MKSU bloğu, mekânsal ve kanal olarak giriş öznetelik haritalarında bir sıkıştırma ve uyarılma işlemini gerçekleştirir. Bu sayede, KSU bloğundan farklı olarak hata tespiti için önemli olabilecek öznetelikler hem kanal hem de mekânsal olarak güçlendirildi. Bu işlem sonucunda güçlü bilgilere sahip  $M_{96 \times 96 \times 512}$  öznetelik haritası elde edilir.
- ZÖEA ağ mimarisinin son katmanında elde edilen  $M$  öznetelik haritasının ardından bir evrişim katmanı ve bir sigmoid aktivasyon katmanı uygulanarak hata tespit tahmin haritası elde edilmiştir.

Önerilen Inc-ZÖEA mimarisinin içerdiği modüllerin teorik yapısı alt başlıklar halinde detaylandırılmıştır.

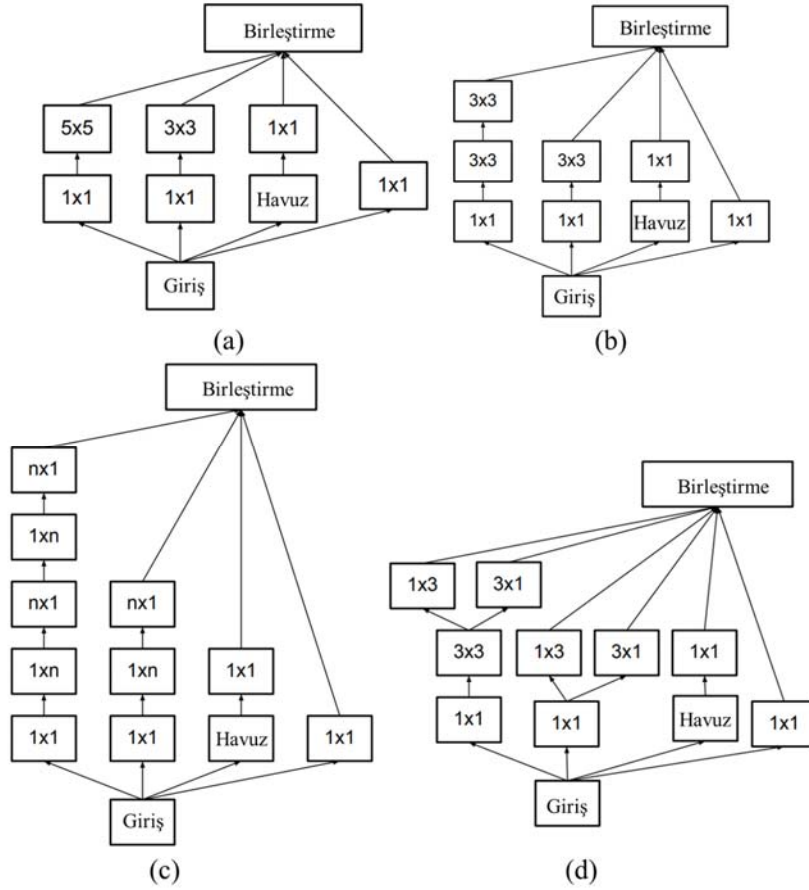
### 2.1. Çok Seviyeli Öznetelik Çıkartma Modülü (Multi-Level Feature Extraction Module)

Önerilen ağ mimarisinin ÇSÖÇ modülünde, omurga ağı olarak InceptionV3 [43] ağ mimarisi kullanarak detaylı bir öznetelik haritası elde edilmesi amaçlanmıştır. InceptionV3 ağ mimarisi, hiyerarşik olarak arka arkaya gelen evrişim katman yapısı kullanmak yerine Inception Bloklarına (IB) dayalıdır. AlexNet veya VGG16 gibi ağlar ile kıyaslandığında kullandıkları Inception blokları hem parametre sayısını düşürmüş hem de işlem maliyetini önemli derecede azaltmıştır.

InceptionV3 ağ modeli 3 farklı IB türünden oluşmaktadır. Bu bloklar Şekil 2'de verilmiştir. Şekil 2.b'de verilen IB Model 1'de (IB M1), ilk önerilen Inception bloklarında (Şekil 2.a) kullanılan  $5 \times 5$  evrişim katmanı yerine arka arkaya gelen  $3 \times 3$  çekirdek boyutuna sahip iki



Şekil 1. Önerilen Inc-ZÖEA mimarisi (Proposed Inc-ZOEA architecture)



Şekil 2. Inception blok yapıları, a) Orijinal IB, b) İB M1, c) İB M2, d) İB M3 [43]  
(Inception block structures, a) Original IB, b) IB M1, c) IB M2, d) IB M3)

evrişim katmanı kullanılmıştır. Şekil 2.c'deki IB M2 'de  $n \times n$  çekirdek boyutunda bir evrişim için arka arkaya gelen  $n \times 1$  ve  $1 \times n$  çekirdek boyutundaki evrişim katmanları uygulanmıştır. Son olarak Şekil 2.d'deki IB M3'te  $n \times 1$  ve  $1 \times n$  çekirdek boyutuna sahip evrişim çıktılarını arka arkaya eklemek yerine çıktılar birleştirilmiştir. InceptionV3 ağ mimarisinin içerdiği katmanların detayları Tablo 1'de verilmiştir.

Tablo 1'de görüleceği üzere InceptionV3 ağ mimarisinde bulunan ( $I_{0-19}$ ) öznitelik haritaları  $96 \times 96$ ,  $48 \times 48$ ,  $24 \times 24$ ,  $12 \times 12$  ve

$6 \times 6$  olmak üzere 5 farklı yükseklik ve genişlik boyutlarındadır. Önerilen Inc-ZÖEA mimarisinde bulunan ÇSÖÇ modülünde omurga ağının her bir seviyesindeki ( $I_{0-19}$ ) öznitelik haritaları kullanılmıştır. ÇSÖÇ modülünde, Tablo 2'de verildiği gibi bu öznitelik haritalarında yükseklik ve genişlik değerleri aynı olanlar birleştirilerek 5 farklı öznitelik haritası elde edilmiştir.

Tablo 2'de gösterildiği gibi birleştirilen öznitelik haritalarında hata tespit başarısını artıracak özniteliklerin ortaya çıkartılması için KSU [41] bloğu uygulanmıştır. KSU orijinal adıyla "Spatial Squeeze and



Channel Excitation" [41] blok detayları Şekil 3'te verilmiştir. Şekil 3'ten anlaşılacağı üzere, giriş öznetelik haritasından ( $G^{X \times Y \times S}$ ) sonra, sırasıyla Global Ortalama Havuzlama (GOH, Global Average Pooling) katmanı, TB (Tam Bağlı) katmanı, ReLU katmanı, TB katmanı ve sigmoid fonksiyonu uygulanmıştır. Bu sayede, öznetelik haritasının her bir kanalı için bir ağırlık katsayısı elde edilmiştir. Son olarak bu ağırlık değerleri giriş öznetelik haritası ile eleman bazlı çarpma işlemi uygulanarak  $F$  öznetelik haritası elde edilmiştir. ÇSÖÇ modülünde 5 farklı öznetelik haritası için aynı işlemler tekrarlanarak  $F_{1,2,3,4,5}$  öznetelik haritaları elde edilmiştir.

## 2.2. Öznetelik Piramit Ağı (Feature Pyramid Network)

Önerilen Inc-ZÖEA mimarisinde ÇSÖÇ modülünden sonra 5 farklı güçlü öznetelik haritaları elde edilmiştir. Bu öznetelik haritalarının arasında hata tespiti için önemli kenar, renk ve doku gibi mekânsal bilgileri taşıyan düşük seviyeli öznetelik haritaları ( $F_{1,2,\dots}$ ) ve önemli anlamsal bilgiler içeren yüksek seviyeli öznetelik haritaları ( $F_{\dots,4,5}$ )

vardır. Bu çalışma, ÖPA [24] modülü kullanılarak yüksek seviyeli özneteliklere düşük seviyeli öznetelikler eklenmiştir. ÖPA modülünde,  $F_l$  ve  $F_{l+1}$  özellik haritalarına ( $NEBR_{\text{çekirdek boyutu}=1 \times 1}^{\text{filtre sayısı}=256}(\cdot)$ ) işlemi uygulanmıştır. Bu işlem sırasıyla, bir noktasal evrişim katmanı, batch normalizasyon katmanı ve ReLU aktivasyon katmanlarını içermektedir. Daha sonra,  $NEBR_{1 \times 1}^{256}(F_{l+1})$  öznetelik haritasına yukarı örnekleme ( $Y\hat{O}(\cdot)$ ), UPSeampling) katmanı uygulanarak yükseklik ve genişlik olarak  $NEBR_{1 \times 1}^{256}(F_l)$  ile aynı boyuta getirilmiştir. Son olarak bu öznetelik haritalarına eleman bazlı toplama işlemi uygulanmıştır. Bu işlemler şekil 4'te gösterilmiştir.


Şekil 4'te verilen  $H_l$ ,  $l$ 'nci seviyedeki ÖPA çıktısını ve NEBR sırası ile noktasal evrişim, batch normalizasyon ve ReLU katmanlarını göstermiştir.  $fs$  ve  $\hat{c}b$  ise sırası ile filtre sayısını ve çekirdek boyutunu temsil etmiştir. ÇSÖÇ modelinde  $l$  değeri sırasıyla 4, 3, 2 ve 1 olarak ele alınarak  $F_l$  öznetelik haritalarından 4 farklı  $H_l$  öznetelik haritası elde edilmiştir.

**Tablo 1.** InceptionV3 katman detayları (EBR: Evrişim, Batch normalizasyon, ReLU aktivasyon katmanını temsil eder) (ETR: Represents Convolution, Batch normalization, ReLU activation layer)


Katman	Katman işlemi	Filtre sayısı	Adım genişliği	Çekirdek boyutu	Çıkış öznetelik boyutu
$I_0$	EBR	32	2	3x3	$96 \times 96 \times 32$
$I_1$	EBR	32	1	3x3	$96 \times 96 \times 32$
$I_2$	EBR	64	1	3x3	$48 \times 48 \times 64$
$I_3$	Havuzlama	-	2	3x3	$48 \times 48 \times 64$
$I_4$	EBR	80	1	1x1	$48 \times 48 \times 80$
$I_5$	EBR	192	1	3x3	$48 \times 48 \times 192$
$I_6$	Havuzlama	-	2	3x3	$24 \times 24 \times 192$
$I_7$	Mixed0	IB M1			$24 \times 24 \times 256$
$I_8$	Mixed1	IB M1			$24 \times 24 \times 288$
$I_9$	Mixed2	IB M1			$24 \times 24 \times 192$
$I_{10}$	Mixed3	IB M1			$12 \times 12 \times 768$
$I_{11}$	Mixed4	IB M2			$12 \times 12 \times 768$
$I_{12}$	Mixed5	IB M2			$12 \times 12 \times 768$
$I_{13}$	Mixed6	IB M2			$12 \times 12 \times 768$
$I_{14}$	Mixed7	IB M2			$12 \times 12 \times 768$
$I_{15}$	Mixed8	IB M2			$6 \times 6 \times 1280$
$I_{16}$	Mixed9_0	IB M3			$6 \times 6 \times 768$
$I_{17}$	Mixed9_1	IB M3			$6 \times 6 \times 2048$
$I_{18}$	Mixed10_0	IB M3			$6 \times 6 \times 768$
$I_{19}$	Mixed10_1	IB M3			$6 \times 6 \times 2048$

**Tablo 2.** ÇSÖÇ modülün elde edilen 5 farklı öznetelik haritası ve çıkış boyutu (5 different feature maps and output size obtained from the ÇSÖÇ module)

Çıkış Öznetelik haritası	KSU blok girişi öznetelik haritaları	Çıkış öznetelik harita boyutu
$F_1$	KSU( $I_0, I_1$ )	$96 \times 96 \times 192$
$F_2$	KSU( $I_2, I_3, I_4, I_5$ )	$48 \times 48 \times 560$
$F_3$	KSU( $I_6, I_7, I_8, I_9$ )	$24 \times 24 \times 1408$
$F_4$	KSU( $I_{10}, I_{11}, I_{12}, I_{13}, I_{14}$ )	$12 \times 12 \times 7104$
$F_5$	KSU( $I_{15}, I_{16}, I_{17}, I_{18}, I_{19}$ )	$6 \times 6 \times 9792$



**Şekil 3.** Kanal bazlı sıkma ve uyarlama bloğu (Channel based squeeze and excitation block)



**Şekil 4.** ÖPA modülünde kullanılan öznetelik aktarma işlemi (Feature transfer process used in the OPA module)

### 2.3. Öznetelik Entegrasyon ve Anlamlandırma (Feature Integration and Signification)

Önerilen Inc-ZÖEA ağının ÖPA çıktısında 4 farklı  $H_{l=1,2,3,4}$  öznetelik haritası elde edilmiştir. Bu öznetelik haritaları her biri hata tespit işlemi için güçlü bilgiler içermektedir. Bu öznetelik haritalarını birleştirmek için önemli ayrıntıların ortaya çıkartılmasına dayalı geliştirilen ÖEA modülü kullanılmıştır. Önerilen ÖEA modülünde, öncelikle farklı boyutlara sahip olan  $H_{l=1,2,3,4}$  öznetelik haritaları için ( $EBR_{\substack{filtre\ sayisi=256 \\ çekirdek\ boyutu=3 \times 3}}(\cdot)$ ) işlemi uygulanmıştır. Bu işlem sırasıyla, evrişim, batch normalizasyon ve ReLU katmanlarından oluşmaktadır. Daha sonra, yükseklik ve genişlik olarak boyutları farklı olan  $H_{l=1,2,3,4}$  öznetelik haritaları atlama değeri sırası ile 2,4 ve 8 olan bir yukarı örnekleme katmanından geçirilerek tüm öznetelik haritaları  $\frac{W}{2} \times \frac{H}{2} \times 128$  boyutuna getirilmiştir. Son olarak Eş. 1'de gösterildiği gibi aynı boyuta getirilmiş  $PF_l$  öznetelik haritaları kanal boyutundan (axis =3) birleştirilmiştir.

$$K = \begin{bmatrix} EBR_{3 \times 3}^{fs=128}(PF_1) \\ YÖ^{ad=2}(EBR_{3 \times 3}^{fs=128}(PF_2)) \\ YÖ^{ad=4}(EBR_{3 \times 3}^{fs=128}(PF_3)) \\ YÖ^{ad=8}(EBR_{3 \times 3}^{fs=128}(PF_4)) \end{bmatrix} \quad (1)$$

Burada  $K$  ve  $YÖ^{ad}$  sırası ile birleştirilmiş öznetelik haritasını ve atlama değeri  $ad$  olan yukarı örnekleme katmanını göstermiştir.  $EBR_{3 \times 3}^{fs=128}(\cdot)$  fonksiyonu ise girdiye sırası ile  $3 \times 3$  çekirdek boyutuna ve  $fs=128$  filtre sayısına sahip evrişim, batch normalizasyon ve ReLU katmanlarının uygulamasını gösterir.

Birleştirme işlemi sonunda  $K$  öznetelik haritası boyutu  $\frac{W}{2} \times \frac{H}{2} \times 512$  şeklindedir. Bu öznetelik haritasında InceptionV3 ağ mimarisinden gelen mekânsal ve anlamsal bilgileri açısından zengin bir öznetelik

haritasıdır. Bu öznetelik haritasında hata tespiti için önemli bilgileri vurgulamak ve güçlendirmek için MKSU [41] uygulanmıştır. MKSU (Şekil 5) bloğun kullanılmasındaki temel amaç Inc-ZÖEA ağ mimari son katmanlarına doğru ilerlerken hem mekânsal hem de kanal bazlı önemli detayları içeren öznetelikleri kaybetmeden güçlendirmektir.

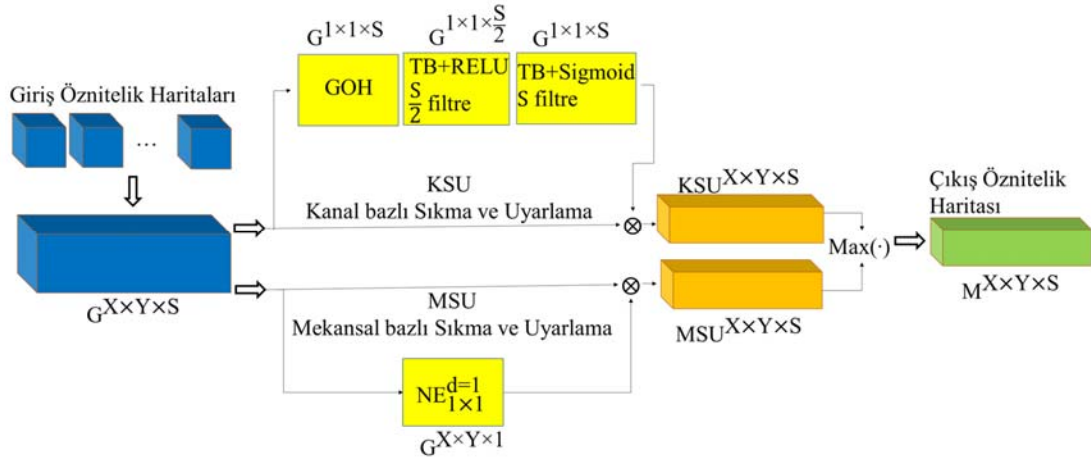
Şekil 5'de gösterildiği gibi, MKSU da birleştirilen öznetelik haritalarına ( $G^{X \times Y \times S}$ ) KSU ile paralel olarak Mekânsal bazlı Sıkma ve Uyarlama (MSU, Spatial based Squeeze and Excitation) yöntemi uygulanır. KSU'da global average pooling katmanı uygulandığı için öznetelik haritasının her bir kanalındaki mekânsal bilgiler (kenar ve renk vb.) tek bir noktada toplanır ( $G^{1 \times 1 \times S}$ ). Bu da önemli kanalların seçimi sırasında hata tespiti için küçük fakat önemli mekânsal bilgilerin kaybolmasına sebep olabilmektedir [41]. Bunun tersine, MSU'da noktasal evrişim kullanarak sıkıştırma işlemini yaptığı için mekânsal detayları kaybetmez. Fakat MSU'da bir pikselin kanal boyunca bilgileri özetlediği ( $G^{X \times Y \times 1}$ ) için kanal boyunca önemli bilgiler kaybolmaktadır. MKSU bloğu Şekil 5'te gösterildiği gibi MSU ve KSU yöntemlerini paralel olarak uyguladığı için hem mekânsal hem de kanal boyunca önemli detayları kaybetmesini önlemektedir. MKSU sonunda elde edilen MSU ve KSU çıktılarının noktasal  $Max(\cdot)$  operatörü uygulanarak çıktı öznetelik haritası elde edilir [41]. Guha vd. yaptıkları çalışmada [41] belirtildiği gibi  $Max(\cdot)$  operatörünün uygulanması MSU ve KSU arasında rekabeti artırır. Bu sayede en yüksek hata tespit sonucu verecek şekilde önemli özneteliklerin güçlendirilmesi sağlanmıştır.

### 2.4. Inc-ZÖEA Eğitimi (Training of Inc-ZÖEA)

Inc-ZÖEA mimarisinin son katmanında hata tespit sonucunu elde etmek için MKSU'nun çıktı öznetelik haritası, sırası ile 128 filtreye sahip evrişim işlemi, batch normalizasyon ve ReLU katmanından geçirilmiştir. Daha sonra öznetelik haritası görüntü ile aynı boyuta getirilmesi için atlama değeri 2 olan yukarı örnekleme katmanından geçirilmiştir. Bu sayede  $W \times H \times 128$  boyutundaki nihai öznetelik haritası elde edilmiştir. Son olarak hata tespit sonucunu elde etmek için çekirdek boyutu  $3 \times 3$  olan ve filtre sayısı 1 olan bir evrişim katmanı ve sigmoid aktivasyon fonksiyonu uygulanmıştır. Yukarıdaki işlemler Eş. 2'de ifade edilmiştir.

$$P = \sigma(E_{3 \times 3}^{fs=1}(YÖ^{s=2}(EBR_{3 \times 3}^{fs=128}(M)))) \quad (2)$$

Burada  $P_{m \times n}$  hata tespit tahmini;  $M$  MKSU'nun çıktı öznetelik haritası;  $\sigma$  sigmoid aktivasyon fonksiyonu;  $E_{3 \times 3}^{fs=1}$ ,  $3 \times 3$  çekirdek boyutuna sahip ve filtre sayısı  $fs = 1$  olan evrişim işlemi;  $YÖ$  yukarı



**Şekil 5.** Mekânsal ve kanal bazlı sıkma ve uyarlama bloğu (Spatial and channel based squeeze and excitation block)

örnekleme katmanı;  $EBR_{3 \times 3}^{fs=128}$ ,  $3 \times 3$  çekirdek boyutuna sahip ve  $fs=128$  olan evrişim, batch normalizasyon ve ReLU katmanını gösterir.

Inc-ZÖEA ağ mimarisinin eğitiminde The Binary Cross-Entropy loss function kullanılmıştır. The Binary Cross-Entropy kayıp fonksiyonu Eş. 3'te verilmiştir.

$$L = - \sum_{i,j}^M y_{i \times j} \log(P_{i \times j}) + (1 - y_{i \times j}) \log(1 - P_{i \times j}) \quad (3)$$

Burada  $L$ , ortalama hata değerini;  $y_{i \times j}$  ve  $P_{i \times j}$ , sırası ile sonuç haritasındaki  $i \times j$  konumundaki pikselin gerçek değeri ve tahmin değerini göstermektedir.

Inc-ZÖEA ağ mimarisinde omurga ağının başlangıç parametreleri için InceptionV3 ağın ImageNet veri seti ile önceden eğitilmiş parametreleri kullanılmıştır. Inc-ZÖEA mimarisinin diğer katmanlarına rastgele değerler atanmıştır. Eğitim boyunca transfer öğrenme modeli uygulanarak Inc-ZÖEA mimarisinin tüm parametreleri güncellenmiştir.

### 3. Deneysel Çalışmalar (Experimental Studies)

Önerilen Inc-ZÖEA yönteminin 3 farklı veri seti üzerindeki performansı değerlendirilmiştir. Inc-ZÖEA mimarisinin kodu; <https://github.com/mturkoglu23/Inc-ZOEA>'dan paylaşılmıştır. Deneysel çalışmalarda, literatürde segmentasyon ve piksel seviyesinde hata tespiti için son teknolojik yöntemler olan Unet [25], PSPNet [44], LinkNet [23] ve Öznitelik Piramit Ağ (FPNet, Feature Pyramid Networks) [24] mimarileriyle aynı deneysel çalışmalar uygulanmış ve sonuçlar karşılaştırılmıştır. Bu bölüm devamında öncelikle veri setleri ve uygulama detayları sunulmuştur. Daha sonra her veri seti için sayısal ve görsel sonuçlar ile yöntemlerin analizlerine yer verilmiştir.

#### 3.1. Veri Setleri (Datasets)

Önerilen Inc-ZÖEA modelin performansını etkili bir şekilde değerlendirmek için MT, DAGM ve MVTEC-Doku veri setleri kullanılmıştır. Bu veri setleri, literatürde paylaşılan ve yaygın kullanılan veri setleridir. Magnetic Tile (MT, manyetik karo) [26] veri seti motorlarda bulunan mıknatısların yüzey görüntülerini içeren bir veri setidir. Bu veri seti ezilme, yıpranma, çatlak, hava deliği ve kırılma gibi yüzey hataları içermektedir. Veri seti farklı çözünürlükte alınmış görüntüler içerdiğinden zorlu bir veri setidir. Deneysel çalışmalar için MT veri setinde bulunan tüm hatalı görüntüler kullanılmıştır. Bu veri seti için %75 eğitim ve geri kalanı test olarak

ayrılmıştır. MVTEC Anomaly Detection [45] veri seti 15 farklı yüzeyden alınmış (10 nesne ve 5 doku sınıfı) gerçek görüntülerden oluşmaktadır. Her bir sınıf, yaklaşık 250 görüntü içermektedir. Yüzey hata tespiti için MVTEC veri setindeki halı, tel levha, deri, fayans, odun olmak üzere 5 yüzey doku (MVTEC-Doku) sınıfı alınmıştır. MVTEC-Doku veri seti deneysel çalışmalar için %75 eğitim ve %25 test olacak şekilde ayrılmıştır. DAGM 2007 [46] DAGM veri seti 10 farklı yüzey görüntüsünden oluşan yapay bir veri setidir. Bu veri seti gerçek doku yüzey görüntülerinden esinlenerek oluşturulmuş olup gerçeğe oldukça yakındır. DAGM veri setinde her bir yüzey sınıfı için eğitim ve test veri setleri ayrılmıştır. Deneysel çalışmalarda [2] nolu çalışma ile benzer olacak şekilde DAGM veri setinden 6 sınıf kullanılmıştır. DAGM veri seti piksel-seviyesinde hata tespiti genel bir elipsle etiketlendiği için piksel seviyesinde bir etiketleme yoktur. Buna rağmen diğer yöntemler ile adil kıyaslama için [2] nolu çalışmadaki gibi etiketler değiştirilmeden orijinal hali ile kullanılmıştır. Bunun yanında, DAGM veri setinde Eğitim ve Test olarak ayrıldığı için burada orijinal hali ile kullanılmıştır. Deneysel çalışmalarda kullanılan MT, DAGM ve MVTEC-Doku veri setlerin örnek sayıları Tablo 3'de verilmiştir.

#### 3.2. Uygulama Detayları (Implementation Details)

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 adım (epoch) sayısı 100 ve yığın boyutu (batch size) 16 olarak ayarlanmıştır. Uygulamalarda etkili bir öğrenme oranı kullanmak için keras kütüphanesinde bulunan ReduceLROnPlateau modeli kullanılmıştır. Bu model eğitim boyunca kayıp (loss) değerini kontrol eder. Belirli adım sayısı kadar (*patience*) kayıp değerinde bir düşme olmadığında öğrenme oranını bir faktör (*factor*) değeri ile çarparak küçültür. Bu sayede yeni öğrenme oranı ( $lr_{new} = lr_{old} * factor$ ) elde edilir. Uygulamalarda *factor* = 0,1 ve *patience* = 8 olarak ayarlanmıştır. Başlangıç öğrenme oranı 0,001 ve olabilecek minimum öğrenme oranı ise 0,00001 olarak ayarlanmıştır. Eğitim için Adam optimizasyonu yöntemi kullanılmıştır. Deneysel çalışmalarda kıyaslamalar F1-Skor ve mIoU (kesişimlerinin tüm alana oranının ortalaması, Mean intersection over union) metrikleri kullanılmıştır.

#### 3.3. Deneysel Sonuçlar (Experimental Results)

MT, MVTEC-Doku ve DAGM veri seti kullanılarak yapılan uygulama sonuçları Tablo 4'te verilmiştir. Verilen sonuçlara göre 3 veri setinde, önerilen Inc-ZÖEA mimarisi diğer yöntemlere göre daha iyi sonuçlar vermiştir. Tablo 4'teki MT veri seti sonuçlarında, Inc-ZÖEA mimarisi %77,44 mIoU ve %87,28 F1-skor ile en yüksek başarıyı sağlarken ikinci en yüksek başarıyı %68,27 mIoU başarı ile LinkNet mimarisi

**Tablo 3.** Deneysel çalışmalarda kullanılan veri setleri ve örnek sayıları (Datasets and sample numbers used in experimental studies)

Veri Seti	Eğitim Örnek Sayısı			Test Örnek Sayısı		
	Hatalı	Hatasız	Toplam	Hatalı	Hatasız	Toplam
MT	289	289	578	97	97	194
DAGM	598	598	1196	602	602	1204
MVTEC-Doku	285	1047	1332	97	352	449

**Tablo 4.** Performans sonuçları (Performance results)

	MT		MVTEC-Doku		DAGM	
	mIoU	F1-skor	mIoU	F1-skor	mIoU	F1-skor
LinkNet	68,27	81,10	71,84	83,61	76,48	86,67
PSPNet	59,37	74,50	68,24	81,12	76,19	86,48
Unet	60,55	75,43	73,47	84,70	76,86	86,92
FPNet	65,87	79,42	65,70	79,30	75,43	85,99
Önerilen Inc-ZÖEA	77,44	87,28	81,20	89,62	79,46	88,55



elde etmiştir. Öznitelik piramit ağ modelini kullanan Inc-ZÖEA ve FPNet ağlarının sonuçları kıyaslandığında %11,57 mIoU ve 7,86 F1-skor farkı, Inc-ZÖEA mimarisinde bulunan ÇSÖÇ, KSU, MKSU ve ÖEA bloklarının katkıları açık şekilde göstermektedir. Bu modüller, tespit edilmesi zor olan yüzey hatalarını içeren görüntülerde, öznitelikler arasında ince ayrıntıları taşıyan önemli bilgileri güçlendirmiştir. Atlama bağlantıları kullanan LinkNet ve Unet yapıları kıyaslandığında MT veri setinde LinkNet %7,72 mIoU skor farkı ile daha yüksek başarı sağlamıştır. PSPNet mimarisini Unet mimarisine benzer bir yapıdadır. Deneysel çalışmalarda PSPNet en düşük sonuçları vermiştir. Bunun temel sebebi PSPNet mimarisini, Unet ve FPNet ağlarına göre Mekânsal ayrıntıları başarılı bir şekilde koruyamamalarıdır. Tablo 4'te verilen MVTEC veri setinin sonuçlarında MT veri setinde olduğu gibi Inc-ZÖEA mimarisini %81.2 mIoU ve %89,62 F1-skoru ile en yüksek başarıyı sağlamıştır. İkinci en yüksek Unet ağı sağlamıştır. Bunların yanı sıra LinkNet, PSPNet ve FPNet ağları sırasıyla %71,84 ve %68 mIoU skoru ile Inc-ZÖEA modelinden ortalama %10 skor daha düşük sonuçlar vermiştir. MVTEC veri setinde en düşük sonuçları FPNet modeli vermiştir. Tablo 4'te verilen DAGM veri setinin sonuçlarında LinkNet, PSPNet, Unet ve FPNet ağları %75,43-%76,86 arasında yakın mIoU sonuçları alırken Inc-ZÖEA modeli yaklaşık %3'lik bir fark ile daha yüksek mIoU sonuçları almıştır.

Şekil 6'da MT veri setinden alınan örnek görüntüler ve tahmin sonuçları verilmiştir. Örnek 1 ve 2'de küçük boyutta ve ince çizik şeklinde hatalar bulunmaktadır. Bu örneklerde Inc-ZÖEA modeli en yüksek başarı ile yüzey hatalarını tespit edebilmiştir. Örnek 1 ve 2'de Unet modeli kısmen başarılı olmuşken diğer yöntemler ise yüzey hatalarını tespit edememiştir. Örnek 3, 4, 5 ve 6'da arka plan ile aşırı uyum gösteren hata tipleri vardır. Bu hata tipine karşı Inc-ZÖEA mimarisini yüksek doğruluk ile hata tespiti yaparken Unet mimarisini


daha düşük sonuçlar vermiştir. LinkNet, PSPNet ve FPNet yöntemleri ise bu örneklerdeki hataları tespitinde zayıf kalmışlardır. Şekil 7'da MVTEC veri setinden alınan örnek görüntüler ve tahmin sonuçları verilmiştir. Verilen örnekler incelendiğinde, MVTEC veri setinin içerdiği hatalar genellikle küçük boyutta ve ince çizik şeklindedir. Bunun yanı sıra, Örnek 2, 3 ve 5 incelendiğinde dinamik (kompleks) arka plana sahip görüntülerdir. Bu görüntülerde en yüksek başarıyı Inc-ZÖEA mimarisini vermiştir. Diğer yöntemler ise kısmen hata konumunu bularak düşük sonuçlar vermiştir. Örnek 3'te verilen görüntüde yüzey hatası arka plan ile aynı doku özelliğine sahiptir. Bundan dolayı yöntemler genel olarak düşük performans sağlamıştır. Bunun yanı sıra yöntemlerin başarıları kıyaslandığında önerilen Inc-ZÖEA modeli en yüksek sonuçları vermiştir. Örnek 5'te verilen görüntüde neredeyse görülmeyecek boyutta bir yüzey hatası vardır. PSPNet, LinkNet ve FPNet bu yüzey hatasını tespit edememiştir. Bunun yanı sıra Unet ağı %12,56 IoU ile hatayı kısmen tespit etmişken önerilen Inc-ZÖEA model ise %45,45 ile daha yüksek bir doğrulukla hatayı tespit edebilmiştir. Şekil 8'da DAGM veri setinden alınan örnek görüntüler ve tahmin sonuçları verilmiştir. DAGM veri seti yapay görüntüler olmasına rağmen yaygın kullanılan bir doku veri setidir. Bu veri seti elips şeklinde hatalı bölgeler gösterilmesine rağmen uygulamalarda kullanılan segmentasyon yöntemleri genel bir başarımla sağlamıştır. Şekil 8'da verilen örnekler arasında gerçek etiket değerlerini en iyi şekilde modelleyerek en yüksek başarımla Inc-ZÖEA mimarisini sağlamıştır. Diğer yöntemler ise verilen hatalı bölgeyi Inc-ZÖEA modeline göre daha düşük bir başarımla tespit etmiştir.

#### 4. Tartışma (Discussion)

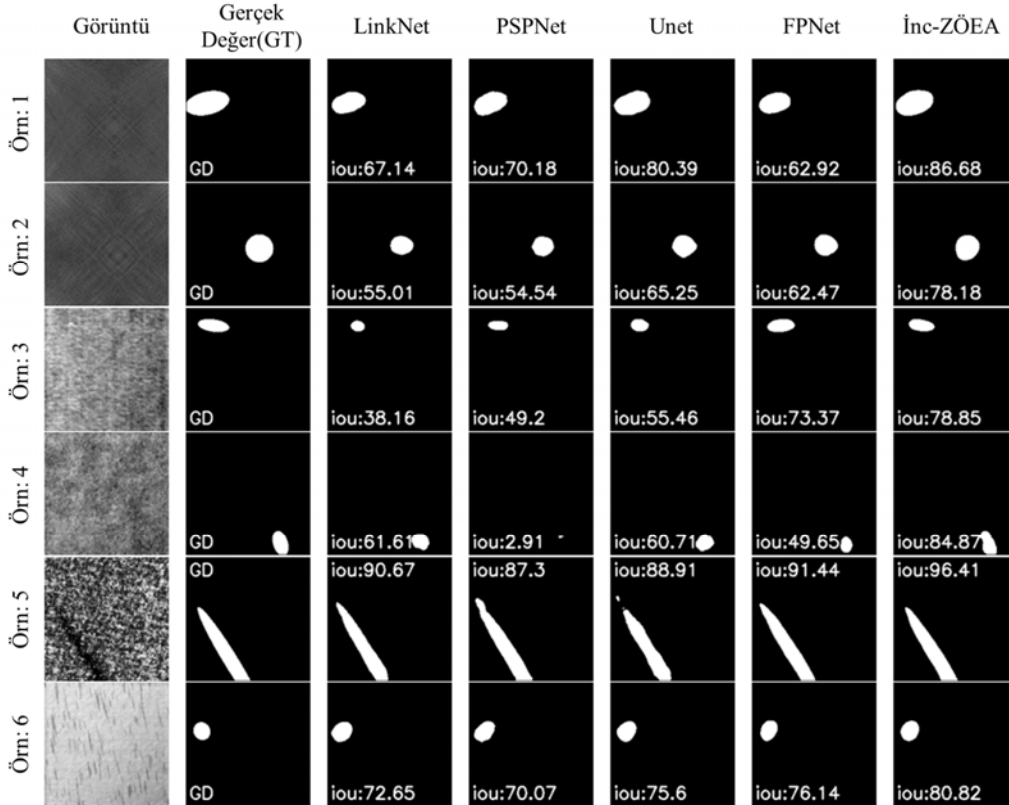
Hata tespiti için var olan çalışmalar ile önerilen Inc-ZÖEA mimarisini performans sonuçları Tablo 5'te verilmiştir. DAGM, MVTEC-Doku ve MT veri setlerinde Inc-ZÖEA mimarisini diğer yöntemlere göre daha

	Görüntü	Gerçek Değer(GT)	LinkNet	PSPNet	Unet	FPNet	İnc-ZÖEA
Örn: 1		GD	iou:1.78	iou:0.0	iou:50.38	iou:0.0	iou:69.86
Örn: 2		GD	iou:16.27	iou:0.0	iou:52.47	iou:0.0	iou:61.16
Örn: 3		GD	iou:25.74	iou:56.29	iou:77.05	iou:65.11	iou:74.05
Örn: 4		GD	iou:67.74	iou:0.0	iou:73.68	iou:0.0	iou:78.78
Örn: 5		GD	iou:54.33	iou:26.53	iou:33.75	iou:32.23	iou:89.39
Örn: 6		GD	iou:74.09	iou:37.84	iou:71.78	iou:84.57	iou:92.31

Şekil 6. MT veri setine dayalı görsel sonuçlar (Visual results based on the MT dataset)



Şekil 7. MVTEc-Doku veri setine dayalı görsel sonuçlar (Visual results based on the MVTEc-texture dataset)



Şekil 8. DAGM veri setine dayalı görsel sonuçlar (Visual results based on the DAGM dataset)

yüksek başarımlı sağlamıştır. VGG16 eğitilmiş parametreleri, ÖPA ve dikkat kapılarını birleştirilerek geliştirilen PGA-Net [2] modeli, MT ve DAGM veri setlerinde sırası ile %71,31 ve %74,78 mIoU performansı elde etmiştir. Buna karşı, Inc-ZÖEA benimsediği güçlendirilmiş öznetelik modeli sayesinde (MT 'de %77,44 mIoU ve

DAGM'da %79,46 mIoU) daha yüksek performans elde etmiştir. PGA-Net ile benzer bir yöntem olan DDF [10] ağında Resnet50 ağ mimarisi kullanılmıştır. Önerilen Inc-ZÖEA mimarisi MT veri setinde bu modelden %3,74 daha yüksek başarı sağlamıştır. KRPCA-NTV [33] ve DPAE [30] mimarileri denetimsiz öğrenmeye dayalı

**Tablo 5.** Performans karşılaştırılması (Performance comparison)

Ağ Mimarisi	Yöntem	Veri Seti	mIoU	F1-skor
<i>PGA-Net [2]</i>	VGG16, ÖPA ve Dikkat Kapıları	MT	71,31	
<i>DPAE [30]</i>	Oto-Kodlayıcı			78,00
<i>DFE [10]</i>	Resnet50 ve Dikkat Kapıları		73,70	82,20
<i>Önerilen Inc-ZÖEA</i>	InceptionV3, ÇSÖÇ, ÖPA ve ÖEA	DAGM	77,44	87,28
<i>PGA-Net [2]</i>	VGG16, ÖPA ve Dikkat Kapıları		74,78	-
<i>Önerilen Inc-ZÖEA</i>	InceptionV3, ÇSÖÇ, ÖPA ve ÖEA		79,46	88,55
<i>KRPCA-NTV [33]</i>	Oto-Kodlayıcı	MVTec-Doku	54,29	-
<i>Önerilen Inc-ZÖEA</i>	InceptionV3, ÇSÖÇ, ÖPA ve ÖEA		81,20	89,62

gelişmiş güçlü modellerdir. Bu modeller genelleme yeteneği Inc-ZÖEA mimarisine göre daha güçlüdür. Fakat, denetimsiz öğrenme küçük ve arka plan ile ayırması zor olan görüntülerde zayıf kalabilmektedir. Bundan dolayı önerilen Inc-ZÖEA mimarisi KRPCA-NTV [33] ve DPAE [30] mimarilerinden sırası ile %26,91 ve %9,28 performans farkı ile daha yüksek başarı sağlamıştır.

Önerilen Inc-ZÖEA modelinin avantajları ve kısıtlamaları/dezavantajları aşağıda maddeler halinde özetlenmiştir.

Avantajlar:

- Önerilen mimarinin yapısında kullanılan ÇSÖÇ modeli, InceptionV3 ağ mimarisinden güçlü özneliklerin çıkartılmasını sağlamıştır.
- ÖPA modülü InceptionV3 ağ mimarilerinden alınan farklı seviyedeki öznelik haritalarını ekleme stratejisi ile kenar, renk ve doku gibi mekânsal (spatial) bilgiler içeren düşük seviyeli öznelikler, anlamsal (semantic) bilgiler içeren yüksek seviyeli özneliklere aktarılmıştır.
- KSU bloğunda öznelik haritalarından hata tespiti için önemli ayrıntıları en iyi şekilde güçlendirilmiştir. Özellikle kullanılan MKSU bloğu ile nihai öznelik haritası için hem mekânsal (spatial) hem de kanal (channel) bazında ince ayrıntıları kaybetmeden öznelikler güçlendirilmiştir.
- MT, MVTec-Doku ve DAGM veri setlerinde, önerilen Inc-ZÖEA mimarisi diğer son teknoloji modellere göre en yüksek başarıyı sağlamıştır.
- Zayıflıkları:
- Önerilen Inc-ZÖEA mimarisinin genelleme yeteneği kısıtlıdır. Bundan dolayı eğitim veri setinde görmediği hata tiplerinde zayıf kalabilir.

## 5. Sonuçlar (Conclusions)

Bu çalışmada, piksel seviyesinde yüzey hata tespiti için InceptionV3 tabanlı Zenginleştirilmiş Öznelik Entegrasyon ve Anlamlandırma Ağ (Inc-ZÖEA) mimarisi geliştirilmiştir. Önerilen mimaride omurga ağı olarak InceptionV3 ağı kullanılmıştır. Bunun yanı sıra önerilen modelinin ÇSÖÇ, KSU, ÖPA, ÖEA ve MKSU bileşenleri, öznelik haritalarından önemli detayları ortaya çıkartmak için kullanılmıştır. Inc-ZÖEA'de bulunan ÇSÖÇ modülü InceptionV3 ağ mimarisinin her seviyesindeki öznelikleri almıştır. Alınan özneliklerden aynı yükseklik ve genişlikteki öznelik haritaları birleştirilmiştir. Birleştirilen öznelik haritaları arasında önemli detayları güçlendirmek için KSU bloğundan geçirilmiştir. Daha sonra ÖPA modülünde farklı genişlik ve yükseklikteki anlamsal öznelikler mekânsal özneliklere eklenerek öznelikler arasında bilgi akışı sağlanmıştır. ÖEA modülünde, ÖPA çıkışındaki 4 farklı seviyedeki öznelik haritaları birleştirilerek mekânsal ve anlamsal açıdan zengin bir öznelik haritası elde edilmiştir. Bu öznelik haritasında hata tespitinde en önemli bilgileri ortaya çıkarmak/güçlendirmek için MKSU bloğu uygulanmıştır. MKSU blok çıkışında nihai öznelik

haritası elde edilmiştir. Son olarak Inc-ZÖEA mimarisinin çıktısında sigmoid fonksiyonu ile piksel seviyesinde hata tespiti yapılmıştır. MVTec-Doku, DAGM ve MT veri setleri kullanılarak yapılan deneysel çalışmada Inc-ZÖEA yöntemi ile son teknoloji yöntemler arasında detaylı kıyaslama ve analizler yapılmıştır. Yapılan deneysel çalışmada MT, MVTec-Doku ve DAGM veri setlerinde sırası ile Inc-ZÖEA mimarisi %77,44 mIoU, %81,2 mIoU ve %79,46 mIoU ile en yüksek başarımları sağlamıştır. İleriki çalışmalarda piksel seviyesinde hata tespit performansın yükseltilmesi için öznelik entegrasyon ağ modülünde Transformer yapıları kullanılması planlanmaktadır. Bunun yanı sıra hata tespiti için gerçek zamanlı uygulamalar gerçekleştirilecektir.

## Teşekkür (Acknowledgement)

Bu çalışma İnönü Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir (Proje Numarası: FDK-2021-2725).

## Kaynaklar (References)

1. Hanbay K., Talu M.F., Özgüven Ö.F., Fabric defect detection systems and methods-A systematic literature review, *Optik*, 127 (24), 11960–11973, 2016.
2. Dong H., Song K., He Y., Xu J., Yan Y., Meng Q., PGA-Net: Pyramid Feature Fusion and Global Context Attention Network for Automated Surface Defect Detection, *IEEE Transactions on Industrial Informatics*, 16 (12), 7448–7458, 2020.
3. Karimi, M.H., ve Asemani D., Surface defect detection in tiling Industries using digital image processing methods: Analysis and evaluation. *ISA Transactions*, 53 (3), 834–844, 2014.
4. Aghdam S.R., Amid E., Imani M.F., A fast method of steel surface defect detection using decision trees applied to LBP based features, *Proceedings of the 2012 7th IEEE Conference on Industrial Electronics and Applications, ICIEA 2012, Chengdu-China, 1447–1452*, 18-20 July, 2012.
5. Tsanakas J.A., Chrysostomou D., Botsaris P.N., Gasteratos A., Fault diagnosis of photovoltaic modules through image processing and Canny edge detection on field thermographic, *Measurements*, 34 (6), 351–372, 2013.
6. Mak K.L., Peng P., Yiu K.F.C., Fabric defect detection using morphological filters, *Image and Vision Computing*, 27(10), 1585–1592, 2009.
7. Bai X., Fang Y., Lin W., Wang L., Ju B.F., Saliency-based defect detection in industrial images by using phase spectrum, *IEEE Transactions on Industrial Informatics*, 10 (4), 2135–2145, 2014.
8. Liu G., Zheng X., Fabric defect detection based on information entropy and frequency domain saliency, *The Visual Computer*, 37 (3), 515–528, 2020.
9. Dong X., Taylor C.J., Cootes T.F., A Random Forest-Based Automatic Inspection System for Aerospace Welds in X-Ray Images, *IEEE Transactions on Automation Science and Engineering*, 18 (4), 2128–2141, 2020.
10. Cao J., Yang G., Yang X., A Pixel-Level Segmentation Convolutional Neural Network Based on Deep Feature Fusion for Surface Defect Detection, *IEEE Transactions on Instrumentation and Measurement*, 70, 1-12, 2021.

11. Firat H., Hanbay D., Classification of Hyperspectral Images Using 3D CNN Based ResNet50, 29th Signal Processing and Communications Applications Conference (SIU), İstanbul-Türkiye, 1-4, 6-9 Haziran, 2021.
12. Yi L., Li G., Jiang M., An End-to-End Steel Strip Surface Defects Recognition System Based on Convolutional Neural Networks, steel research international, 88 (2), 2017.
13. Jain S., Seth G., Paruthi A., Soni U., Kumar G., Synthetic data augmentation for surface defect detection and classification using deep learning, Journal of Intelligent Manufacturing, 1-14, 2020.
14. Long J., Shelhamer E., Darrell T., Fully Convolutional Networks for Semantic Segmentation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 39 (4), 640-651, 2014.
15. Ren S., He K., Girshick R., Sun J., Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, IEEE Transactions on Pattern Analysis and Machine Intelligence, 39 (6), 1137-1149, 2017.
16. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C., SSD: Single Shot MultiBox Detector, European conference on computer vision, 9905, Springer, Cham, 21-37, 2016.
17. Redmon J., Divvala S., Girshick R., Farhadi A., You Only Look Once: Unified, Real-Time Object Detection, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Las Vegas-USA, 779-788, 27-30 June, 2016.
18. He Y., Song K., Meng Q., Yan Y., An End-to-End Steel Surface Defect Detection Approach via Fusing Multiple Hierarchical Features, IEEE Transactions on Instrumentation and Measurement, 69 (4), 1493-1504, 2020.
19. Yanan S., Hui Z., Li L., Hang Z., Rail Surface Defect Detection Method Based on YOLOv3 Deep Learning Networks, Proceedings 2018 Chinese Automation Congress, Chinese, CAC, 1563-1568, 2018.
20. Redmon J., ve Farhadi A., YOLOv3: An Incremental Improvement, arXiv:1804.02767, 2018.
21. Yuan H., Chen H., Liu S., Lin J., Luo X., A deep convolutional neural network for detection of rail surface defect, 2019 IEEE Vehicle Power and Propulsion Conference, Hanoi-Vietnam, 14-17 october, 2019.
22. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.C., MobileNetV2: Inverted Residuals and Linear Bottlenecks, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake-USA, 4510-4520, 18-23 June, 2018.
23. Chaurasia A., Culurciello E., LinkNet: Exploiting encoder representations for efficient semantic segmentation, 2017 IEEE Visual Communications and Image Processing, VCIP 2017, 2018-January, 1-4, 2018.
24. Lin T.Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S., Feature Pyramid Networks for Object Detection, arXiv:1612.03144, 2016.
25. Ronneberger O., Fischer P., Brox T., U-Net: Convolutional Networks for Biomedical Image Segmentation, International Conference on Medical image computing and computer-assisted intervention, Springer-Cham, 9351, 234-241, 18 November, 2015.
26. Huang Y., Qiu C., Yuan K., Surface defect saliency of magnetic tile, The Visual Computer, 36(1), 85-96, 2020.
27. Lu J., Liang B., Lei Q., Li X., Liu J., Liu J., Wang W., SCueU-Net: Efficient Damage Detection Method for Railway Rail, IEEE Access, 8, 125109-125120, 2020.
28. Dong X., Taylor C.J., Cootes T.F., Defect Detection and Classification by Training a Generic Convolutional Neural Network Encoder, IEEE Transactions on Signal Processing, 68, 6055-6069, 2020.
29. Rudolph M., Wandt B., Rosenhahn B., Same But DifferNet: Semi-Supervised Defect Detection with Normalizing Flows, arXiv:2008.12577, 2020.
30. Liu J., Song K., Feng M., Yan Y., Tu Z., Zhu L., Semi-supervised anomaly detection with dual prototypes autoencoder for industrial surface inspection, Optics and Lasers in Engineering, 136, 106324-106333, 2021.
31. Defard T., Setkov A., Loesch A., Audigier R., PaDiM: A Patch Distribution Modeling Framework for Anomaly Detection and Localization, Lecture Notes in Computer Science, 12664 LNCS, 475-489, 2021.
32. Tan D.S., Chen Y.C., Chen T.P.C., Chen W.C., TrustMAE: A Noise-Resilient Defect Classification Framework using Memory-Augmented Auto-Encoders with Trust Regions, arXiv:2012.14629, 2021.
33. Wang J., Xu G., Li C., Wang Z., Yan F., Surface Defects Detection Using Non-convex Total Variation Regularized RPCA with Kernelization, IEEE Transactions on Instrumentation and Measurement, 70, 1-13, 2021.
34. Firat H., Asker M.E., Hanbay D., Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN, Remote Sensing Applications: Society and Environment, 25, 100694-10712, 2022.
35. Cheng X., Yu J., RetinaNet with Difference Channel Attention and Adaptively Spatial Feature Fusion for Steel Surface Defect Detection, IEEE Transactions on Instrumentation and Measurement, 70, 1-11, 2021.
36. Firat H., Hanbay D., 4CF-Net: New 3D convolutional neural network for spectral spatial classification of hyperspectral remote sensing images, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (1), 439-454, 2021.
37. Uzen H., Turkoglu M., Hanbay D., Texture defect classification with multiple pooling and filter ensemble based on deep neural network, Expert Systems with Applications, 175, 114838-114849, 2021.
38. Fan Z., Li C., Chen Y., Wei J., Loprencipe G., Chen X., Di Mascio P., Automatic crack detection on road pavements using encoder-decoder architecture, Materials, 13 (13), 1-18, 2020.
39. Bousabarah K., Ruge M., Brand J.S., Hoevels M., Rueß D., Borggrefe J., Kocher M., Deep convolutional neural networks for automated segmentation of brain metastases trained on clinical data, Radiation Oncology, 15 (1), 1-9. 114838, 2020.
40. Wang J., Lv P., Wang H., Shi C., SAR-U-Net: Squeeze-and-excitation block and atrous spatial pyramid pooling based residual U-Net for automatic liver segmentation in Computed Tomography, Computer Methods and Programs in Biomedicine, 208, 106268, 2021.
41. Roy A.G., Navab N., Wachinger C., Recalibrating Fully Convolutional Networks With Spatial and Channel "Squeeze and Excitation" Blocks, IEEE Transactions on Medical Imaging, 38 (2), 540-549, 2019.
42. Hu J., Shen L., Albanie S., Sun G., Wu E., Squeeze-and-Excitation Networks, IEEE Transactions on Pattern Analysis and Machine Intelligence, 42 (8), 2011-2023, arXiv:1709.01507, 2017.
43. Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z., Rethinking the Inception Architecture for Computer Vision, 2016 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu-USA, 6230-6239, 27-30 June, 2016.
44. Zhao H., Shi J., Qi X., Wang X., Jia J., Pyramid scene parsing network, arXiv:1612.01105, 2016.
45. Bergmann P., Fauser M., Sattlegger D., Steger C., MVTEC ad-A comprehensive real-world dataset for unsupervised anomaly detection 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach-CA-USA, 9584-9592, 15-20 June, 2019.
46. Wieler M., Hahn T., Weakly Supervised Learning for Industrial Optical Inspection, <https://hci.iwr.uni-heidelberg.de/content/weakly-supervised-learning-industrial-optical-inspection>, Erişim tarihi May 7, 2021.