

# Faster Region-Based Multi-Layer Convolutional Neural Networks for Cracked Detection in Eggshell Images

 Muammer TÜRKÖĞLU<sup>1,\*</sup> 
<sup>1</sup>Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 12000, Merkez, BİNGÖL

## Graphical/Tabular Abstract

In this study, a deep network-based system was developed for automatic cracked detection in eggshell images. This system consists of image acquisition, image labeling, training, and testing stages. A unique data set based on the developed defective egg detection device was used in experimental studies. The operation steps of the proposed system are given in Figure A.

### Article Info:

Research article  
 Received:10/02/2021  
 Revision:22/02/2021  
 Accepted:26/02/2021

### Highlights

- Eggshell Defects
- Deep Learning
- Segmentation
- MATLAB

### Keywords

Cracked Detection  
 Faster Region-  
 Convolutional Neural  
 Networks  
 Computer Aided Detection  
 System




Figure A. Schema of the Proposed System

**Purpose:** Identifying cracked eggs is very significant in terms of health and hygiene. Separating cracked eggs in the food industry is done manually by experts. This situation causes many errors due to eye fatigue and the excessive workload of the expert. In line with this purpose, a deep learning-based system was developed to assist the experts for cracked detection on the egg surface smoothly and in a shorter time.

**Theory and Methods:** In this study, a Faster Region-based Convolutional Neural Network-based model was presented to detect cracked eggs. First, the cracked egg images were resized. Subsequently, the cracked regions were manually labeled on the images, and their locations were determined. The tagged images were applied to the entry of the 16-layer architecture developed based on Convolutional Neural Networks, and the training process was carried out. Finally, the test phase was conducted using the cracked detector containing knowledge about the texture and shape of the cracked areas obtained through the training phase.

**Results:** 107-cracked egg images based on the developed defective-egg detection device were used to test the proposed model. As a result, the proposed model achieved an average precision of 95.69% in detecting cracks on the egg. Visual and numerical test results of the proposed model are given in Chapter 4.

**Conclusion:** In the experimental results, it has been observed that the cracked areas on the egg surfaces are determined correctly with high performance using the proposed model. These results show that the proposed model can be used in the food industry to separate cracked eggs automatically. Besides, this study, in which extensive experimental studies were carried out, is suggested to lead to more studies on cracked detection on the egg surfaces.



## Faster Region-Based Multi-Layer Convolutional Neural Networks for Cracked Detection in Eggshell Images

Muammer TÜRKOĞLU<sup>1,\*</sup>

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

### Abstract

Automatic detection of cracked eggs is of great importance in terms of health. Today, the separation of cracked eggs is done by experts through observation. This process causes time loss and erroneous detections together with tiring. In this direction, a system based on Region-based Convolutional Neural Network (CNN) has been designed for the automatic detection of cracks in the egg surface. An original data set containing cracked eggs images were created for the training and testing phase of the proposed 16-layer CNN-based model. Cracked regions in 107 egg images using the MATLAB platform were labeled. Within the scope of experimental studies, an average precision of 95.69% was obtained by using the proposed model for cracked region detection. These results showed that the proposed computer-based system can be used to automatically separate cracked eggs in the food industry.

### Makale Bilgisi

Araştırma makalesi  
Başvuru: 10/02/2021  
Düzeltilme: 22/02/2021  
Kabul: 26/02/2021

### Keywords

Egg Cracked Detection  
Faster Region-  
Convolutional Neural  
Networks  
Computer Aided Detection  
System

### Anahtar Kelimeler

Yumurta Kırık Tespiti  
Daha Hızlı Bölgesel  
Evrişimsel Sinir Ağları  
Bilgisayar Destekli Tespit  
Sistemi

### Yumurta Kabuğu Görüntülerinde Kırık Tespiti için Daha Hızlı Bölgesel Tabanlı Çok Katmanlı Evrişimsel Sinir Ağları

### Öz

Kırık yumurtaların otomatik olarak tespiti sağlık açısından büyük bir önem taşımaktadır. Günümüzde, kırık yumurtaların ayrıştırılması uzmanlar tarafından gözlem yoluyla yapılmaktadır. Bu süreç, yorucu olmakla birlikte zaman kaybına ve hatalı tespitlere yol açmaktadır. Bu doğrultuda, yumurta yüzeyindeki kırıkların otomatik tespiti için Bölgesel tabanlı Evrişimsel Sinir Ağına (ESA) dayalı bir sistem tasarlanmıştır. Önerilen 16 katmanlı ESA tabanlı modelin eğitim ve test aşaması için kırık yumurta görüntülerini içeren özgün bir veri seti oluşturulmuştur. MATLAB platformu kullanılarak 107 yumurta görüntüsündeki kırık bölgeler etiketlenmiştir. Deneysel çalışmalar kapsamında, kırık bölge tespiti için önerilen model kullanılarak %95,69 ortalama kesinlik elde edilmiştir. Bu sonuçlar, önerilen bilgisayar destekli sistem, gıda sanayisinde otomatik olarak kırık yumurtaların ayrıştırılması amacıyla kullanılabilceğini göstermiştir.

## 1. GİRİŞ (INTRODUCTION)

Hayvansal gıda ürünlerinden biri olan yumurta, insanlar için önemli bir besin kaynağıdır. Yumurta, uygun fiyatlı ve besleyici olması açısından dünya çapında yaygın olarak tüketilmektedir. Bu derece yaygın olarak kullanılan yumurtanın kalite kontrolü de önem arz etmektedir. Yumurtaların toplanması ve paketlenmesi otomatik olarak yapılmasına rağmen yumurta kabuğunda oluşabilecek kusurların tespitine yönelik sistemler yetersiz kalmaktadır. Bu tür problemlerin giderilmesi amacıyla, birçok bilim adamı ve araştırmacı tarafından otomatik bir sistem tasarlanmaya çalışılmıştır [1-4].

Kırık yumurtaların tespit edilmesi, sağlık ve hijyen açısından çok önemlidir. Çatlak ya da kırık yumurtalar, zararlı bakteriyel enfeksiyonların yumurta kabuğundan içeri girmesine yol açmaktadır [1-2, 4]. Bu nedenle, yumurtalar tüketicilere ulaşmadan önce kırık tespitinin yapılması önemli hale gelmektedir. Günümüzde, yumurta kusurlarının tespiti ve ayrıştırılması, uzman kişiler tarafından görsel

olarak yapılmaktadır. Bu durum, uzman kişinin göz yorgunluğu ve aşırı iş yükünden dolayı yumurta kusurlarını tam olarak tespitini sınırlamaktadır. Son zamanlarda, kırık yumurtaların tespiti için makine öğrenmesi ve görüntü işleme yöntemlerine dayalı birçok çalışma yapılmıştır. Bu çalışmalar, sınıflandırma ve kırık bölge tespiti (segmentasyon) olmak üzere ikiye ayrılır. Bu çalışmalar Tablo 1’de özetlenmiştir.

**Tablo 1.** Mevcut çalışmalar

	Araştırmacılar	Kullanılan Yöntem	Performans (%)
<b>Sınıflandırma</b>	Öztürk ve Gangal [4]	Görüntü işleme teknikleri	88 (doğruluk)
	Omid ve ark. [5]	Görüntü işleme teknikleri ve bulanık mantığa dayalı hibrit bir sistem	94,5 (doğruluk)
	Guanjun ve ark. [6]	LOG (Laplacian of Gaussian) ve görüntü işleme teknikleri	92,5 (doğruluk)
	Wu ve ark. [7]	İstatistiksel özellikler ve DVM sınıflandırıcısı	93 (doğruluk)
	Abbaspour-Gilandeh ve Azizi [8]	Canny kenar detektörü, Hough dönüşümü ve Doğrusal diskriminant analizi	90,1 (doğruluk)
<b>Kırık bölge tespiti (segmentasyon)</b>	Yang ve ark. [9]	Görüntü işleme teknikleri ve bulanık mantığa dayalı bir sistem	94,55 (kesinlik)
	Abdullah ve ark. [10]	Görüntü işleme teknikleri ve Destek Vektör Makinesi	89,2 (duyarlılık) ve 94,6 (özgüllük)
	Datta ve ark. [11]	Daha hızlı bölgesel evrimsel sinir ağları	78,17 (ortalama kesinlik)

Tablo 1’den anlaşılacağı üzere, kırık yumurtaların sınıflandırılmasına dayalı mevcut çalışmalar, yaklaşık olarak %90-95 aralığında performans elde edilirken, segmentasyona dayalı çalışmalarda ortalama %90 performans elde edilmiştir. Ayrıca, sınıflandırma ve kırık bölge tespiti ile ilgili mevcut çalışmalarda, genellikle geleneksel görüntü işleme yöntemleri kullanılmıştır. Bu yöntemler, ışık, arka plan ve uzaklık gibi birçok farklı koşullarda performansları değişkenlik gösterebilmektedir. Bu sebeple, gıda sanayisi için geliştirilen gerçek zamanlı uygulamalarda bu tür yöntemler tercih edilmemektedir.

Son zamanlarda, görüntü sınıflandırılması ve nesnelerin konumlarının belirlenmesi için ESA’ya dayalı çalışmalar popüler hale gelmiştir. Bunun nedeni ise, eğitim aşamasında ayırt edici özelliklerin insandan bağımsız olarak çıkartılması ve yüksek performansa sahip olmasıdır. Bu çalışma kapsamında, yumurta yüzeyindeki kırık bölgelerin tespiti için Daha Hızlı Bölgesel Evrimsel Sinir Ağ modeli (DH-BESA) geliştirilmiştir. İlk olarak, kırık yumurta görüntüleri yeniden boyutlandırılmıştır. Daha sonra kırık bölgeler, görüntü üzerinde manuel olarak etiketlenmiş ve konumları belirlenmiştir. Etiketlenen görüntüler, Evrimsel Sinir Ağlara dayalı geliştirilen 16 katmanlı mimarinin girişine uygulanmıştır. Önerilen modeli test etmek için kırık yumurta görüntülerini içeren özgün bir veri seti kullanılmıştır. Deneysel çalışmalardan elde edilen sonuçlar, önerilen DH-BESA mimarisinin yüksek performansa sahip olduğunu göstermektedir.

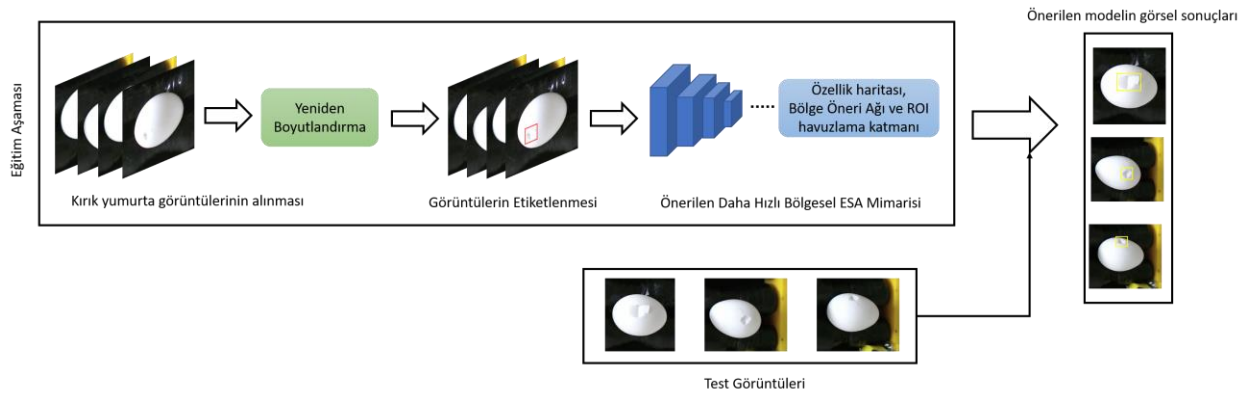
Önerilen modelin ana katkıları aşağıda maddeler halinde verilmiştir. Bunlar:

- Bu çalışmada, kırık yumurta görüntülerini içeren kamuya açık özgün bir veri seti oluşturulmuştur.
- Bu çalışmada, 16 katmanlı Evrimsel Sinir Ağlara dayalı bir model tasarlanmıştır. Önerilen model kullanılarak %95,69 ortalama kesinlik elde edilmiştir.
- Deneysel çalışmalardan elde edilen performans, kırık yumurtaların tespiti için önerilen modelin gıda sanayisinde gerçek zamanlı olarak kullanılabilirliğini göstermiştir.

Çalışma şu şekilde organize edilmiştir. Çalışmanın ikinci bölümünde önerilen modelin teorik alt yapısı ve veri kümesi anlatılmıştır. Üçüncü bölümde önerilen model detaylandırılmıştır. Deneysel sonuçlar dördüncü bölümde verilirken, son bölümde ise sonuçlar ve gelecek çalışmalardan bahsedilmiştir.

## 2. MATERYAL ve METOT (MATERIAL and METHOD)

Bu çalışmada, kırık yumurtalarının tespiti için Bölgesel Evrişimsel Sinir Ağlarına (BESA) dayalı bir model sunulmuştur. Önerilen modeli test etmek için geliştirilen kusurlu yumurta tespit cihazına dayalı özgün bir veri kümesi kullanılmıştır. Bu çalışmanın ana işlem adımları Şekil 1’de gösterilmiştir.



Şekil 1. Bu çalışmanın akış diyagramı

Önerilen modelin teorik alt yapısı ve kullanılan veri kümesi alt başlıklar halinde detaylandırılmıştır.

### 2.1. Veri Kümesi (Dataset)

Önerilen çalışma kapsamında geliştirilen kusurlu yumurta tespit makinesi kullanılarak kırık yumurta görüntülerini içeren bir veri seti oluşturulmuştur. Bu kapsamda, 4000x6000 çözünürlüğe sahip 107 kırık yumurta görüntüsü elde edilmiştir. Bu görüntüler, Nikon D7200 fotoğraf makinesi kullanılarak sabit uzaklıktan çekilmiştir. Örnek kırık yumurta görüntüleri Şekil 2’de verilmiştir.





Şekil 2. Örnek kırık yumurta görüntüleri

## 2.2. Evrişimsel Sinir Ağları (Convolutional Neural Networks)

ESA, konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katmanı içeren çok kademeli bir ağ yapısına sahiptir. İleri beslemeli bir sinir ağı modeline dayanan ESA, eğitim aşamasında geri yayılım sayesinde yinelemeli olarak ağırlıklarını güncellemektedir [12-14]. Derin ESA mimarisi, girdi görüntüsünden özellik haritalarının çıkarılması için Denklem 1’de verilen konvolüsyon katmanı ile gerçekleştirir.

$$S[m, n] = (I * K)[m, n] \sum_i \sum_j I(m + i, n + j)K(i, j) \quad 1$$


Burada çıkış matrisinin satır ve sütunları sırasıyla m ve n olarak ifade edilir. Giriş olarak I görüntüsü ve bir K konvolüsyon çekirdeği kullanılarak, S[m,n] konvolüsyon katmanının çıkış görüntüsü oluşturulmaktadır. Elde edilen özellik haritası belirlenen bir aktivasyon fonksiyonundan geçirilmektedir. Bir sonraki aşamada ise aşırı uyumu ortadan kaldırılması için havuzlama katmanı bulunmaktadır. Havuzlama katmanında maksimum, minimum ve ortalama değerler kullanılarak çıktı haritaların alt örneklemeleri elde edilir.  $2 \times 2$  boyutunda maksimum havuzlama fonksiyonu kullanılarak hesaplama, Denklem 2’de gösterildiği gibi formüle edilebilir.

$$f_{havuzlama} = \text{Max}(S_{m,n}, S_{m+1,n}, S_{m,n+1}, S_{m+1,n+1}) \quad 2$$

Konvolüsyon ve havuzlama katmanı işlemleri sonucunda elde edilen özellik haritaları, tam bağlı katman sayesinde tek boyuta indirgenmektedir. Son olarak özellik matrisi, sınıflandırıcıya girdi olarak verilmektedir [12-17].

## 2.3. Daha Hızlı Bölgesel Evrişimsel Sinir Ağları (Faster Regional Convolutional Neural Networks)

Bu çalışmada, veri setindeki görüntü boyutları  $128 \times 128$  olarak yeniden boyutlandırıldı. Bu işlemten sonra, görüntülerdeki yumurta ve kırık bölgelerinin özelliklerinin çıkarılması için bir ESA mimarisi kullanıldı. Bu çalışmada kullanılan DH-BESA, üç ana aşamadan oluşan bir algılayıcıdır. Bu aşamalardan ilki temel adım olarak görüntü özelliklerinin çıkarılması için kullanılan ESA mimarisi, ikincisi nesne sınırlarının tahmini için önerilen bir bölge öneri ağı (RPN) ve son olarak tespit edilen bölgeler için sınırlayıcı kutu regresör (bounding box regressor) ile sınıflandırıcı içeren bir ROI (ilgili alan) kısmından oluşmaktadır [18-19]. Önerilen DH-BESA mimarisinin örnek bir gösterimi Şekil 3’te verilmiştir.



Şekil 3. DH-BESA mimarisinin yapısı

### 3. ÖNERİLEN YÖNTEM (THE PROPOSED METHOD)

Bu çalışmada, yumurta yüzeyindeki kırık bölgeleri tespit etmek için Bölgesel ESA'ya dayalı bir model geliştirilmiştir. Önerilen modelin temel işlem adımları şunlardır:

- Kırık yumurta görüntülerini içeren bir veri seti oluşturuldu.
- Elde edilen görüntüler, 128x128 boyutunda yeniden boyutlandırıldı.
- MATLAB programının Image Labeler araç kutusu kullanılarak yumurta üzerindeki kırık bölgeler etiketlendi.
- Eğitim ve test kümelerine ayırma işlemi yapıldı.
- Evrimsel Sinir Ağlarına dayalı derin bir mimari tasarlandı ve ağın eğitim işlemi gerçekleştirildi. Daha sonra, kırık bölgelerin doku ve şekil gibi özellik bilgilerini barındıran kırık detektörü elde edildi.
- Son olarak, elde edilen kırık detektörü kullanılarak test aşaması gerçekleştirildi ve önerilen modelin performansı belirlendi.

Bu çalışmada ESA'ya dayalı tasarlanan mimari, konvolüsyon, ReLu, havuzlama ve tam bağlı katmanlardan oluşmaktadır. Bu mimarinin genel yapısı ve karakteristik özellikleri Tablo 2'de detaylandırılmıştır.

Tablo 2. Tasarlanan ESA mimarisinin genel yapısı


	Ad	Tip	Filtre Boyutu/Stride	Çıkış Boyutu
1	Input_1	Görüntü	-	128x128x3
2	Conv_1	Konvolüsyon	5x5/1	126x126x32
3	Relu_1	ReLU	-	-
4	Conv_2	Konvolüsyon	5x5/1	124x124x64
5	Relu_2	ReLU	-	-
6	Averagepool_1	Havuzlama	3x3/2	61x61x64
7	Conv3_1	Konvolüsyon	5x5/1	59x59x64
8	Relu_3	ReLU	-	-
9	Conv3_1	Konvolüsyon	5x5/1	57x57x32
10	Relu_3	ReLU	-	-
11	Averagpool_1	Havuzlama	3x3/2	28x28x32
12	Fc_1	Tam Bağlı	-	1x1x1024
13	Relu_3	ReLU	-	-
14	Fc_2	Tam Bağlı	-	1x1x2
15	Softmax_1	Softmax	-	2
16	Classoutput	Sınıflandırma Çıkışı	-	-

#### 4. BULGULAR ve TARTIŞMA (RESULTS and DISCUSSION)

Deneyisel çalışmalarda kullanılan bilgisayar, NIDIA Quadro P4000 GPU kartı, Intel Xeon Silver 2.19 GHz ve 32 GB Ram bellek özelliklerine sahiptir. Tüm uygulamalar, MATLAB (R2020a) platformu kullanılarak gerçekleştirilmiştir. Önerilen modelin performans kriteri için duyarlılık ve kesinlik değerlerine dayalı Ortalama Kesinlik (Average Precision-AP) kullanılmıştır. Duyarlılık, pozitif olarak tahmin edilmesi gereken verilerin ne kadarını pozitif olarak tahmin edildiğini gösteren bir kriterdir. Kesinlik ise, pozitif olarak tahmin edilen değerlerin gerçekte ne kadarının pozitif olduğunu gösteren bir kriterdir. Bu değer matematiksel olarak Denklem 3'te verilmiştir.


$$\text{Ortalama Kesinlik (AP)} = \sum_{k=1}^{n-1} |Duyarlılık(k) - Duyarlılık(k+1)| * Kesinlik(k) \quad 3$$

Deneyisel çalışmalarda, özgün veri setimiz için rastgele bir şekilde verilerin %80'i eğitim ve geri kalan ise test için kullanılmıştır. Öncelikle, veri seti 128x128 olarak yeniden boyutlandırılmıştır. Daha sonra, Matlab Image Labeler araç kutusu kullanılarak yumurtalardaki kırıklar dikdörtgen bir şekilde etiketlenmiştir. Bu işlem ile ilgili örnek bir gösterim Şekil 4'te verilmiştir.




Şekil 4. Image Labeler araç kutusu işlemi

Yumurta görüntülerindeki kırık bölgeler etiklendikten sonra önerilen mimari kullanılarak eğitim işlemi gerçekleştirilmiştir. Önerilen ESA tabanlı mimarinin eğitimi için epoch değeri 50, batch boyutu 1, öğrenme katsayısı  $1 \times 10^{-4}$  ve Stokastik dereceli alçalma tabanlı momentum (stochastic gradient descent with momentum) optimizasyon yöntemi kullanılmıştır. Önerilen ağı eğitimi 5350 iterasyon sonra sona ermiştir. Daha sonra, eğitim aşamasından elde edilen kırık detektörü kullanılarak test işlemi gerçekleştirilmiştir. Önerilen mimari kullanılarak 20 kırık yumurta görüntüsünü içeren test işlemleri kapsamında elde edilen kesinlik/duyarlılık eğrisi Şekil 5'te verilmiştir.



Şekil 5. Deneyisel sonuçlara göre kesinlik/duyarlılık eğrisi

Şekil 5'te verilen kesinlik/duyarlılık eğrisinin altındaki alan ortalama kesinliği (average precision) vermektedir. Sonuç olarak, deneysel çalışmalardan elde edilen ortalama kesinlik %95,69 olarak hesaplanmıştır. Önerilen mimarinin test sonuçları, Şekil 6'da görsel olarak sunulmuştur.



Şekil 6. Önerilen modelin görsel test sonuçları

Şekil 6'daki sarı etiketler, yumurta üzerindeki kırık bölgeleri temsil etmektedir. Etiketler üzerindeki rakamlar ise etiketlenen bölgenin kırık olma ihtimalini göstermektedir. Bu görsel sonuçlara göre, önerilen DH-BESA modeli kullanılarak yumurta yüzeylerindeki kırık bölgeler yüksek performans ile konumları doğru tespit edildiği gözlenmiştir.

Nesne tespiti ya da segmentasyon ile ilgili çok sayıda çalışma bulunmaktadır. Beyin tümör, araba plakası ve yüz tanıma gibi birçok alanda konum tespit çalışmaları yapılmıştır. Fakat, yumurta yüzeylerindeki kusurlu bölgelerin tespiti veya konum belirleme ile ilgili çalışmalar çok az sayıdadır. Bu çalışmalardan Yang ve ark. [9], yumurta yüzeylerindeki kırık tespiti için görüntü işleme teknikleri ve bulanık mantığa dayalı bir sistem sunmuşlardır. Test işlemi için 55 yumurta örneğine dayalı gerçekleştirilen deneysel çalışmalarda, %94,55 kesinlik elde etmişlerdir. Diğer bir çalışmada ise daha hızlı bölgesel evrimsel sinir ağlara dayalı bir model kullanılarak %78,17 ortalama kesinlik elde etmişlerdir [11]. Tüm bu sonuçlara göre, önerdiğimiz model, diğer çalışmalara göre daha yüksek performansa sahip olduğu gözlenmiştir. Ayrıca, kapsamlı deneysel çalışmalar gerçekleştirilen bu çalışma, yumurta yüzeylerindeki kırık tespiti ile ilgili yapılacak çalışmalara öncülük edeceği düşünülmektedir.



#### 4. SONUÇ (CONCLUSION)

Bu çalışmada, yumurta görüntülerinde kırık bölgelerin otomatik olarak tespiti için Bölgesel tabanlı Evrişimsel Sinir Ağlara dayalı bir model geliştirilmiştir. Önerilen model, konvolüsyon, havuzlama ve relu katmanlarını içeren 16 katmandan oluşmaktadır. Deneysel çalışmalarda, kusurlu yumurta tespit cihazı ile elde edilen 107 kırık yumurta görüntüleri kullanılmıştır. Sonuç olarak, önerilen model, yumurta üzerindeki kırıkların tespitinde %95,69 ortalama kesinlik elde etmiştir. Bu sonuçlar, önerilen modelin gıda sanayisinde otomatik olarak kırık yumurtaların ayrıştırılması amacıyla kullanılabileceğini göstermiştir. İleriki çalışmalarda, daha ince kırık görüntüleri içeren veri kümesinin genişletilmesi düşünülmektedir. Ayrıca önceden eğitilmiş derin mimariler kullanılarak kırık yumurta tespiti yapılması planlanmaktadır.

#### TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu çalışma Tubitak 1512 (Teknogirişim Sermayesi Desteği Programı) kapsamında 2180160 nolu proje sonuçlarından hazırlanmıştır. Desteği için TUBİTAK'a teşekkür ederiz.

#### KAYNAKLAR (REFERENCES)

- [1] N. Öztürk, "Görüntü işleme teknikleri ile beyaz yumurtalar üzerindeki yumurta kabuğu kusurlarının algılanması," Yüksek Lisans Tez, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye, 2014.
- [2] İ. Durmuş, E. Yenice and Ş. E. Demirtaş, "Egg abnormality," Tavukçuluk Araştırma Dergisi, vol. 7, no. 1, pp. 66-71, 2007.
- [3] J. Priyadumkol, C. Kittichaikarn, and S. Thainimit, "Crack detection on unwashed eggs using image processing," Journal of Food Engineering, vol. 209, pp. 76-82, 2007.
- [4] N. Öztürk and A. Gangal, "Eggshell defects detection on white eggs using image processing techniques," In 2014 22nd Signal Processing and Communications Applications Conference (SIU), pp. 810-813, 2014.
- [5] M. Omid, M. Soltani, M. H. Dehrouyeh, S. S. Mohtasebi and H. Ahmadi, "An expert egg grading system based on machine vision and artificial intelligence techniques," Journal of food engineering, vol. 118, no. 1, pp. 70-77, 2013.
- [6] B. Guanjun, J. Mimi, X. Yi, C. Shibo and Y. Qinghua, "Cracked egg recognition based on machine vision," Computers and Electronics in Agriculture, vol. 158, pp. 159-166, 2019.
- [7] L. Wu, Q. Wang, D. Jie, S. Wang, Z. Zhu and L. Xiong, "Detection of crack eggs by image processing and soft-margin support vector machine," Journal of Computational Methods in Sciences and Engineering, vol. 18, no. 1, pp. 21-31, 2018.
- [8] Y. Abbaspour-Gilandeh, and A. Azizi, "Identification of Cracks in Eggs Shell Using Computer Vision and Hough Transform," Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi, vol. 28, no. 4, pp. 375-383, 2018.
- [9] J. Yang, C. Y. Xia, H. Pan, Y. Shi, and X. Y. Li, "Research of Test Model for Eggshell Crack Detection," Advanced Materials Research. Vol. 846, Trans Tech Publications Ltd, 2014.
- [10] M. H. Abdullah, S. Nashat, S. A. Anwar and M. Z. Abdullah, "A framework for crack detection of fresh poultry eggs at visible radiation," Computers and Electronics in Agriculture, vol. 141, pp. 81-95, 2017.
- [11] A. K. Datta, B. Botta and S. S. R. Gattam, "Damage detection on chicken eggshells using Faster R-CNN," 2019 ASABE Annual International Meeting. American Society of Agricultural and Biological Engineers, 2019.

- [12] Q. Li, and G. Chen, "Recognition of industrial machine parts based on transfer learning with convolutional neural network," Plos one, vol. 16, no. 1, pp. e0245735, 2021.
- [13] M. Turkoglu, "COVIDetectioNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble," Applied Intelligence, pp. 1-14, 2020.
- [14] S. K. Khare, and V. Bajaj, "Time-frequency representation and convolutional neural network-based emotion recognition," IEEE transactions on neural networks and learning systems, pp. 1-9, 2020.
- [15] F. Demir, M. Turkoglu, M. Aslan, and A. Sengur, "A new pyramidal concatenated CNN approach for environmental sound classification," Applied Acoustics, vol. 170, pp. 107520, 2020.
- [16] D. Şengür and S. Siuly, "Efficient approach for EEG-based emotion recognition," Electronics Letters, vol. 56, no. 25, pp. 1361-1364, 2020.
- [17] M. B. ER, "Akciğer Seslerinin Derin Öğrenme ile Sınıflandırılması," Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, vol. 8, no. 4, pp. 830-844, 2020.
- [18] Y. Guo, Y. Peng and B. Zhang, "CAFR-CNN: coarse-to-fine adaptive faster R-CNN for cross-domain joint optic disc and cup segmentation," Applied Intelligence, pp. 1-25, 2021.
- [19] 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, 2016.