



## Detection of Eggshell Defects using Convolutional Neural Networks

Muammer Türkoğlu<sup>1,a,\*</sup>

<sup>1</sup>Computer Engineering Department, Engineering Faculty, Bingol University, 12000 Bingol, Turkey

\*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 06/11/2020 Accepted : 28/01/2021</p> <p><b>Keywords:</b> Defective egg detection Deep architectures Convolutional neural networks Transfer Learning Classification</p>	<p>In commercial egg farming industries, the automatic sorting of defective eggs is economically and healthily important. Nowadays, detect of defective eggs is performed manually. This situation involves time consuming, tiring and complex processes. For all these reasons, automatic classification of defects that may occur on the egg surface has become a very important issue. For this purpose, in this study, classification of egg defects was performed using AlexNet, VGG16, VGG19, SqueezeNet, GoogleNet, Inceptionv3, ResNet18, and Xception architectures, which were developed based on Convolutional Neural Networks (CNN), which provide high performance in object recognition and classification. To test the performance of these architectures, an original data set containing dirty, bloody, cracked, and intact eggs were built. As a result of experimental studies, the highest accuracy score was obtained with VGG19 architecture as 96.25%. In these results, it was observed that ESA methods achieved high success in classifying defective eggs.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 9(3): 559-567, 2021

## Evrişimsel Sinir Ağları Kullanılarak Yumurta Kabuğu Kusurlarının Tespiti

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 06/11/2020 Kabul : 28/01/2021</p> <p><b>Anahtar Kelimeler:</b> Kusurlu yumurta tespiti Derin mimariler Evrişimsel sinir ağları Transfer Öğrenme Sınıflandırma</p>	<p>Ticari yumurta çiftliği endüstrilerinde, kusurlu yumurtaların otomatik olarak ayrılması ekonomik ve sağlık açısından önemlidir. Günümüzde, kusurlu yumurtaların tespiti manuel olarak yapılmaktadır. Bu durum, zaman alıcı, yorucu ve karmaşık süreçler içermektedir. Tüm bu nedenlerden dolayı, yumurta yüzeyinde oluşabilecek kusurların otomatik olarak sınıflandırılması oldukça önemli bir konu haline gelmiştir. Bu amaç doğrultusunda, bu çalışmada, nesne tanıma ve sınıflandırma alanlarında yüksek performans sağlayan Evrişimsel Sinir Ağlarına (ESA) dayalı geliştirilen AlexNet, VGG16, VGG19, SqueezeNet, GoogleNet, Inceptionv3, ResNet18 ve Xception mimarileri kullanılarak yumurta kusurlarının sınıflandırılması gerçekleştirilmiştir. Bu mimarilerin performansını test etmek için kirli, kanlı, kırık ve sağlam yumurtaları içeren özgün bir veri seti inşa edilmiştir. Deneysel çalışmalar sonucunda, en yüksek doğruluk skoru VGG19 mimarisi ile %96,25 olarak elde edilmiştir. Bu sonuçlarda, ESA yöntemlerinin kusurlu yumurtaların sınıflandırılmasında yüksek başarı sağladığı gözlemlenmiştir.</p>

<sup>a</sup> [mturkoglu@bingol.edu.tr](mailto:mturkoglu@bingol.edu.tr)

<sup>id</sup> <https://orcid.org/0000-0002-2377-4979>

## Giriş

Yumurta zengin besin değerleri içermesinden dolayı insan beslenmesinde kullanılan en önemli hayvansal gıdalardan biridir. Dünya nüfusunun artması ile birlikte son zamanlarda yumurta üretim çiftlik sayıları artmıştır. Artan yumurtaya talepler beraberinde birtakım sorunlar ortaya çıkarmıştır. Bir yumurta kabuğunda, kir, kan ve kırık gibi temel kusurlar meydana gelebilir. Bu kusurlardan kirli yumurtalar, su vasıtasıyla temizlenmesi, yumurta kabuğundaki zararların zarar görmesine ve böylece mikroorganizmaların yumurtanın içerisine girmesine neden olmaktadır. Aynı şekilde, yumurta kabuğundaki kan lekeleri de insan sağlığına zarar vermektedir. Kırık yumurtalar ise zararlı bakteriyel enfeksiyonların yumurta kabuğundan içeri girmesine ve çeşitli hastalıklara neden olduğu bilinmektedir (Durmuş ve ark., 2007; Omid ve ark., 2013; Öztürk ve Gangal, 2014).

Yumurta üretim çiftliği endüstrilerinde, tüketici için yumurtaların işlenmesi; toplama, yıkama, sınıflandırma ve paketleme olmak üzere 4 aşamadan oluşmaktadır. Bu aşamalardan, toplama, yıkama ve paketleme için gerekli makine teçhizatları bulunmaktadır (Öztürk ve Gangal, 2014; Öztürk, 2014). Bunun yanı sıra, yumurtaların sınıflandırılması için hali hazırda bilgisayar tabanlı sistemler bulunmamaktadır. Bu işlemler, görsel denetim kullanılarak manuel yapılmaktadır. Ayrıca, çoğu endüstri sınıflandırma işlemi yapmadan toplanan yumurtaları olduğu gibi tüketiciye ulaştırılmaktadır. Tüm bu nedenlerden dolayı, kusurlu yumurtaların erkenden tespiti ve bunların ayrılması, yumurta endüstrilerine ekonomik ve sağlık açısından büyük bir katkı sağlayacaktır (Omid ve ark., 2013; Arivazhagan ve ark., 2013; Patel ve ark., 1988).

Son yıllarda, kusurlu yumurtalarının sınıflandırılması ve sağlam yumurtanın tespiti için makine öğrenmesi ve derin öğrenme yöntemlerine dayalı birçok çalışma gerçekleştirilmiştir. Syahir ve ark. (2007), yumurtalardaki anormallikleri tespit etmek için görüntü işleme yaklaşımları kullanılmışlardır. Bu çalışmada, renk geliştirme ve görüntü filtreleme yöntemleri kullanılarak renkli yumurta görüntüleri iyileştirilmiştir. Daha sonra, yatay tarama işlemleri kullanılarak özellikler çıkartılmış ve bu elde edilen bilgilere dayalı bölütleme işlemi uygulanmıştır. Sonuç olarak, kan lekesine sahip yumurtaların tespiti için %83 doğruluk elde edilmiştir. Leiqing ve ark. (2007), çatlak yumurtaların tespiti için Geri Yayılım sinir ağı yöntemine dayalı bir model sunmuşlardır. Çatlak ve çatlaksız yumurta görüntüleri kullanılarak görüntü işleme teknikleri uygulandı ve beş geometrik özelliklere dayalı her bir görüntü için karakteristik parametreler elde edildi. Son olarak, beş girişli Geri Yayılım sinir ağı modeli geliştirilmiştir. Deneysel sonuçlarda, çatlak ve çatlaksız yumurtaların sınıflandırılması için %96,8 doğruluk elde edilmiştir. Omid ve ark. (2013), iç kan lekesi, çatlak ve kabuk kırılması gibi yumurta kusurlarının sınıflandırılması için makine öğrenmesi ve bulanık mantığa dayalı hibrit bir sistem önermişlerdir. Tasarlanan sistem, manuel olarak sınıflandırma işlemlerini gerçekleştiren uzmanlara göre daha iyi performans elde edildiği gözlenmiştir. Öztürk ve Gangal (2014), kirli, çatlak ve temiz yumurtaların sınıflandırılması için hibrit bir sistem geliştirmişlerdir. İlk olarak, görüntü işleme yöntemleri kullanılarak yumurtalar arka zeminden ayrılmıştır. Daha sonra, eşikleme ve kenar

belirleme algoritmasına dayalı kir ve çatlak yumurtaların tespiti gerçekleştirilmiştir. Deneysel çalışmalarda, yumurtaların kusurlu ve temiz olarak sınıflandırma başarısı %93, kirli yumurtaların tanıma başarısı %92 ve çatlak yumurtaların tanıma başarısı ise %88'dir. Abbaspour-Gilandeh ve Azizi (2018), yumurta kabuğundaki çatlakların tespiti için Canny kenar detektörü ve Hough dönüşümüne dayalı ön-işlem yöntemleri uygulamışlardır. Daha sonra, sınıflandırmak için doğrusal diskriminant analizi kullanılmıştır. Deneysel sonuçlarda, sağlam ve çatlak yumurtaların sınıflandırılması için doğruluk oranı %90,1 olarak elde edilmiştir. Wu ve ark. (2018), sağlam ve kırık yumurtaların sınıflandırılması için renk bileşenleri ve kenar algoritmalarına dayalı bir model geliştirmişlerdir. Özellik çıkarım aşamasında, ortalama, varyans ve çarpıklık gibi istatistiksel momentler kullanılmıştır. Son olarak, elde edilen bu özellikler için SVM yöntemi kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Deneysel sonuçlarda, 10 kat çapraz doğrulama yöntemi kullanılarak %93 doğruluk elde edilmiştir. Guanjun ve ark. (2019), arka ışık aydınlatma sistemi kullanılarak yumurtadaki çatlakları geliştirmek ve iyileştirmek için LOG (Laplacian of Gaussian) yöntemi kullanılmıştır. Daha sonra, yumurta görüntüsündeki ilgisiz alanları ortadan kaldırmak için Hysteresis eşikleme yöntemi uygulanmış ve en uygun eşik değeri belirlenmiştir. Son olarak, çatlak bölgeyi ayırmak için geliştirilmiş yerel uygulama görüntüsü indeksi kullanılmıştır. Deneysel sonuçlarda, yumurtadaki çatlakların tespiti için %92,5 doğruluk elde edilmiştir. Nasiri ve ark. (2020), kanlı, çatlak ve sağlam yumurtaların tanınması için önceden eğitilmiş VGG16 modelinin geliştirilmiş bir versiyonu önerilmişlerdir. Sonuç olarak, 5 kat çapraz doğrulama yöntemi kullanılarak %94,84 doğruluk elde edilmiştir. Deneysel çalışmalarda, geliştirilen model, geleneksel makine öğrenmesi yöntemlerine göre daha iyi performans gösterdiği gözlenmiştir.

Bu çalışmada, kusurlu yumurtaların tespiti için literatürde yaygın olarak kullanılan ve yüksek performans elde edilen Evrimsel Sinir Ağları (ESA) yöntemleri kullanılmıştır. Bu amaç doğrultusunda, transfer öğrenme yaklaşımına dayalı önceden eğitilmiş ESA mimarilerinden AlexNet, VGG16, VGG19, GoogleNet ve ResNet18 modelleri kullanılmıştır. Bu derin mimarileri test etmek için Kusurlu yumurta tespit cihazı kullanılarak sağlam, kirli, kırık ve kanlı olmak üzere 600 farklı yumurta görüntüsü kullanılmıştır. Önerilen sistemin ana katkıları şunlardır;

- Geliştirilen kusurlu yumurta tespit cihazı ile 890 farklı yumurta kullanılarak kapsamlı bir veri seti inşa edilmiştir.
- Bu çalışmada, kusurlu yumurtaların tespiti için en çok kullanılan derin öğrenme mimarileri adapte edilmiştir. Bu amaç doğrultusunda, transfer öğrenme yaklaşımı kullanılmış ve elde edilen sonuçlar kapsamlı bir şekilde tartışılmıştır. Ayrıca, kullandığımız derin mimarilerinin eğitim süreleri hesaplanmış ve karşılaştırılmıştır.
- Bu çalışma, kusurlu yumurtaların doğru tespiti açısından yüksek performansa sahip, etkili ve basit olduğundan değerlidir.

Çalışma şu şekilde organize edilmiştir. Bölüm 2’de, önerilen sistem ile ilgili bilgiler ve kullanmış olduğumuz özgün veri seti detaylandırılmıştır. Bölüm 3’te önerilen sistemin sonuçları ve bu sonuçlara dayalı bir tartışma yer almaktadır. Son bölümde ise sonuçlar ve gelecekteki çalışmalar ile ilgili bilgiler bulunmaktadır.

## Materyal ve Yöntem

Kusurlu yumurtaların sınıflandırılması için önermiş olduğumuz akış modeli Şekil 1’de verilmiştir. Bu doğrultuda, öncelikle geliştirilen kusurlu yumurta tespit cihazı kullanılarak özgün bir veri seti elde edilmiştir. Etiketleme ve yeniden boyutlandırma işlemleri gerçekleştirilerek ESA mimarilerinin girişlerine verilmiştir. Son olarak ESA mimarilerinin son katmanı olarak Softmax katmanı kullanılarak sınıf etiketleri belirlenmiştir. Buna ek olarak, ESA mimarilerinin eğitimi için en performansa sahip ağ parametreleri, deneme yanılma yoluyla tespit edilmiştir.

Bu bölümde, özgün veri setimiz ve önerilen sistemi oluşturan teorik altyapı alt başlıklar halinde verilmiştir.

### Veri Seti

Deneyel çalışmalar için geliştirilen yumurta hastalık tespit cihazı kullanılarak yumurta görüntüleri elde edildi. Geliştirilen bu cihazda (Şekil 2), birer adet bilgisayar, kayan zemin, kamera sistemi ve vakum kolu yer almaktadır. Genel olarak bu cihazın çalışma prensibi: ilk olarak yumurtaların bulunduğu hazne kayan zeminin başlangıç kısmına yerleştirilir. Daha sonra, yürüyen bant çalıştırılır ve kızılötesi sensor aracılığıyla kamera sistemi bölümüne geldiğinde durdurulur. Nikon d7200 kamera kullanılarak güneş ışığında 10’lu yumurta haznesi içerisinde yumurta görüntüleri çekilir ve yumurta her bir yumurta görüntüsü için sabit koordinatlar kullanılarak otomatik ayırma işlemi yapılır. Önerilen yazılım sistemi kullanılarak yumurtalarının sınıf etiketleri belirlenir. Son olarak, kusurlu yumurtaların koordinatları Aurdino kartını gönderilir ve bu yumurtalar vakum kolu aracılığıyla yumurta haznesinden ayırma işlemi gerçekleştirilir. Geliştirilen bu cihaz ile 890 farklı yumurta kullanılarak 250 kanlı, 190 kırık, 150 kirli ve 300 sağlam yumurta görüntüleri elde edilmiştir. Her bir sınıf için örnek görüntüler Şekil 2’de verilmiştir.

Deneyel çalışmalarda, özgün veri setimiz için rastgele bir şekilde verilerin %70’i eğitim ve geri kalan %30’u ise test için kullanılmıştır. Bütün deneyel çalışmalarda aynı eğitim ve test kümesi kullanılarak kusurlu yumurta tespiti için sınıflandırma performansına etkileri sabitlenmiştir.

### Evrişimsel Sinir Ağları

Temel Evrişimsel Sinir Ağı mimarisi, genel olarak konvolüsyon, havuzlama, normalizasyon, doğrultulmuş doğrusal birim (ReLU) ve tam bağlı olmak üzere 5 temel katmanlardan oluşmaktadır. Bu katmanlardan konvolüsyon katmanı, ESA mimarisinin temelini oluşturur. Bu katman, giriş görüntülerinde ayırt edici özellikleri çıkarmayı amaçlamaktadır. Şekil 3’te gösterildiği gibi, konvolüsyon katmanında, çeşitli evrişim filtreleri kullanılarak görüntünün tümünü soldan sağa ve yukarıdan aşağıya gezdirerek yeni bir özellik haritası elde edilir (Turkoglu, 2019). Konvolüsyon işleminin matematiksel ifadesi Denklem 1’de belirtilmiştir.

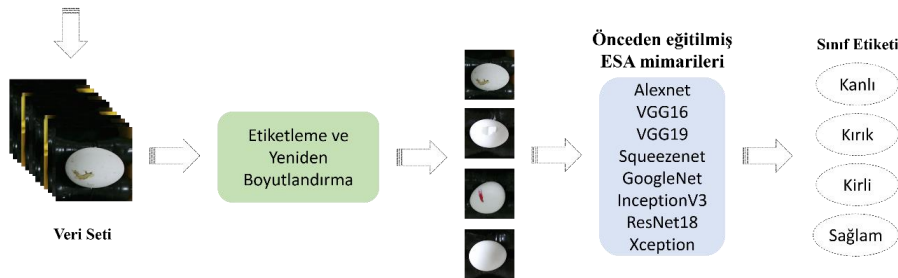
$$f[m,n] \times h[m,n] = \sum_j \sum_i h[j,k] f[m-j,n-i] \quad (1)$$

Burada, girdi görüntüsü  $f$  ve filtre (çekirdek)  $h$  ile ifade edilir. Çıkış matrisinin satır ve sütunları sırasıyla  $m$  ve  $n$  olarak gösterilir.  $j$  ve  $k$  ise filtredeki konumu gösterir (Basaran ve ark., 2020). Evrişim işleminden sonra aktivasyon fonksiyonu olarak Düzeltilmiş doğrusal birim katmanı (ReLU) fonksiyonu takip eder. Bu fonksiyon, giriş verisindeki negatif değerleri sıfıra çeker ve bu sayede ağı daha hızlı öğrenmesi sağlanır (Turkoglu, 2019; Turkoglu ve ark., 2020). ReLU fonksiyonu matematiksel olarak Denklem 2’de verilmiştir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (2)$$


ReLU aktivasyon katmanından sonra giriş verilerinin belirli bir aralıkta olmasını ve ağı performansının artırılması için normalizasyon katmanı kullanılır. Son olarak, havuzlama katmanı uygulanır. Bu katmanın çalışma prensibi, belirli filtre çeşitleri kullanılarak görüntünün tüm pikselleri üzerinde gezdirilir ve görüntüdeki piksellerin maksimum değeri alınır. Bu sayede, bir görüntünün boyutu küçültme işlemine gerçekleştirilir (Turkoglu, 2019; Turkoglu ve ark., 2020).

Kusurlu yumurta tespit cihazı




Şekil 1. Önerilen sistemin genel yapısı (Kaynak: Yazarlar tarafından üretilmiştir)

Figure 1. General structure of the proposed system



Şekil 2. Veri Setine ait örnek görüntüler, a) Sağlam yumurta, b) Kırık yumurta, c) Kirlı yumurta, d) Kanlı yumurta (Kaynak: Yazarlar tarafından üretilmiştir)

Figure 2. Sample images of the Dataset, a) Intact egg, b) Cracked egg, c) Dirty egg, d) Bloody egg.

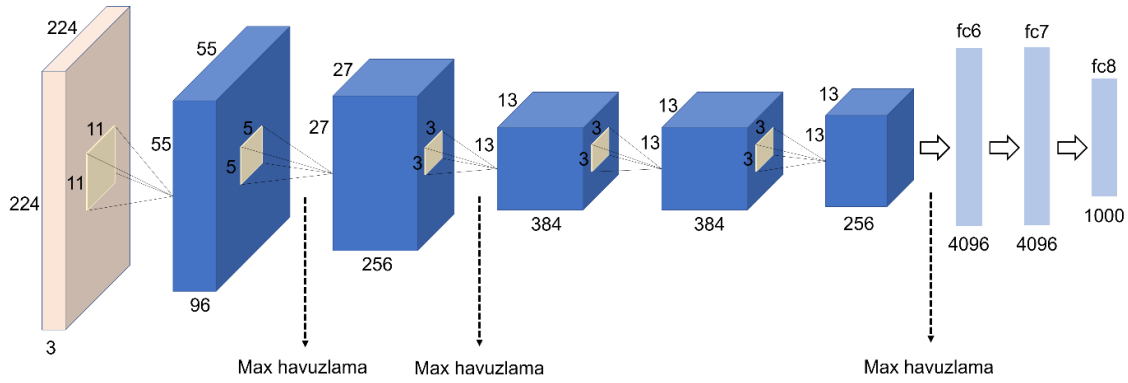


Şekil 3. Konvolüsyon işlemi ile ilgili örnek bir uygulama (Turkoglu, 2019)

Figure 3. An example application about the convolution process

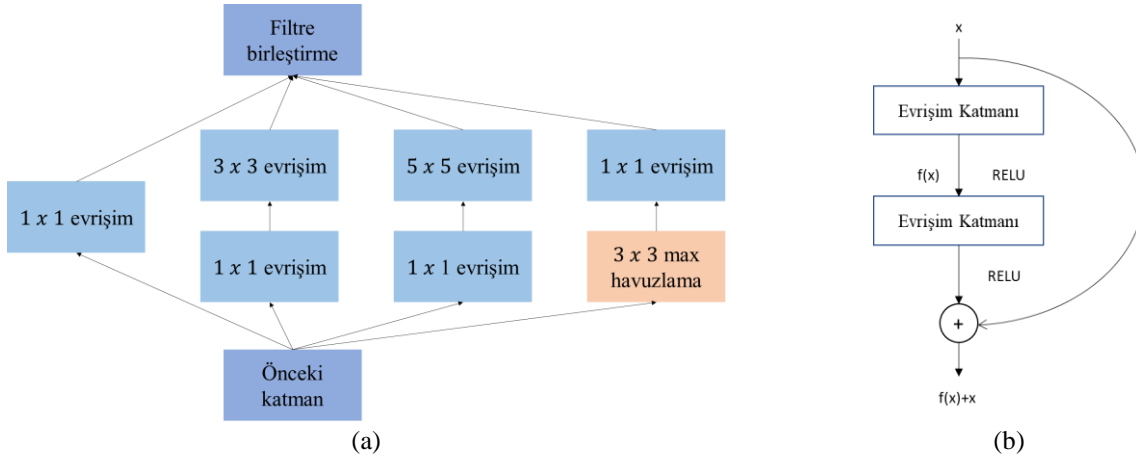
Evrişimsel sinir ağları, 2012 yılında büyük ölçekli görsel tanıma (ILSVRC) adlı yarışma ile popüler hale gelmiştir. Bu yarışmalarda, klavye, fare, kalem ve birçok hayvan gibi 1000 sınıflı olmak üzere bir milyondan fazla görüntü içeren ImageNet veri seti kullanılarak ESA'ya dayalı birçok modeller geliştirilmiştir. Günümüze kadar ESA tabanlı geliştirilen bu mimariler, birbirlerinden farklı karakteristik özelliklere sahiptir. Bu mimarilerden en yaygın olarak kullanılan AlexNet, Krizhevsky ve diğerleri tarafından geliştirilerek yüksek doğruluk elde edilmiş ve yarışmada birinci olmuştur. Bu mimari (Şekil 4), 5 konvolüsyon, 3 havuzlama katmanı ve 3 tam bağlı katman olmak üzere 25 katmandan oluşmaktadır. Ayrıca AlexNet modeli, 61 milyon parametre ve 227 MB boyut içermektedir (Turkoglu ve Hanbay, 2019; Altuntas ve ark., 2019; Turkoglu, 2020).

Bu çalışmada, AlexNet mimarisine ek olarak VGG16, VGG19, GoogleNet, SqueezeNet ve ResNet18 mimarileri de kullanılmıştır. Bu mimariler, birbirinden benzersiz özelliklere sahiptir. VGG16 ve VGG19 mimarileri, AlexNet mimarisine göre daha fazla katman içermektedir. Buna ek olarak, SqueezeNet, AlexNet mimarisine göre 50 kat daha az parametre içermektedir. Diğer yandan, GoogleNet ve Inceptionv3 mimarileri, Inception modülü ile birlikte farklı boyutlarda filtreleme işlemlerini içermektedir (Şekil 5a). Xception, standart konvolüsyonlarla değiştirildiği Inception mimarisinin bir uzantısıdır. Buna ek olarak, ResNet18 mimarisi ise atık (residual) modellerden oluşmaktadır (Şekil 5b). Bu mimarilerin genel olarak karakteristikleri Tablo 1'de detaylandırılmıştır.



Şekil 4. AlexNet mimarisi (Kaynak: Yazarlar tarafından üretilmiştir)

Figure 4. Alexnet architecture



Şekil 5. Derin Mimariler, a) Inception modülü, b) Atık modülü (Kaynak: Yazarlar tarafından üretilmiştir)

Figure 5. Deep architectures, a) Inception module, b) Residual module

Tablo 1. Derin mimarilerin karakteristikleri  
Table 1. Characteristics of deep architectures

Algoritmalar	Derinlik	Boyut	Parametre (Milyon)	Görüntü giriş boyutu
AlexNet (Krizhevsky ve ark., 2012)	8	227	61	227x227
VGG16 (Simonyan ve Zisserman, 2014)	16	515	138	224x224
VGG19 (Simonyan ve Zisserman, 2014)	19	535	144	224x224
SqueezeNet (Landola ve ark., 2016)	18	4,6	1,24	227x227
GoogleNet (Szegedy ve ark., 2015)	22	27	7,0	224x224
Inceptionv3 (Szegedy ve ark., 2016)	48	89	23,9	299x299
ResNet18 (He ve ark., 2016)	18	44	11,7	224x224
Xception (Chollet, 2017)	71	85	22,9	299x299



Bu çalışmada kullanılan önceden eğitilmiş ESA mimarilerinin eğitimi için epoch değeri 10, batch boyutu 7 ve öğrenme katsayısı  $1 \times 10^{-4}$  olarak belirlenmiştir. Buna ek olarak, stokastik dereceli alçalma yöntemi (SGA) optimizasyon yöntemi kullanılmıştır. Eğitim aşaması 940 iterasyondan sonra sona ermiştir.

## Sonuçlar ve Tartışma

Deneyel çalışmalarda, donanımsal olarak NIDIA Quadro P4000 GPU kartı, 32 GB Ram ve Intel Xeon Silver 2.19 GHz ile donatılmış bir bilgisayar kullanılmıştır. Yazılımsal olarak ise MATLAB (R2019a) platformu kullanılarak deneysel çalışmalar gerçekleştirilmiştir.

Bu çalışmada kullanılan ESA mimarilerinin performanslarını ölçmek için doğruluk, duyarlılık, kesinlik ve F1-skor kullanılmıştır. Bu istatistiksel değerlerin hesaplanması Denklem 3-7'de gösterilmiştir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (5)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (6)$$

$$\text{F1-Skor} = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$

Denklem 3-7'de, DP, DN, YP ve YN değerleri sırasıyla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif olarak ifade edilir.

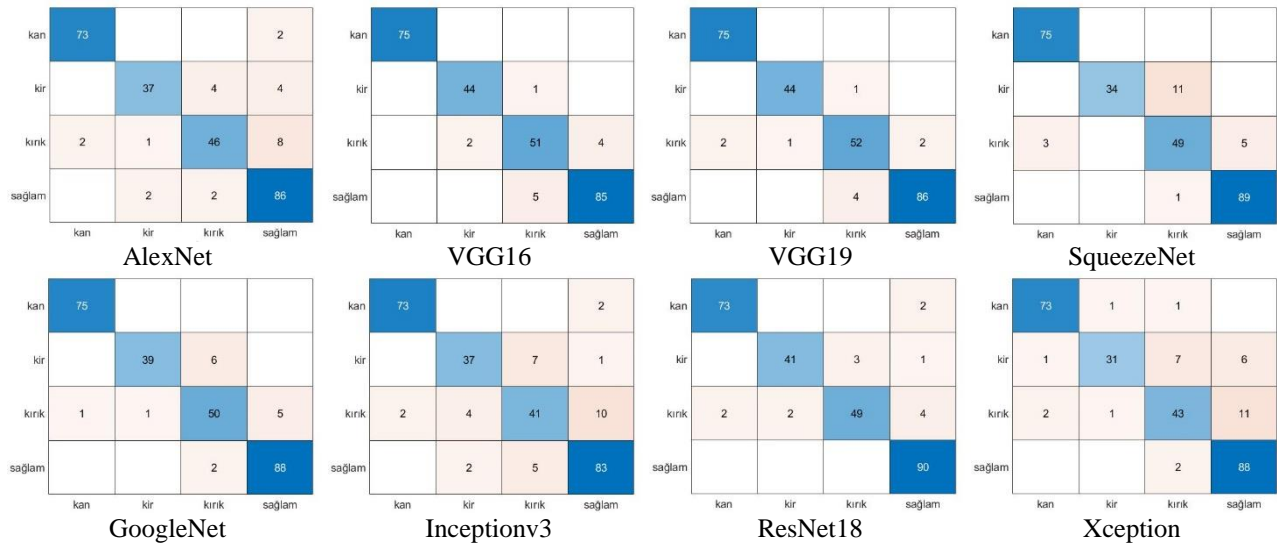
## Bulgular

Bu çalışmada, kusurlu yumurtaların sınıflandırılması için 8 önceden eğitilmiş derin mimari kullanılmıştır. Gerçekleştirilen bu çalışmalarda, derin mimarilerin karışıklık matrisleri Şekil 6'da verilmiştir.

Şekil 6'da kanlı, kirli, kırık ve sağlam yumurtaların sınıflandırılması için kullanılan ESA mimarilerinin karmaşıklık matrisleri verilmiştir. Şekil 6'dan anlaşılacağı üzere, yumurta türlerinden sağlam yumurtayı tanıma başarımı ResNet18 mimarisi ile %100 olarak elde edilmiştir. Bunun yanı sıra, VGG16, VGG19, SqueezeNet ve GoogleNet mimarileri kullanılarak kanlı yumurtayı %100 tanıma başarımı elde edilmiştir. Bu karışıklık matrisine bağlı olarak, bu derin mimarilerin performans ölçütleri Tablo 2'de verilmiştir.

Tablo 2'de gösterildiği gibi, kanlı, kirli, kırık ve sağlam yumurtaların sınıflandırılması için en yüksek doğruluk VGG19 mimarisi ile %96,25 olarak elde edilmiştir. Buna ek olarak, en iyi ikinci doğruluk VGG16 mimarisi ile %95,51 olarak elde edilirken, en kötü performans Inceptionv3 mimarisi ile %87,64 olarak hesaplanmıştır. Bu sonuçlara göre, transfer öğrenme yaklaşımına dayalı önceden eğitilmiş derin mimariler, kusurlu yumurtaların tespiti için yüksek bir sınıflandırma doğruluğuna sahip olduğu gözlenmiştir. Öte yandan, bu çalışmada kullanılan derin mimariler farklı karakteristik (katman, bağlantı, filtre türü, vs.) özelliklere sahip olduğundan dolayı sınıflandırma doğrulukları da birbirinden farklıdır. Deneyel çalışmalarda, yüksek sayıda katman ve bağlantı içeren mimarilerin benzer şekilde sınıflandırma performanslarının da yüksek olacağı anlamına gelmeyeceği tespit edilmiştir. Örneğin, ResNet18 mimarisi, VGG16 mimarisinden daha fazla katman ve bağlantıya sahip olmasına rağmen sınıflandırma doğruluğu daha düşüktür.

Kusurlu yumurtaların tespiti için transfer öğrenme yaklaşımına dayalı önceden eğitilmiş derin mimarilerin eğitimi süreleri hesaplanmıştır. Bu sonuçlar Şekil 7'de verilmiştir. Bu sonuçlara göre, AlexNet modeli diğer mimariler arasında en hızlı eğitim süresine (1 dak/27 sn) sahipken, Inceptionv3 mimarisi ise en yavaş eğitim süresine (10 dak) sahiptir. Buna ek olarak, Resnet18, SqueezeNet, GoogleNet, VGG16, VGG19 and Xception mimarilerinin eğitim süreleri sırasıyla, 2 dak/5 sn, 2 dak/30 sn, 3 dak/20 sn, 4 dak/50 sn, 5 dak-39 sn ve 8 dak/27 sn'dir.



Şekil 6. Derin mimarilerin karışıklık matrisleri (Kaynak: Yazarlar tarafından üretilmiştir)

Figure 6. Confusions matrices of deep architectures

Tablo 2. Derin mimarilerin performans ölçütleri (%)

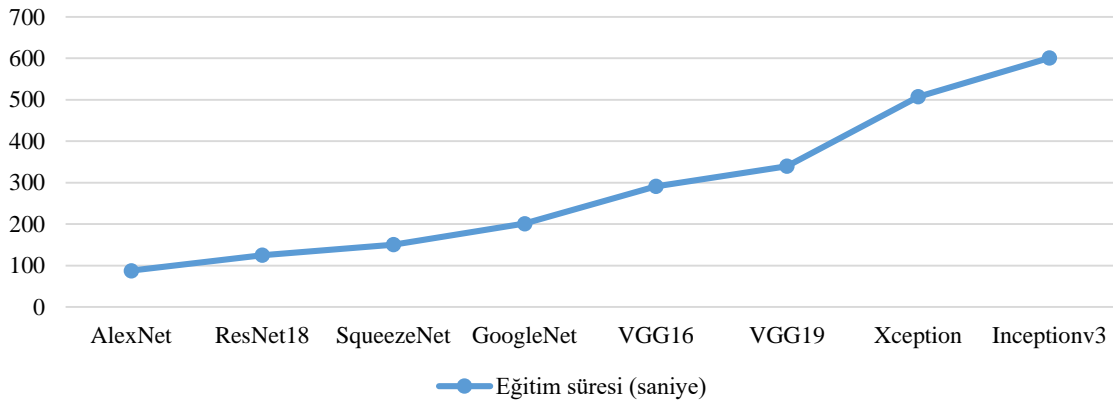
Table 2. Performance measures of deep architectures (%)

Derin Mimariler	Duyarlılık	Özgüllük	Kesinlik	F1-skor	Doğruluk
AlexNet	88,95	96,71	91,07	89,83	90,64
VGG16	95,42	98,50	95,16	95,29	95,51
VGG19	96,14	98,75	96,03	96,08	96,25
SqueezeNet	90,10	97,47	92,79	90,98	92,51
GoogleNet	93,04	98,10	94,25	93,56	94,38
Inceptionv3	85,93	95,80	86,80	86,30	87,64
ResNet18	93,60	98,17	94,92	94,17	94,76
Xception	84,86	95,79	88,73	86,15	88,01

Tablo 3. Mevcut çalışma ile önceki çalışmaların karşılaştırılması

Table 3. Comparison of current study with previous studies

Araştırmacılar	Kullanılan Yöntem		Sınıf Sayısı	Doğruluk Skoru (%)
	Özellik Çıkarma	Sınıflandırma		
Leiçing ve ark. (2007)	Görüntü işleme teknikleri ve geometrik özellikler	Geri yayılım sinir ağı	2 (kırık ve sağlam)	96,8
Öztürk ve Gangal (2014)	Eşikleme ve kenar belirleme algoritmasına		3 (kirlili, kırık ve sağlam)	93
Abbaspour-Gilandeh ve Azizi (2018)	Canny kenar detektörü ve Hough dönüşümü	Doğrusal diskriminant analizi	2 (kırık ve sağlam)	90,1
Wu ve ark. (2018)	Renk bileşenleri ve kenar algoritmaları ile istatistiksel momentler	SVM	2 (kırık ve sağlam)	93
Nasiri ve ark. (2020)	VGG16	Softmax	3 (kanlı, kırık ve sağlam)	94,84
Bu çalışma	ESA mimarileri	Softmax	4 (kanlı, kirlili, kırık ve sağlam)	96,25



Şekil 7. Derin mimarilerin eğitim süreleri (Kaynak: Yazarlar tarafından üretilmiştir)

Figure 7. Training times of deep architectures

### Tartışma

Yumurta yetiştiriciliği endüstrisinde, kusurlu yumurtanın otomatik tespiti, ekonomik ve sağlığa uygunluk açısından önemli bir rol oynamaktadır. Bu nedenle, yumurta yüzeyinde oluşabilecek kusurların otomatik olarak sınıflandırılması oldukça önemli hale gelmiştir. Bu çalışmada, nesne tanıma ve sınıflandırma alanında yaygın olarak kullanılan ESA mimarilerine dayalı yumurta kusurlarının sınıflandırılması gerçekleştirilmiştir. Buna ek olarak, Son zamanlarda kusurlu yumurtaların tanımlanması ve sınıflandırılması için makine öğrenimi ve derin öğrenmeye dayalı olarak çeşitli çalışmalar yapılmıştır. Bu çalışmalar ile önerilen çalışmanın veri sayısı, doğruluk skorları ve kullanılan yöntemler Tablo 3'te verilmiştir.

Tablo 3'te görüleceği üzere, yumurta yüzeyinde oluşabilecek kusurların tanınmasına yönelik önceden yapılan çalışmalarda, genellikle geleneksel makine öğrenmesi yöntemleri kullanılmıştır. Leiçing ve ark. (2007), Öztürk ve Gangal (2014), Abbaspour-Gilandeh ve Azizi (2018) ve Wu ve ark. (2018) çalışmalarında, çeşitli ön-işlem yöntemleri kullanılarak kırık ve kan gibi kusurlar belirginleştirmişlerdir. Daha sonra, geleneksel makine öğrenmesi özellik çıkarıcı ve sınıflandırıcı yöntemleri kullanılarak yumurta türünü belirlemişlerdir. Nasiri ve ark. (2020) çalışmasında ise, kanlı, kırık ve sağlam yumurtalarını sınıflandırmak için önceden eğitilmiş VGG16 mimarisi kullanılmış ve %94.84 doğruluk elde etmişlerdir. Sonuç olarak, derin öğrenme, geleneksel

yöntemlere kıyasla herhangi bir ön-işlem aşamasına ihtiyaç duymadan yüksek sınıflandırma doğruluklarına sahiptir.

Bu çalışmada, ön-işlem aşaması uygulanmaksızın ESA'ya dayalı önceden eğitilmiş derin mimarilerin sınıflandırma performansları değerlendirilmiştir. Önceki çalışmalarda genellikle kırık ve sağlam yumurtalar kullanılmıştır. Bu çalışmada ise kanlı, kirli, kırık ve sağlam yumurtalar kullanılarak kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Deneysel sonuçlarda, kullanılmış olduğumuz sistem ile umut vaat eden performans sonuçları elde edildiği gözlenmiştir.

Son olarak, kusurlu yumurtaların tespiti ile ilgili yapılan önceki çalışmalarda, eğitim süreleri verilmediğinden dolayı, herhangi bir karşılaştırma yapılmamıştır.

## Sonuç

Bu çalışmada, kusurlu yumurtaların tespiti için transfer öğrenme yaklaşımına dayalı ESA mimarilerinin sınıflandırma performansları değerlendirildi. Bu amaç doğrultusunda, AlexNet, VGG16, VGG19, SqueezeNet, GoogleNet, Inceptionv3, ResNet18 ve Xception olmak üzere önceden eğitilmiş ESA mimarileri kullanıldı. Bu ESA mimarilerini, kusurlu yumurta sınıflandırılması probleminde adapte etmek için bu ağların son üç katmanını yerine yeni katmanlar transfer edilerek ince ayar işlemi uygulandı.

Gerçek zamanlı tasarlanan kusurlu yumurta tespit cihazı kullanılarak kanlı, kirli, kırık ve sağlam yumurta görüntülerini içeren bir veri seti elde edilmiştir. Deneysel çalışmalarda, bu veri seti kullanılarak ESA mimarilerinin sınıflandırma performansları hesaplandı. Sonuç olarak, kusurlu ve sağlam yumurtaların sınıflandırılması için en yüksek sınıflandırma doğruluğu, VGG19 mimarisi ile %96.25 olarak elde edilmiştir. Bu sonuçlar, önerilen çalışmanın kanlı, kirli, kırık ve sağlam yumurtaları sınıflandırmak için gıda endüstrisinde kullanılabilceğini göstermiştir.

Gelecek çalışmalarda, kusurlu ve sağlam yumurta görüntü sayıları artırılması ve sınıflandırma performansının yükseltilmesi için farklı özellik çıkarıcı yöntemler ile makine öğrenmesi sınıflandırıcı yöntemlerinin kullanılması planlanmaktadır.

## Teşekkür

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

## Kaynaklar

- Abbaspour-Gilandeh Y, Azizi A. 2018. Identification of Cracks in Eggs Shell Using Computer Vision and Hough Transform. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 28(4), 375-383.
- Altuntaş Y, Cömert Z, Kocamaz AF. 2019. Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach. *Computers and Electronics in Agriculture*, 163, 104874.

- Arivazhagan S, Shebiah RN, Sudharsan H, Kannan RR, Ramesh R. 2013. External and internal defect detection of egg using machine vision. *Journal of Emerging Trends in Computing and Information Sciences*, 4(3), 257-262.
- Başaran E, Cömert Z, Sengur A, Budak Ü, Celik Y, Toğaçar M. 2020. Normal ve Kronik Hastalıklı Orta Kulak İmgelerinin Evrişimsel Sinir Ağları Yöntemiyle Tespit Edilmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 13(1), 1-10.
- Chollet F. 2017. Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- Durmuş İ, Yenice E, Demirtaş ŞE. 2007. Egg abnormality. *Tavukçuluk Araştırma Dergisi*, 7(1), 66-71.
- Guanjun B, Mimi J, Yi X, Shibo C, Qinghua Y. 2019. Cracked egg recognition based on machine vision. *Computers and Electronics in Agriculture*, 158, 159-166.
- He K, Zhang X, Ren S, Sun J. 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Krizhevsky A, Sutskever I, Hinton GE. 2012. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, 1097-1105.
- Landola FN, Han S, Moskewicz MW, Ashraf K, Dally WJ, Keutzer K. 2016. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- Lei Qing P, Kang T, Zipeng S, Jiali Y, Hongwen L. 2007. Crack detection in eggs using computer vision and BP neural network [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 5.
- Nasiri A, Omid M, Taheri-Garavand A. (2020). An automatic sorting system for unwashed eggs using deep learning. *Journal of Food Engineering*, 110036.
- Omid M, Soltani M, Dehrouyeh MH, Mohtasebi SS, Ahmadi H. 2013. An expert egg grading system based on machine vision and artificial intelligence techniques. *Journal of food engineering*, 118(1), 70-77.
- Öztürk N. 2014. Görüntü işleme teknikleri ile beyaz yumurtalar üzerindeki yumurta kabuğu kusurlarının algılanması, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.
- Öztürk N, Gangal A. 2014. Eggshell defects detection on white eggs using image processing techniques. In *2014 22nd Signal Processing and Communications Applications Conference (SIU)* (pp. 810-813). IEEE.
- Patel VC, McClendon RW, Goodrum JW. 1998. Color computer vision and artificial neural networks for the detection of defects in poultry eggs. In *Artificial Intelligence for Biology and Agriculture* (pp. 163-176). Springer, Dordrecht.
- Simonyan K, Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. In *ICLR*.
- Syahir WM, Suryanti A, Ain NN. 2007. Eggs Bloodspot Detection Using Image Processing. In *Second International Conference on Innovative Computing, Information and Control (ICICIC 2007)* (pp. 424-424). IEEE.
- Szegedy C. et al., 2015. Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. 2016. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Turkoglu M. 2019. Görüntü işleme tabanlı bitki türleri ve hastalıkları tanıma. Doktora Tezi, Fen Bilimleri Enstitüsü, İnönü Üniversitesi, Malatya, Türkiye.



- Turkoglu M, Hanbay D. 2019. Plant disease and pest detection using deep learning-based features. *Turkish Journal of Electrical Engineering & Computer Sciences*, 27(3), 1636-1651.
- Turkoglu M. 2020. COVIDetectioNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence*, 1-14.
- Turkoglu M, Hanbay K, Sivrikaya IS, Hanbay D. 2020. Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345.
- Wu L, Wang Q, Jie D, Wang S, Zhu Z, Xiong L. 2018. Detection of crack eggs by image processing and soft-margin support vector machine. *Journal of Computational Methods in Sciences and Engineering*, 18(1), 21-31.