

AYDINLATMA ÖZNETELİĞİ KULLANILARAK EVRİŞİMSEL SİNİR AĞI MODELLERİ İLE MEYVE SINIFLANDIRMA

Birkan BÜYÜKARIKAN * 
Erkan ÜLKER ** 

Alınma: 02.10.2019; düzeltme: 01.01.2020; kabul: 02.03.2020

Öz: Aydınlatma, nesnelerin olduğu gibi görünmesini sağlayan doğal veya yapay kaynaklardır. Özellikle görüntü işleme uygulamalarında yakalanan görüntüdeki nesne bilgisinin eksiksiz ve doğru şekilde alınabilmesi için aydınlatmanın kullanılması bir gerekliliktir. Ancak aydınlatma kaynağının tür, parlaklık ve konumunun değişimi; nesnenin görüntüsü, rengi, gölgesi veya boyutunun da değişmesine ve nesnenin farklı olarak algılanmasına sebep olmaktadır. Bu sebeple görüntülerin ayırt edilmesinde güçlü bir yapay zeka tekniğinin kullanılması, sınıfların ayırt edilmesini kolaylaştıracaktır. Bir yapay zeka yöntemi olan Evrişimsel Sinir Ağları (ESA), otomatik olarak özellikleri çıkarabilen ve ağ eğitilirken öğrenme sağlandığı için bariz özellikleri kolaylıkla belirleyen bir algoritmadır. Çalışmada ALOI-COL veriseti kullanılmıştır. ALOI-COL, 12 farklı renk sıcaklığıyla elde edilmiş 1000 sınıftan oluşan bir verisetidir. ALOI-COL verisetindeki 29 sınıftan oluşan meyve görüntüleri, ESA mimarilerinden AlexNet, VGG16 ve VGG19 kullanılarak sınıflandırılmıştır. Verisetindeki görüntüler, görüntü işleme teknikleriyle zenginleştirilmiş ve her sınıftan 51 adet görüntü elde edilmiştir. Çalışma; %80-20 ve %60-40 eğitim-test olmak üzere iki yapıda incelenmiştir. 50 devir çalıştırılması sonucunda test verileri, AlexNet (%80-20) ve VGG16 (%60-40) mimarilerinde %100, VGG19 (%80-20) mimarisinde ise %86,49 doğrulukla sınıflandırılmıştır.

Anahtar Kelimeler: Aydınlatma, Derin Öğrenme Mimarileri, Görüntü İşleme, Meyve Sınıflandırma, Evrişimsel Sinir Ağları

Fruit Classification with Convolution Neural Network Models using Illumination Attribute

Abstract: Illumination is a natural or artificial source and it allows objects to be seen. Especially use of illumination for necessary in image processing applications for correct and complete object information captured from images. However type, brightness and position of lighting source change, it also changes the image, color, shadow or size of the object and it causes to appear differently on the object. Therefore, the use of a strong artificial intelligence technique to distinguish images will ease the differentiation of classes. Convolutional Neural Networks (CNN), an artificial intelligence method, is an algorithm that can automatically extract features and easily identify obvious features as learning is provided while training network. In the study ALOI-COL dataset used. ALOI-COL consists of 1000 classes such as food and toys obtained with 12 different color temperatures. Fruit images of 29 classes in the dataset were classified using the CNN architectures AlexNet, VGG16 and VGG19. The images in the dataset were increased with image processing techniques and 51 images of each class created. The study 80-20% and 60-40% training-test examined in two structures. As a result of 50 epochs in the test data classified accuracy as 100% by using AlexNet (80-20%) and VGG16 (60-40%) architectures and 86.49% in VGG19 (80-20%) architecture.

* Selçuk Üniversitesi, Sarayönü Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, 42430, Sarayönü, Konya

** Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, 42250, Konya

İletişim Yazarı: Birkan Büyükarıkan (birkan@selseuk.edu.tr)

Keywords: Illumination, Deep Learning Architecture, Image Processing, Fruit Classification, Convolutional Neural Networks

1. GİRİŞ

Gerçek dünyada nesnelere görüntülenirken yaşanan problemlerden biri, nesnenin görünümünün bir görüntüden diğer bir görüntüye göre değişimidir (Jacobs ve diğ. 1998). Nesneyi çevreleyen ışık kaynaklarının açılma ve spektral dağılımının etkisi, görüntünün farklı olarak algılanmasıyla birlikte (Mindru ve diğ., 2004; Jehle ve diğ., 2010) nesnenin gölgesi, şekli ve kullanılan sahnenin de değişmesine sebep olmaktadır (Braje ve diğ., 1998). Bu sebeple değişen aydınlatma koşullarındaki nesnelere etkili bir şekilde tanınması, bilgisayarlı görüntü uygulamalarında çözülmesi gereken önemli problemlerden birini oluşturmaktadır (Ijjina ve Mohan, 2014).

Bilgisayarlı görüntü uygulamalarında yüksek kontrast ve homojen olarak ışığın dağılmasıyla nesnenin görselleştirilmesi sağlanmaktadır (Jähne ve Haußecker, 2000). Görüntü alımı sırasında aydınlatmanın değişimi az olsa bile kaynak ile hedef görüntü arasında büyük farklılıklar oluşabilir. Bu durum görüntü sınıflarının ayırt edilmesini zorlaştırmaktadır (Brodatz, 1966; Phillips ve diğ., 2009; Vageeswaran ve diğ., 2012). Ancak güçlü bir yapay zeka tekniğinin kullanılmasıyla görüntülerin sınıflandırılması kolaylaşacaktır.

Yapay zekanın alt dallarından biri olan derin öğrenme, birçok ileri beslemeli sinir ağlarının eğitim sürecini içeren adımlardan oluşmaktadır. Donanımdaki gelişmeler ve Yapay Sinir Ağının paralel olarak artan katman sayısı ile derin öğrenme mimarileri oluşturulmuş ve daha karmaşık problemlerin çözümünde yer almıştır (Tümen ve diğ., 2017; Yiğit, 2017). Derin öğrenme mimarilerinden ESA tabanlı mimarilerin, geleneksel yöntemlere göre görüntüleri daha iyi sınıflandırdığı ve aydınlatma karmaşıklıklarının da üstesinden geldiği tespit edilmiştir (Cusano ve diğ., 2016a). ESA'nın ağ yapısındaki evrişim (konvolüsyon) işlemi ile eğitim verilerindeki özellikler otomatik olarak çıkartılmakta ve daha sonraki katmanlara bu çıkartılan özellikler gönderilmektedir. Böylece belirgin olan özellikler ortaya çıkarılmaktadır (Doğan ve Türkoğlu, 2018). Dolayısıyla aydınlatma farklılıklarını içeren görüntülerde, ESA mimarilerinin kullanılmasıyla görüntü sınıflandırma problemlerine çözüm sağlanabilir.

Literatürde, aydınlatma özneliğiyle gıda ve tarım sektörlerinde, klasik yapay zeka ve ESA mimarileri kullanılarak nesnelere tanınması ve sınıflandırılmasıyla ilgili birçok çalışma bulunmaktadır. Bu çalışmalarda kullanılan görüntü verisetleri açık olduğu gibi farklı aydınlatma koşulları kullanılarak da görüntüler elde edilmiştir. Literatürdeki çalışmalar iki başlık altında incelenmiştir.

1.1. Klasik Yapay Zeka Yöntemleri Kullanılarak Yapılan Çalışmalar

Rocha ve diğ. (2010), farklı aydınlatma koşullarındaki meyve ve sebze görüntülerini otomatik olarak sınıflandırmak için makine öğrenmesi algoritmalarını kullanmışlardır. Görüntülerin arka planlarının çıkartılarak elde ettikleri görüntü özelliklerinin eğitilmesi sonucunda, ortalama hatanın %15'lere kadar düştüğünü belirtmişlerdir. Lü ve Tang (2012), kivi meyvesindeki gizli morlukları tespit etmek için hiperspektral görüntüleme sistemi kullanmışlardır. Spektral dalga boyutunu azaltmak için Temel Bileşenler Analizi (Principle Component Analysis- PCA) kullanmışlar ve bir görüntü işleme algoritması ile sınıflandırmışlardır. Kivi meyvesindeki gizli morlukların tespit hatasının %14,5 olduğunu belirtmişlerdir. Wang ve diğ. (2015), 18 kategoriden oluşan 1653 meyve görüntüsünden elde ettikleri 12 özelliği kullanarak makine öğrenmesi yöntemleri ile sınıflandırmışlardır. PCA, Uygunluk Ölçeğinde Kaotik Yapay Arı Kolonisi (Fitness-Scaled Chaotic Artificial Bee Colony - FSCABC) ve İleri Beslemeli Sinir Ağı (Feedforward Neural Network - FNN) yöntemlerinin beraber kullanılması sonucunda %89,1 ile en yüksek başarıyı elde etmişlerdir. Jana ve diğ. (2017), değişen aydınlatma koşulları altında meyvelerin hasat edilirken türlerine göre

sınıflandırılması için bir yöntem önermişlerdir. Meyve görüntülerinin arka planları çıkartılarak Gri Seviye Eş Oluşum Matrisi (Grey Level Co-Occurrence Matrix - GLCM) yöntemi ile görüntülerin doku ve istatistiksel renk özelliklerini elde etmişlerdir. Elde edilen özellikleri Destek Vektör Makineleri (Support Vector Machines - SVM) ile sınıflandırmışlardır. Test sonuçlarına göre; sekiz meyve içerisinde elma, portakal ve ananasın daha yüksek doğrulukla sınıflandırıldığını belirtmişlerdir.

1.2. ESA Mimarileri Kullanılarak Yapılan Çalışmalar

Ijjina ve Mohan (2014), çalışmalarında ALOI-COL verisetindeki meyve ve sebzeleri sınıflandırmak için 3 boyutlu renk histogramına göre ESA, SVM ve k-En Yakın Komşuluk (K-Nearest Neighbor – kNN) yöntemlerini kullanmışlardır. ESA mimari, giriş görüntüsü 20x20 boyutunda, 2 evrişim ve 2 havuzlama katmanlarından oluşturulmuştur. Oluşturdukları ESA mimarisi ile meyveleri %98,53, sebzeleri ise %99,26 doğruluk ile sınıflandırmışlardır. Pouladzadeh ve diğ. (2015), değişen aydınlatma ve farklı kameralardan alınan yemek görüntüleri üzerinde renk doku segmentasyonu, graf kesim segmentasyonu ve derin öğrenme algoritmalarını kullanarak yemek tanıma sistemi yapmışlardır. Buna göre; derin öğrenme algoritması ile yemekleri %100 doğrulukla tanımışlardır. Cusano ve diğ. (2016a), Raw Food Texture verisetiyle farklı aydınlatma koşullarında görüntülerin doku özelliklerinin nasıl etkilendiğini belirlemek için ESA mimarilerini kullanmışlardır. ESA mimarilerinden Vgg VeryDeep 16 mimarisinin diğer mimarilere göre çoğunlukla yüksek başarı elde ettiklerini belirtmişlerdir. Cusano ve diğ. (2016b), Raw Food Texture verisetindeki görüntüleri kullanarak farklı renk tanımlayıcıları ile kombinasyonlu ve kombinasyonsuz görüntüler elde etmişler ve ESA ile görüntüleri sınıflandırmışlardır. Çalışma sonuçlarına göre; kombinasyonlu renk tanımlayıcıları ile oluşturulan görüntülerde daha başarılı sınıflandırma yaptıklarını belirtmişlerdir. Sa ve diğ. (2016), açık alanda kullanılmak üzere oluşturdukları tarımsal amaçlı bir robot ve ESA mimarisiyle daldaki meyveleri belirlemeye çalışmışlardır. Çalışmada yedi farklı meyve çeşidi kullanmışlar ve daldaki meyveleri %83 oranındaki doğrulukla tespit etmişlerdir. Bianco ve diğ. (2017), Raw Food Texture verisetindeki görüntülerle çalışmış, farklı renk dengeleme modelleri ile ESA mimarilerini (AlexNet, VGG16, VGG19 vd.) kullanarak gıda ürünlerini sınıflandırmışlardır. Renk dengeleme modellerinden Rooted-Srgb ve ESA mimarilerinden ResNet-50 ile gıda ürünlerini sınıflandırırken diğer yöntemlere göre daha başarılı olduklarını belirtmişlerdir. Zhang ve diğ. (2018), bir buzdolabında farklı kamera açısı ve aydınlatma koşullarıyla ESA mimarilerinden ResNet, VGG16, VGG19 ve bu mimarilerin birleştirilmesinden elde edilen özellikleri kullanılarak geri yayımlı sinir ağı ile meyveleri tanıma sistemi yapmışlardır. ResNet’de %91, VGG16’da %89, VGG19’da %90 ve mimarilerin birleştirilmesi ile oluşturulan mimaride ise %97 doğrulukla başarı elde ettiklerini belirtmişlerdir. Steinbrener ve diğ. (2019), farklı renk sıcaklığı ve parlaklıklarda oluşturulan hiperspektral meyve ve sebze görüntülerini ESA ile sınıflandırmışlardır. GoogleNet’in ağırlıkları kullanılarak görüntülerin test edilmesi sonucunda ortalama %88,15 ve mimari üzerindeki değişikliklerle ortalama %92,23 başarıyla sınıflandırma yaptıklarını belirtmişlerdir.


Literatür incelendiğinde, geleneksel yapay zeka yöntemleri ile nesnelerin tanınması ve sınıflandırılması çalışmalarında başarı oranlarının nispeten ESA mimarilerine göre düşük olmasıyla ESA’nın aydınlatmadan kaynaklı problemlerin çözülmesinde önemli bir rol oynayacağı görülmüştür ve bu makale kapsamındaki çalışma gerçekleştirilmiştir.

Bu bağlamda, aydınlatma koşullarının görüntü sınıflandırmadaki etkisini belirlemek amacıyla, 12 farklı renk sıcaklığında oluşturulmuş ALOI-COL verisetindeki (Geusebroek ve diğ., 2005) meyve görüntüleri kullanılmıştır. Genellikle derin öğrenme algoritmalarında, çok sayıda veri ile çalışılmaktadır. Bu yüzden ALOI-COL verisetindeki 29 sınıf ve 12 adet görüntüden oluşan meyve görüntülerinin sayısını zenginleştirmek için renk dengeleme, histogram eşitleme gibi renk parlaklık değerine etki eden yöntemlere ek olarak görüntü döndürme, kırpma, hareket ve gürültü ekleme işlemleri de kullanılmıştır. Elde edilen 1479

görüntü ESA mimarilerinden AlexNet, VGG16 ve VGG19 ile sınıflandırılmış ve bu mimarilerin başarı durumları karşılaştırılmıştır.

2. EVRİŞİMSEL SİNİR AĞLARI

ESA, görüntü ve örüntü tanıma işlemlerinde yaygın olarak kullanılan bir derin öğrenme yöntemidir (Liu ve diğ., 2015b). ESA, ileri beslemeli bir ağ yapısına sahip olan ve eğitilebilen Çok Katmanlı Algılayıcıların (Multi Layer Perceptron - MLP) bir türüdür. Bu yöntem insanların görme merkezinden ilham alınarak modellenmiştir (Hubel ve Wiesel, 1968; LeCun ve diğ., 1998). ESA’da görüntüye ait piksel değerleri tensör adı verilen çok boyutlu bir matris yapısına sahiptir ve bunlar girdi olarak kullanılmaktadır. ESA’da giriş katmanındaki nöronların sayısı görüntünün renk kanal (gri tonlama bir ve renkli görüntü üç) sayısına bağlı olarak değişmektedir (Yiğit, 2017). ESA mimarileri oluşturulurken katmanlar birbirleri ardına eklenmektedir. Evrişim, aktivasyon, havuzlama, tam bağlı, seyreltme (dropout) ve sınıflandırma katmanları kullanılarak oluşan ESA’nın yapısı Şekil 1’de görülmektedir.



Şekil 1:

ESA mimarilerinde kullanılan katmanlar ve katmanlar arasındaki bağlantılar

2.1. Evrişimsel Sinir Ağı Yapısı


2.1.1. Evrişim katmanı

ESA’nın temelini oluşturan ve giriş görüntüsünün uzamsal yapılarını dikkate alan katmandır (Çağlayan, 2018). Görüntü matrisi üzerinde sol üst kenardan başlanarak sağ alt noktaya doğru giden ve 3x3, 5x5, 7x7, 9x9, 11x11 boyutundaki bir filtre ile kaydırma yapılarak evrişim işlemi oluşturulmaktadır. Görüntü üzerinde dolaşan bu filtreler ile görüntüdeki özellikler belirginleşmektedir. Diğer bir deyişle, görüntünün belirli parçalarının bulunduğu belirgin özellikler çıkartılmaktadır. Evrişim işlemi sonucunda özellik haritası oluşmuş olur (Liu ve diğ., 2015a). Bu katman, matematiksel olarak Denklem 1’deki gibi ifade edilmektedir (Çağlayan, 2018).

$$h_{l+1} = f(W_l * h_l + b_l) \quad (1)$$

2.1.3. Havuzlama katmanı

Özellik çıkarım aşamasındaki evrişim katmanında oluşan filtreleme işlemi sonrasındaki katman, havuzlama katmanıdır (Castelluccio ve diğ., 2015). Burada özellik haritasından oluşan bilgilerin özeti çıkarılarak; uzamsal boyutu, parametre sayısı ve modelin ezberleme (overfitting) durumunun azaltılması sağlanmış olur (Goodfellow ve diğ., 2016). Özetlenen bilgiler ile parametre sayısı azaldığı için hesaplama verimliliği artar (Jarrett ve diğ., 2009). $N \times N$ boyutundaki matris, görüntü üzerinden kaydırılarak görüntü matrisi içerisinde yer alan en büyük veya ortalama değer alınarak yeni bir matris oluşturulur (Doğan ve Türkoğlu, 2018). Buradaki N değeri, görüntünün büyüklüğüne göre 2 ile 5 değerleri arasında seçilmektedir. Şekil 4'te havuzlama örneği görülmektedir (Scherer ve diğ., 2010).



Şekil 4:
Maksimum havuzlama örneği

2.1.4. Tam bağlı katman


Kendinden önce gelen katmandaki verilerin tek boyutlu bir matris haline getirildiği katmandır. Her nöron kendinden sonraki nörona bağlanır (Adler ve diğ., 2016). Bu katman, sınıflandırma katmanına giden son özellikleri seçmektedir (Uçar ve Bingöl, 2018).

2.1.5. Sınıflandırma katmanı

Tam bağlı katmandan sonra gelen ve sınıflandırma işlemini sınıflandırıcılar yardımıyla elde eden katmandır. Genellikle softmax sınıflandırıcısı kullanılmaktadır ve bu sınıflandırıcı 0 ile 1 arasındaki değerlere göre ağırlığın tahmin ettiği nesnenin, hangi sınıfa daha yakın olduğunu belirlemektedir (İnik ve Ülker, 2017).

2.1.6. Seyreltme katmanı

Ezberlemeyi ortadan kaldırmak için, sinir ağı içerisinde bazı ağ bağlantılarının ortadan kaldırılmasında seyreltme katmanı kullanılmaktadır. Böylece ağı ezberleme yapması önlenerek performansın artması sağlanmaktadır (Hinton ve diğ., 2012; Xiao ve diğ., 2016). Şekil 5'te ağ yapısı ve seyreltme katmanından sonraki yeni ağ yapısı görülmektedir.




Şekil 5:
Seyreltme katmanı
a. Ağ yapısı **b.** Seyreltme'den sonraki ağ yapısı

2.2. Evrimsel Sinir Ağları Mimarileri

2.2.1. AlexNet mimarisi

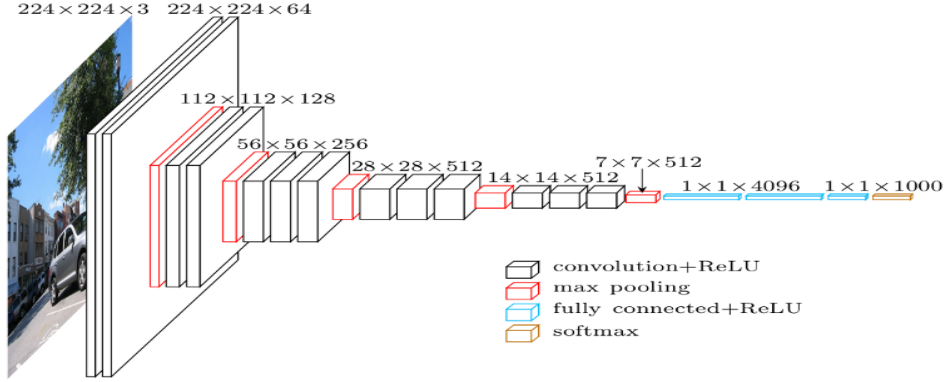
Krizhevsky ve diğ., (2012) tarafından oluşturulan derin öğrenme mimarisidir ve 25 katmandan oluşmaktadır. Bir giriş, beş evrişim, üç havuzlama, iki seyreltme, üç tam bağlı, yedi ReLU, iki normalizasyon ve sınıflandırma katmanlarını içermektedir. Giriş katmanı görüntüsü $227 \times 227 \times 3$ boyutundadır (Doğan ve Türkoğlu, 2018). Aktivasyon fonksiyonu olarak ReLU ve havuzlama katmanında ise maksimum havuzlama yöntemi kullanılmaktadır (Krizhevsky ve diğ., 2012). Şekil 6'da AlexNet mimarisi gösterilmiştir (Kızrak, 2018).



Şekil 6:
AlexNet ağ yapısı <(Kızrak, 2018)>

2.2.2. VGG16 mimarisi

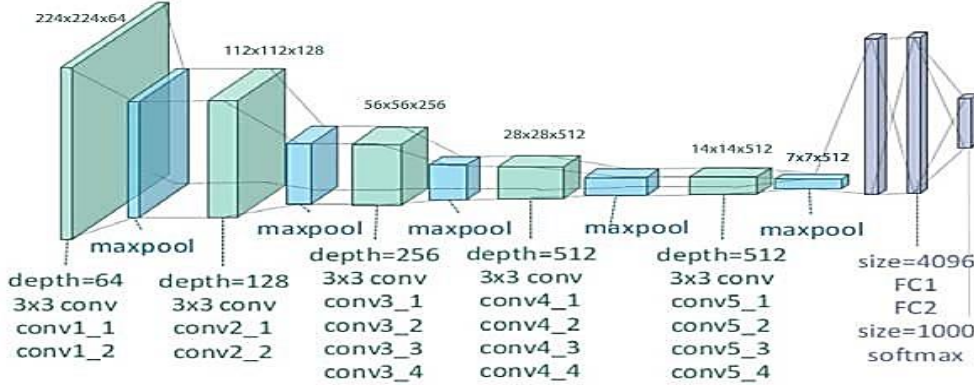
2014 yılında Oxford Üniversitesi Görsel Geometri Grubu tarafından oluşturulan ve on üç evrişim, üç tam bağlı ve diğer katmanların birleştirilmesiyle toplam 41 adet katman bulunmaktadır. Giriş katmanı görüntüsü $224 \times 224 \times 3$ boyutundadır (Simonyan ve Zisserman 2014; Chen ve diğ., 2017). Şekil 7'de VGG16 mimarisinin yapısı verilmiştir (Frossard, 2016).



Şekil 7:
VGG16 ağ yapısı <(Frossard, 2016)>

2.2.3. VGG19 mimarisi

2014 yılında Oxford Üniversitesi Görsel Geometri Grubu tarafından oluşturulan ve on altı evrişim, üç tam bağlı ve diğer katmanlarla birlikte toplam 47 adet katman bulunmaktadır. Giriş katmanı görüntüsü 224x224x3 boyutundadır. (Simonyan ve Zisserman, 2014; He ve diğ., 2016). Şekil 8’de VGG19 mimarisinin katman yapıları görülmektedir (Zheng ve diğ., 2018).



Şekil 8:
VGG19 ağ yapısı <(Zheng ve diğ., 2018)>

3. ARAŞTIRMA BULGULARI

3.1. Veriseti

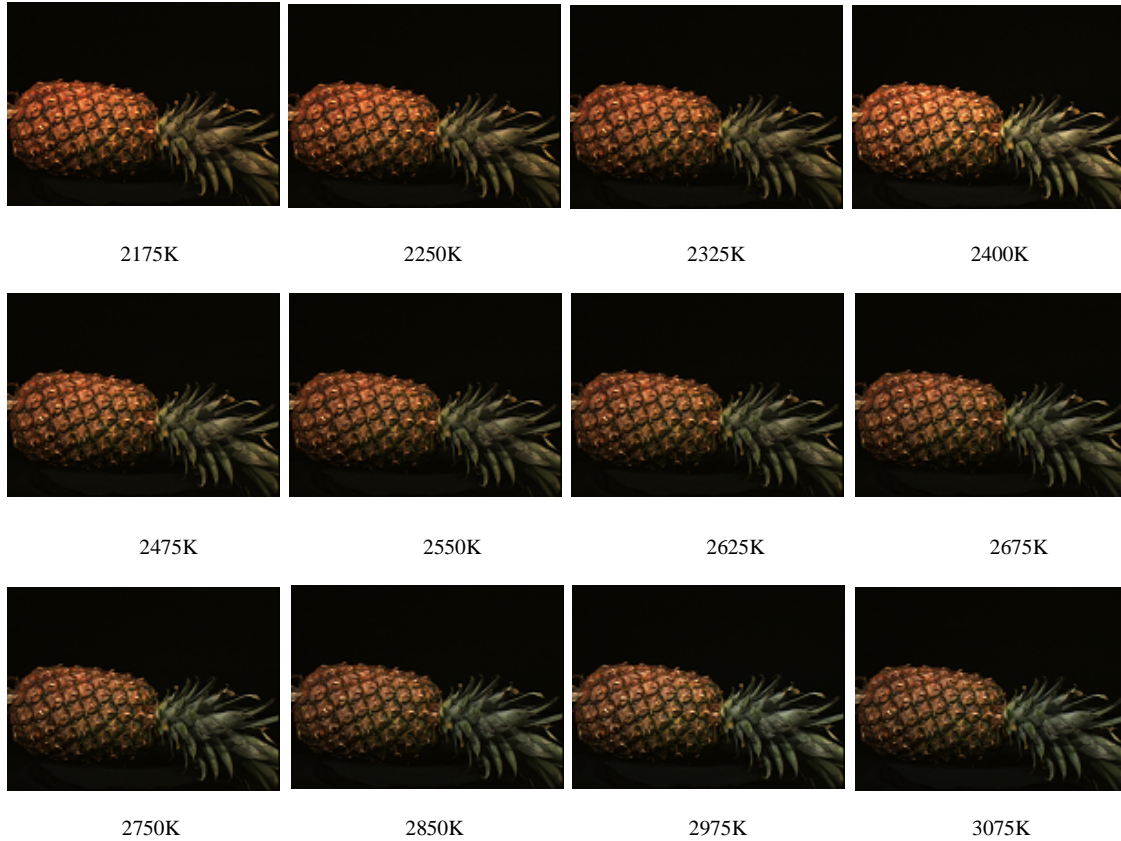
ALOI-COL veriseti; 2175 ile 3075 Kelvin arasındaki 12 farklı renk sıcaklığında alınmış nesnelerin ön profil görüntülerinden oluşmaktadır. Verisetinde oyuncak, giyecek, çeşitli araç-gereç, meyve ve sebze gibi görüntülerin olduğu 1000 adet nesne sınıfı mevcuttur (Geusebroek ve diğ., 2005). Çalışmada ALOI-COL verisetindeki 29 sınıftan oluşan meyve görüntüleri kullanılmıştır.

ALOI-COL verisetindeki meyve görüntülerinin sırası, bulunduğu sınıflar ve sınıftaki meyve adları (ALOI, 2004) Tablo 1’de verilmiştir.

Tablo 1. ALOI-COL veriseti meyve sınıfları ve adları

Nesne sırası – Sınıf - Meyve Adı	Nesne sırası – Sınıf -Meyve Adı	Nesne sırası – Sınıf -Meyve Adı
0- 3- Kayısı	10- 651- Limon	20- 721- Armut
1- 52- Rambutan	11- 705- Yeşil Biber	21- 722- Limon
2- 69- Domates	12- 706- Kırmızı Biber	22- 870- Ananas
3- 82- Elma	13- 707- Mango	23- 873- Mango
4- 102- Kivi	14- 708- Kivi	24- 879- Salatalık
5- 273- Limon 2	15- 710- Elma	25- 882- Siyah Kabak
6- 446- Portakal	16- 712- Mandalina	26- 888- Kavun
7- 567- Armut	17- 713- Limon	27- 947- Çeri Domates
8- 649- Elma	18- 715- Bilinmeyen Meyve	28- 950- Muz
9- 650- Kivi	19- 716- Bilinmeyen Meyve 2	

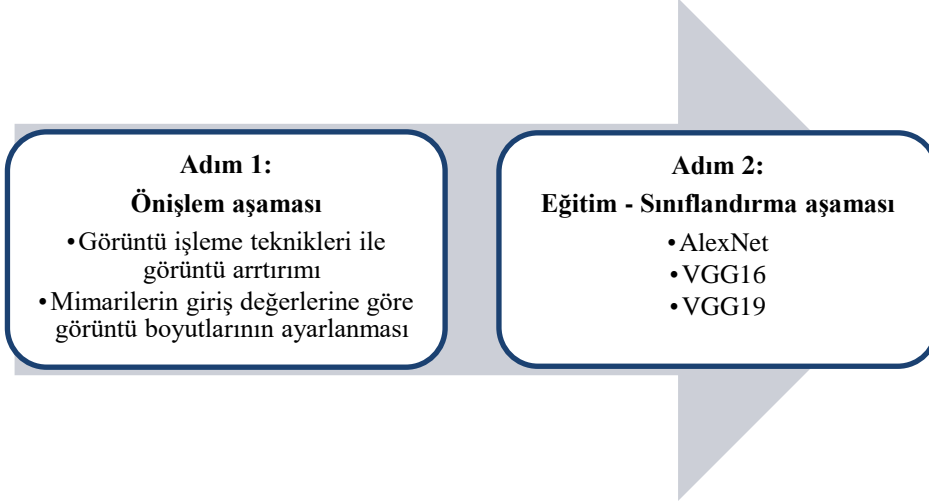
Şekil 9’da farklı renk sıcaklığında alınmış 870. sınıfa ait ananas meyvesinin görüntüleri görülmektedir. Verisetindeki tüm meyvelerin görüntüleri 768 x 576 boyutundadır.



Şekil 9:
ALOI-COL veri setinden seçilmiş bir meyve için farklı renk sıcaklığındaki görüntüleri (K:Kelvin)

3.2. Geliştirilen Uygulama

ESA mimarileri ile meyve görüntülerinin sınıflandırılması için oluşturulan işlem süreci Şekil 10’da verilmiştir. Bu süreç; önışlem ve eğitim-sınıflandırma aşaması olmak üzere 2 adımdan oluşmaktadır.



Şekil 10:

Geliştirilen uygulamanın işlem süreci

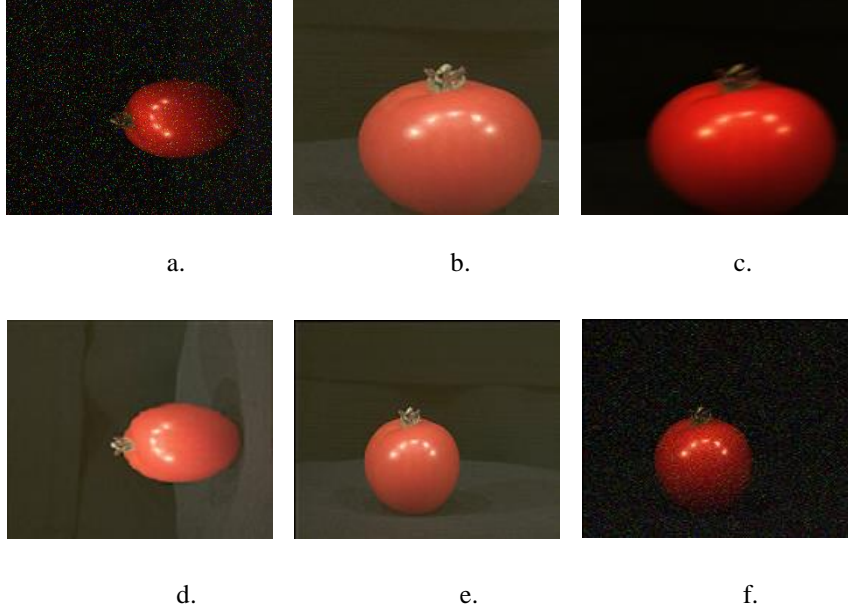
Nesne tanıma uygulamalarında farklı aydınlatma koşullarının, sistemlerin performansını önemli derecede etkilediği görülmektedir. Bu yüzden geniş aydınlatma varyasyonları altında nesnelere görüntüleri alınarak büyük bir veri seti oluşturulması gerekmektedir (Zhu ve diğ., 2017). Eğer eğitim ve test verileri değişen aydınlatma koşullarına sahip olursa, uygulamadaki nesne tanıma performansı da olumlu yönde etkileneceği bir gerçektir (Zhang ve diğ., 2009). Ayrıca verilerin artırılması ile ağır ezberlenmesi de önlenebilir.

Derin öğrenme yöntemlerinde, veri sayısının çok ve varyasyonlu olması gerektiği dikkate alınarak önışleme aşamasında; görüntü işleme teknikleri ile ALOI-COL veri setindeki meyve görüntüleri zenginleştirilmiştir. Orijinal veri setinde her sınıfta bulunan 12 görüntüden, rastgele görüntüler seçilmiştir. Her meyve sınıfındaki görüntü sayısı 51’e çıkarılmıştır. Veri zenginleştirme için kullanılan yöntemler Tablo 2’de verilmiştir. Görüntünün parlaklık değerine etki eden yöntemlerle beraber görüntü çeşitliliği için diğer zenginleştirme yöntemleri de kullanılmıştır. Elde edilen veri setinde orijinal görüntülere zenginleştirme yöntemleri uygulandığı gibi zenginleştirilen görüntülerin kombinasyonlu halleri de oluşturulmuştur.

Tablo 2. Kullanılan görüntü artırma yöntemleri

Yöntem
Hareket (motion blur)
Tuz-biber (salt-paper)
Döndürme
Kesme
Kaydırma
Beyaz dengeleme (srgb)
Histogram eşitleme

Zenginleştirme yapılan verisetindeki 69. sınıfa ait domates meyvesi görüntülerinden bazıları Şekil 11’de verilmiştir.



Şekil 11:

ALOI-COL verisetine uygulanan görüntü işleme teknikleri sonucundaki görüntüler a. tuz-biber gürültüsü olan görüntünün 90° döndürülmesi b. sRGB görüntünün belli bir bölümünün kesilmesi c. motion blur uygulanan görüntünün belli bir bölümünün kesilmesi d. sRGB görüntünün 90° döndürülmesi e. sRGB görüntünün kaydırılması f. görüntüye tuz-biber gürültüsünün eklenmesi

ESA’da her mimari farklı giriş görüntü boyutunu kullanmaktadır. Bu yüzden ön işlem aşamasında 768x576 boyutundaki görüntüler, AlexNet mimarisi için 227x227x3, VGG16 ve VGG19 mimarileri için ise 244x224x3 boyutuna ayarlanmıştır.

DeneySEL çalışmalarında iki yapı benimsenmiştir. Eğitim ve sınıflandırma aşamasında; elde edilen görüntüler rastgele olarak %80’i eğitim, %20’si test ve %60’ı eğitim, %40’ı test verisi olarak ayrılmıştır. Sonra ESA mimarileri kullanılarak bu veriler ile hem eğitim hem de sınıflandırma yapılmıştır. Tablo 3’te ESA mimarilerinin eğitim-test aşamasında kullanılan parametrelerin değerleri verilmiştir.

Eğitim verilerinin işlenmesinde Stokastik Gradyan İnişi (Stochastic Gradient Descent - SGD) optimizasyon yöntemi kullanılmıştır. SGD salınımların azaltılmasında tutarlı ve hızlı çözümler üretmektedir. Momentum değeri 0,8, öğrenme oranı ise 0,001 olarak seçilmiştir. ESA, her iterasyonda yığın boyutu kadar veri üzerinde işlem yapmaktadır. Çalışmada yığın boyutu AlexNet için 64, VGG16 ve VGG19 için 32 olarak belirlenmiştir. Burada yığın boyutu değerinin artması işlemlerin artmasına sebep olmaktadır. Bu yüzden katman sayısının arttığı VGG16 ve VGG19 mimarilerinde yığın boyutu düşük olarak seçilmiştir. Her güncelleme işleminden sonra öğrenme oranının belli oranlarda güncellemesi için Ağırlığın Azaltılması (Weight Decay) 1e-6 değerinde değişmektedir. Mimarilerin eğitimi sırasında en uygun ağırlık değerlerini hesaplamak için devir sayısı kullanılmaktadır. Çalışmada devir sayısı 30 ila 50 arasında 10’ar artan şekilde değişmektedir.

Tablo 3. ESA mimarilerinde kullanılan hiper parametre değerleri

Parametre/Model	AlexNet	VGG16	VGG19
Giriş görüntüsü	227x227x3	224x224x3	224x224x3
Optimizasyon yöntemi	SGD	SGD	SGD
Momentum	0,8	0,8	0,8
Öğrenme Oranı	0,001	0,001	0,001
Yığın Boyutu (Batch size)	64	32	32
Ağırlığın Azaltılması	1e-6	1e-6	1e-6
Devir sayısı	30-40-50	30-40-50	30-40-50

3.3. Sınıflandırma Ölçütleri

Sınıflandırma aşamasında; en uygunun ayırt edilmesi, sınıflandırma yönteminin seçilmesi, sınıflar arasında önemliliğin belirlenmesi ve tahminleme gibi kriterlerin bulunabilmesi için ölçütler kullanılmaktadır. Tablo 4'te sınıflandırma performanslarını karşılaştırmak için çalışmada kullanılan ölçütler verilmiştir (Hossin ve Sulaiman, 2015).

Tablo 4. Sınıflandırma ölçütleri

Ölçüt	Formül	Açıklama
Doğruluk (Accuracy)	$\frac{TP + TN}{TP + FP + TN + FN}$	Toplam örnek sayısı üzerindeki doğru tahminler
Duyarlılık (Sensitivity)	$\frac{TP}{TP + FN}$	Doğru sınıflandırılmış pozitiflerin değerini ölçme
Kesinlik (Precision)	$\frac{TP}{TP + FP}$	Pozitif olarak etiketlenen örneklerin pozitif olarak sınıflandırılmış toplam örnek sayısı
F-Skor (F-Score)	$\frac{2*TP}{2*TP + FP + FN}$	Sistemin doğru optimize edilmesi

3.4. Deneysel Sonuçlar

Bu çalışmada ALOI-COL verisetinde farklı renk sıcaklıklarında, 29 sınıftan oluşan meyve görüntüleri, ESA mimarileri kullanarak sınıflandırılmıştır. Ayrıca ESA başarı oranını artırdığı için literatürde de yapıldığı gibi çalışılan görüntü sayısı görüntü işleme teknikleriyle zenginleştirilmiştir.

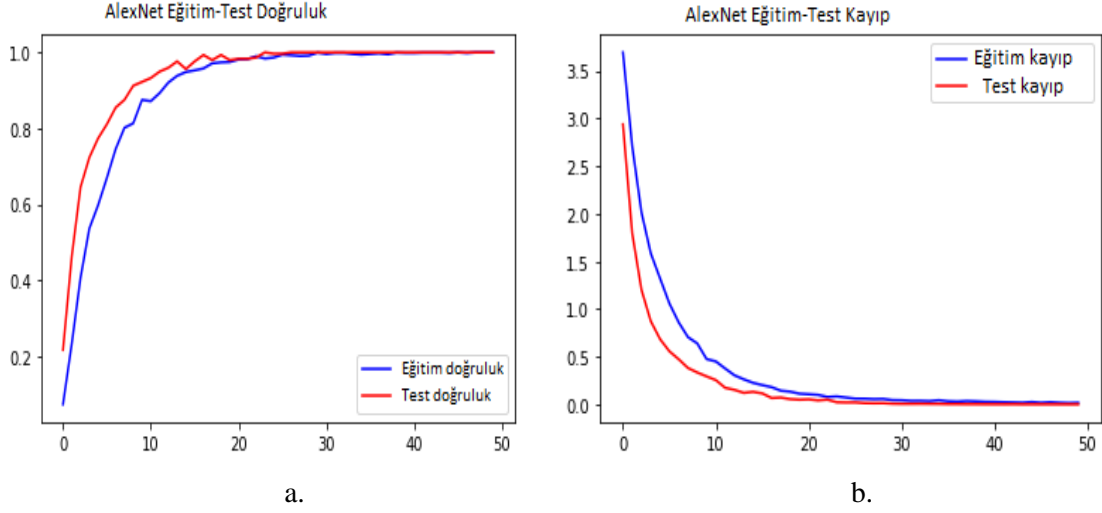
ESA mimarileri, Keras Kütüphanesi ve Python yazılım diliyle oluşturulmuştur. Deneysel çalışmalar için Tesla T4 donanımı ve Google Colaboratory kullanılmıştır. ESA mimarilerine göre eğitim-testteki meyveleri sınıflandırma başarıları ve mimarilerin çalıştırılma süreleri Tablo 5'te sunulmuştur. Mimarilere göre eğitim-test sınıflandırma doğruluk, eğitim-test sınıflandırma kayıp değerleri ve süreleri iyi olan değerler koyu renkte gösterilmiştir. Çalışmada eğitim-test işlemleri için geçen toplam süre saniye olarak verilmiştir.

Tablo 5. Zenginleştirilmiş verisetinde uygulanan ESA mimarileri sonuçları

Mimari	Eğitim-Test	Devir (Epoch)	Eğitim (%)	Eğitim Kayıp	Test (%)	Test Kayıp	Süre (sn)
AlexNet	%80-%20	30	99,41	0,0542	100,00	0,0067	74,202
		40	99,75	0,0215	100,00	0,0024	97,034
		50	100,00	0,0172	100,00	0,0012	119,862
	%60-%40	30	98,65	0,0839	98,99	0,0514	68,049
		40	99,21	0,0496	99,32	0,0248	89,079
		50	100,00	0,0318	99,49	0,0250	110,462
VGG16	%80-%20	30	70,75	1,0572	65,54	1,4813	645,472
		40	100,00	3,8308e-04	98,99	0,0875	878,268
		50	98,73	0,0397	99,32	0,0507	1013,860
	%60-%40	30	20,52	3,3317	13,01	3,3403	918,486
		40	93,01	0,2637	92,91	0,4848	1226,462
		50	100,00	4,9116e-04	100,00	6,8740e-04	1791,413
VGG19	%80-%20	30	10,40	3,3484	7,43	3,3541	765,041
		40	34,83	2,1333	39,53	1,8305	1013,909
		50	83,52	0,6204	86,49	0,4124	1284,461
	%60-%40	30	8,12	3,3632	6,08	3,3679	651,736
		40	13,30	3,3315	9,12	3,3454	869,969
		50	81,40	0,9722	79,90	0,6402	1084,829

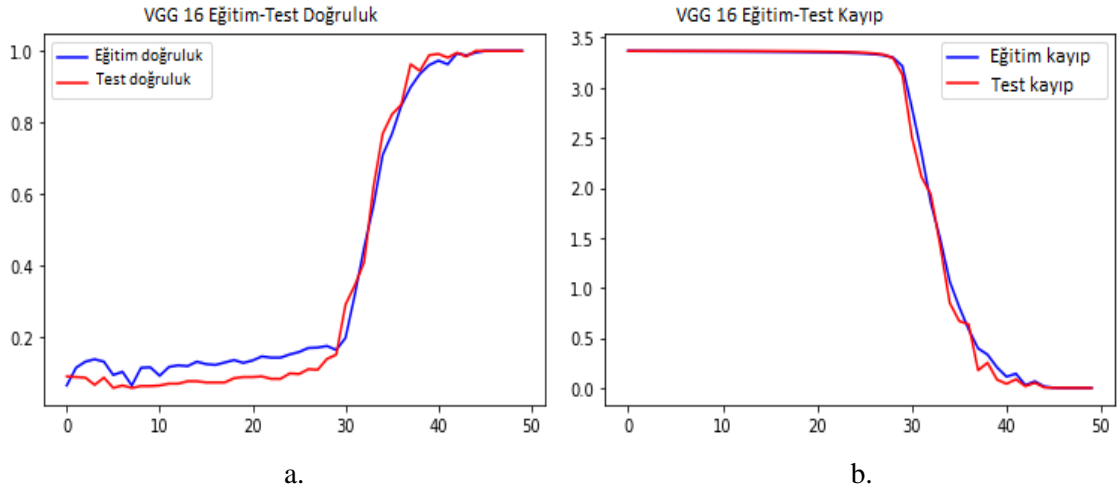
Mimarilerin katman sayıları farklı olmasına rağmen test başarısında çok büyük bir farklılığa neden olmamıştır. Tablo 5'te görüldüğü gibi katman sayısı az olmasına rağmen AlexNet mimarisi, VGG16 mimarisine aynı başarıyı göstermiştir. Ayrıca tüm mimarilerde devir sayısı arttığında sınıflandırma doğruluğunun da arttığı görülmektedir. İşlem süreleri tüm mimarilerde 30 devirde, daha az sürede çalışmıştır. AlexNet mimarisi için verisetinin %60-%40 olarak ayrıldığı yapıda yaklaşık 68 sn'de işlem yapmıştır. VGG16'da verisetinin %80-%20 eğitim-test, 645 sn ve VGG19'da %60-%40 eğitim-test olarak ayrıldığı durumda ise yaklaşık 651 sn'de sonuçları elde etmiştir.

Şekil 12'de AlexNet mimarisine göre; meyvelerin eğitim-test aşamalarındaki doğruluk-kayıp sonuçlarının grafikleri verilmiştir. AlexNet mimarisinde en iyi sonuç, verisetinin %80 eğitim ve %20 test olarak ayrılıp, 50 devir çalıştırılması sonucunda elde edilmiştir. Eğitim-test sınıflandırma doğruluğu %100 olarak bulunmuştur. Kullanılan verisetinde, AlexNet mimarisi diğer mimarilere göre daha hızlı yakınsama yapmaktadır. Eğitim doğruluğunun, 20. devirden sonra %100'e yaklaştığı ve eğitim hatasının da sıfır değerine yakınsadığı görülmektedir. Diğer bir ifadeyle pozitif sınıf gerçek sınıra yaklaşmaktadır. Ayrıca yığın boyutu değerinin diğer mimarilere göre yüksek olması, grafikteki dalgalanmaların azalmasını sağlamıştır.



Şekil 12:
AlexNet mimarisi sonuçları
a. doğruluk grafiği b. kayıp grafiği

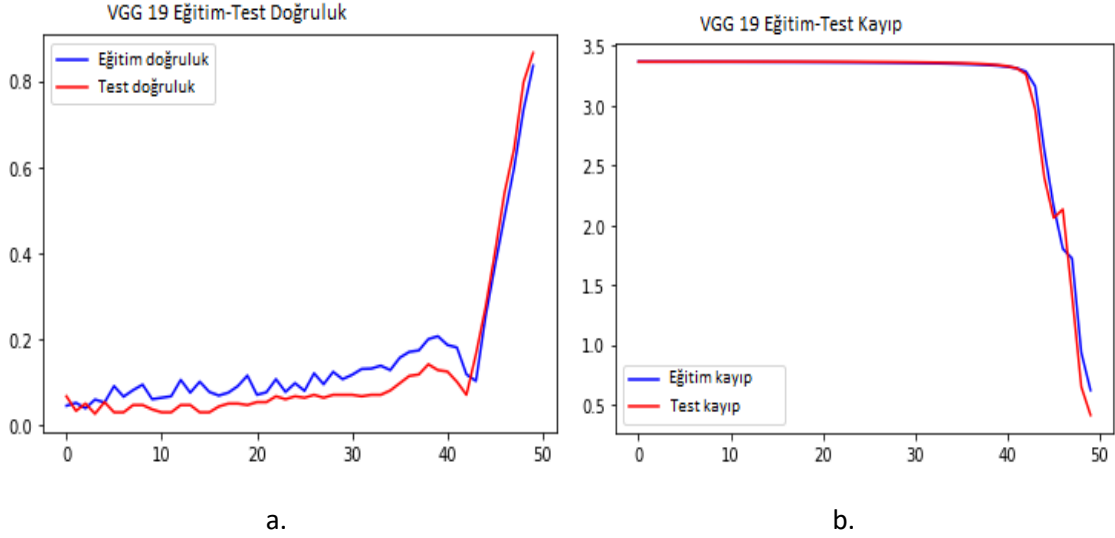
Şekil 13'te VGG16 mimarisi için %60'ı eğitim, %40'ı test olarak ayrılmış veriseti ile eğitim sonucunda elde edilen eğitim-test aşamasındaki doğruluk ve kayıp grafiği verilmiştir. Bu eğitimler 50 devir çalıştırılmıştır. Mimaride eğitim ve test için 30. devirden sonra kayıp oranı azalırken, doğruluk oranı da artmaktadır. 40. devirden sonra ise kayıp değerinde önemli bir değişikliğin olmadığı görülmektedir. VGG16 mimarisinin eğitim ve test başarısı %100 olarak bulunmuştur. Diğer bir deyişle 40. devirden sonra öğrenmenin doygunluğa ulaştığı görülmektedir.



Şekil 13:
VGG16 mimarisi sonuçları
a. doğruluk grafiği b. kayıp grafiği

VGG19 mimarisinin 0-50 devirdeki eğitim-test doğruluk ve kayıp grafikleri Şekil 14'te verilmiştir. VGG19 mimarisinde en yüksek başarı %80 eğitim, %20 test verisi olarak eğitildiği

verisetinde bulunmuştur. Yaklaşık 40. devirden sonra kayıp değerinin azaldığı görülmektedir. VGG19 mimarisinde, eğitim %83,52 ve test ise %86,49 oranındaki doğrulukla görüntüler sınıflandırılmıştır. VGG19 mimarisinin doğruluk ve kayıp grafiğindeki eğriler analiz edildiğinde, amaçlanan öğrenmenin tam olarak gerçekleşmediği görülmektedir. Doğruluk grafiğinin düz bir çizgi olmaması dolayısıyla öğrenmenin devam edeceğini ve devir sayısının yeterli gelmediğini göstermektedir. VGG16 ve VGG19 mimarisi karşılaştırıldığında; VGG16 mimarisinin daha hızlı bir eğitim yaptığı görülmektedir.



Şekil 14:
VGG19 mimarisi sonuçları
a. doğruluk grafiği b. kayıp grafiği

AlexNet ve VGG16 mimarisinin sınıflandırma doğruluğunun %100 olarak bulunması ezberlemenin olduğu anlamına gelebilir. Ancak mimarilerdeki eğitim ve test grafiklerinin birbirlerine yakın olmaları verisiyle mimarilerin birbirleriyle uyumlu olduğunu ve ezberlemenin olmadığını göstermektedir. Ayrıca eğitim ve test kayıp değerlerinin aynı zamanlarda değişmesi ezberleme durumunun oluşmadığını da kanıtlamaktadır.

ESA mimarileriyle test için ayrılan 296 ve 592 görüntü örneği üzerinde çalışılmıştır. AlexNet (%80-20), VGG16 (%60-40) ve VGG19 (%80-20) mimarilerin sınıflandırma başarı ölçütleri sonuçları Tablo 6'da verilmiştir. Buna göre; problem uzayında AlexNet ve VGG16 mimarileri, yüksek doğrulukla sınıflandırma yapmışlardır. AlexNet ve VGG16 mimarilerinin katman sayılarında farklılıklar olmasına rağmen test başarısında herhangi bir farklılık olmamıştır. Buna karşın VGG19 mimarisi, diğer mimarilerin başarılarına göre daha düşük başarı elde etmiştir. VGG19 mimarisinin kesinliği %91,96, duyarlılığı %86,13 ve F-Skoru %88,95 olarak bulunmuştur.

Tablo 6. ESA mimarilerinin sınıflandırma ölçütleri sonuçları

Mimari	Katman Sayısı	Veriseti (Eğitim-Test)	Kesinlik (%)	Duyarlılık (%)	F-Skor
AlexNet	15	%80-%20	100,00	100,00	100,00
VGG16	41	%60-%40	100,00	100,00	100,00
VGG19	47	%80-%20	91,96	86,13	88,95

Konuyla ilgili literatür incelendiğinde, kullanılan verisetinde meyve görüntüleri üzerinde yapılmış, sadece bir çalışma bulunmuştur. Ijjina ve Mohan (2014), ALOI-COL verisetinde meyveleri kendi oluşturdukları bir ESA'da %98,53 ile doğru sınıflandırmışlardır. Ayrıca makine öğrenmesi yöntemlerinden SVM'de %64,01 ve kNN'de %90,50 doğrulukla meyveleri sınıflandırma yapmışlardır.

4. SONUÇ

Bilgisayarlı görü sistemleri; kamera, aydınlatma kaynağı ve verilerin işlenmesi için gerekli olan bir bilgisayardan oluşmaktadır. Bu sistemin donanımsal temelini oluşturan ve nesnelerin gerektiği gibi görülmesini sağlayan aydınlatma kaynağının kullanımı oldukça önemlidir. Özellikle aydınlatma koşullarının heterojen olması, nesne sınıflandırma problemlerindeki başarıyı da olumsuz yönde etkilemektedir. Yapay zekanın alt dalından biri olan derin öğrenme mimarilerinden ESA, ağ yapısı eğitilirken öğrendiği özellikleri, nesne sınıflandırılma aşamasındaki özellik eşleşmesinde kullanmaktadır. Böylece nesnelere tanımayı kolaylaştıran parçalar belirlenebilmektedir. Bu bağlamda bilgisayarlı görü uygulamalarında görüntülerden otomatik olarak özelliklerin çıkartılmasına olanak tanıyan ESA'nın, aydınlatma problemlerinin çözülmesinde önemli bir rol oynayacağı fark edilmiş ve bu makale aydınlatma özniteliği kullanılarak oluşturulan bir verisetindeki sınıflandırma problemine uygulanmıştır.

Bu çalışmada 12 farklı renk sıcaklığına sahip ALOI-COL verisetindeki 29 meyve sınıfı, ESA mimarilerinden AlexNet, VGG16 ve VGG19 mimarileriyle sınıflandırılmıştır. Derin öğrenmede, işlenecek veri sayısının fazla olması ve farklı varyasyonlarda görüntülerin kullanılması, problemin çözümünü kolaylaştıracaktır. Bu amaçla görüntü işleme teknikleri ile her sınıftan 51 farklı görüntü elde edilmiştir. Görüntünün parlaklık değerine etki eden yöntemler ile görüntünün varyasyonlarının oluşturulduğu yöntemler kullanılmıştır. Elde edilen 1479 görüntünün %80'i eğitim, %20'si test ve %60'ı eğitim, %40'ı test verisi olarak ayrılmıştır. Bu iki yapı üzerinden veriler eğitilerek sonuçlar elde edilmiştir. Verilerin çalıştırılması için kullanılan devir sayısı 30 ile 50 arasındadır. Mimarilerin 50 devir çalıştırılmasıyla elde edilen sonuçlara göre; AlexNet ve VGG16'da eğitim ve test başarısı %100, VGG19 mimarisinde ise eğitim başarısı %83,52, test başarısı da %86,49 olarak bulunmuştur. Oluşturulan verisetiyle kayda değer bir başarı sağlandığı görülmektedir.

KAYNAKLAR

1. Adler, A., Elad, M. and Zibulevsky, M. (2016) Compressed Learning: A Deep Neural Network Approach, arXiv preprint, arXiv: 1610.09615.
2. ALOI, (2004). Konu: Amsterdam Library of Object Images (ALOI). Erişim Adresi: <http://aloi.science.uva.nl/> (Erişim Tarihi:19.1.2019)
3. Bianco, S., Cusano, C., Napoletano, P. and Schettini, R. (2017) Improving CNN-Based Texture Classification by Color Balancing, *Journal of Imaging*, 3(3), 33. doi:10.3390/jimaging3030033
4. Braje, W.L., Kersten, D., Tarr, M.J. and Troje, N.F. (1998) Illumination effects in face recognition, *Psychobiology*, 26(4), 371-380. doi: 10.3758/BF03330623
5. Brodatz, P. (1966) Textures: a photographic album for artists and designers, Dover Pubns, New York.
6. Castelluccio, M., Poggi, G., Sansone, C. and Verdoliva, L. (2015) Land use classification in remote sensing images by convolutional neural networks, arXiv preprint, arXiv:1508.00092
7. Chen, L.C., Papandreou, G., Kokkinos, I., Murphy, K. and Yuille, A.L. (2017) Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully

- connected crfs, IEEE transactions on pattern analysis and machine intelligence, 40(4), 834-848. doi: 10.1109/TPAMI.2017.2699184
8. Cusano, C., Napoletano, P. and Schettini, R. (2016a) Evaluating color texture descriptors under large variations of controlled lighting conditions, *JOSA A*, 33(1), 17-30. doi: 10.1364/JOSAA.33.000017
 9. Cusano, C., Napoletano, P. and Schettini, R. (2016b) Combining multiple features for color texture classification, *Journal of Electronic Imaging*, 25(6), 061410. doi:10.1117/1.JEI.25.6.061410
 10. Çağlayan, A. (2018). Derin Öğrenme Tekniklerini Kullanarak RGB-D Nesne Tanıma, Doktora Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara. (in Turkish)
 11. Doğan, F. ve Türkoğlu, İ. (2018) Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, *Sakarya University Journal Of Computer And Information Sciences*, 1(1), 10-21. (in Turkish)
 12. Frossard, D., (2016). Konu: VGG in TensorFlow. Erişim Adresi: <http://www.cs.toronto.edu/~frossard/post/vgg16/> (Erişim Tarihi:19.1.2019)
 13. Geusebroek, J.M., Burghouts, G.J. and Smeulders, A.W.M. (2005) The Amsterdam library of object images, *International Journal of Computer Vision*, 61(1), 103-112. doi: 10.1023/B:VISI.0000042993.50813.60
 14. Goodfellow, I., Bengio, Y. and Courville, A. (2016) *Deep Learning*, MIT Press, Cambridge.
 15. He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep residual learning for image recognition, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, USA, 770-778. doi: 10.1109/CVPR.2016.90
 16. Hinton, G.E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.R. (2012). Improving neural networks by preventing co-adaptation of feature detectors, *arXiv preprint*, arXiv:1207.0580
 17. Hossin, M. and Sulaiman, M.N. (2015) A review on evaluation metrics for data classification evaluations, *International Journal of Data Mining & Knowledge Management Process*, 5(2), 1-11. doi: 10.5121/ijdkp.2015.5201
 18. Hubel, D.H. and Wiesel, T.N. (1968) Receptive fields and functional architecture of monkey striate cortex, *The Journal of Physiology*, 195(1), 215-243. doi: 10.1113/jphysiol.1968.sp008455
 19. Ijjina, E.P. and Mohan, C.K. (2014) View and illumination invariant object classification based on 3D Color Histogram using Convolutional Neural Networks, In *Asian Conference on Computer Vision*, Springer, Cham, 316-327. doi: 10.1007/978-3-319-16628-5_23
 20. İnik, Ö. ve Ülker, E. (2017) Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104. (in Turkish)
 21. Jacobs, D.W., Belhumeur, P.N. and Basri, R. (1998) Comparing Images Under Variable Illumination, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR98)*, Santa Barbara, CA, USA, 610-617. doi: 10.1109/CVPR.1998.698668
 22. Jähne B. and Hausbecke, B. (2000) *Computer Vision and Applications*, Academic Press, USA.

23. Jana, S., Basak, S. and Parekh, R. (2017) Automatic fruit recognition from natural images using color and texture features, 2017 Devices for Integrated Circuit (DevIC), Kalyani, India, 620-624. doi: 10.1109/DEVIC.2017.8074025
24. Jarrett, K., Kavukcuoglu, K., Ranzato, M.A. and LeCun, Y. (2009) What is the best multi-stage architecture for object recognition?, 2009 IEEE 12th International Conference on Computer Vision, Kyoto, Japan, 2146-2153. doi: 10.1109/ICCV.2009.5459469
25. Jehle, M., Sommer, C. and Jähne, B. (2010) Learning of optimal illumination for material classification, In Joint Pattern Recognition Symposium, Springer, Berlin, Heidelberg, 563-572. doi: 10.1007/978-3-642-15986-2_57
26. Kızrak, A., (2018). Konu: Derine Daha Derine: Evrişimli Sinir Ağları, Bilgisayarlı görü neden gerekli?. Erişim Adresi: <https://medium.com/deep-learning-turkiye/deri%CC%87ne-daha-deri%CC%87ne-evri%C5%9Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9> (Erişim Tarihi:19.1.2019)
27. Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) Imagenet classification with deep convolutional neural networks, In Advances in neural information processing systems, 25(2), 1097-1105. doi: 10.1145/3065386
28. LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P. (1998) Gradient-based learning applied to document recognition, Proceedings of the IEEE, 86(11), 2278-2324. doi: 10.1109/5.726791
29. Liu, L., Shen, C. and van den Hengel, A. (2015a) The treasure beneath convolutional layers: Cross-convolutional-layer pooling for image classification, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, Massachusetts, 4749-4757. doi: 10.1109/CVPR.2015.7299107
30. Liu, T., Fang, S., Zhao, Y., Wang, P. and Zhang, J. (2015b) Implementation of training convolutional neural networks, arXiv preprint. arXiv:1506.01195
31. Lü, Q. and Tang, M. (2012) Detection of hidden bruise on kiwi fruit using hyperspectral imaging and parallelepiped classification, Procedia Environmental Sciences, 12, 1172-1179. doi: 10.1016/j.proenv.2012.01.404
32. Mindru, F., Tuytelaars, T., Van Gool, L. and Moons, T. (2004) Moment invariants for recognition under changing viewpoint and illumination, Computer Vision and Image Understanding, 94(1-3), 3-27. doi: 10.1016/j.cviu.2003.10.011
33. Phillips, P.J., Scruggs, W.T., O'Toole, A.J., Flynn, P.J., Bowyer, K.W., Schott, C.L. and Sharpe, M. (2009) FRVT 2006 and ICE 2006 large-scale experimental results, IEEE transactions on pattern analysis and machine intelligence, 32(5), 831-846. doi: 10.1109/TPAMI.2009.59
34. Pouladzadeh, P., Yassine, A. and Shirmohammadi, S. (2015) Foodd: Food detection dataset for calorie measurement using food images, In International Conference on Image Analysis and Processing, Springer, Cham, 441-448. doi: 10.1007/978-3-319-23222-5_54
35. Rocha, A., Hauagge, D. C., Wainer, J. and Goldenstein, S. (2010) Automatic fruit and vegetable classification from images, Computers and Electronics in Agriculture, 70(1), 96-104. doi: 10.1016/j.compag.2009.09.002
36. Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T. and McCool, C. (2016) Deepfruits: A fruit detection system using deep neural networks, Sensors, 16(8), 1222. doi: 10.3390/s16081222
37. Scherer, D., Müller, A., and Behnke, S. (2010) Evaluation of pooling operations in convolutional architectures for object recognition, In International conference on artificial neural networks, Springer, Berlin, Heidelberg, 92-101. doi: 10.1007/978-3-642-15825-4_10

38. Simonyan, K. and Zisserman, A. (2014) Very deep convolutional networks for large-scale image recognition, arXiv preprint, arXiv:1409.1556 2014
39. Steinbrener, J., Posch, K. and Leitner, R. (2019) Hyperspectral fruit and vegetable classification using convolutional neural networks, *Computers and Electronics in Agriculture*, 162, 364-372. doi: 10.1016/j.compag.2019.04.019
40. Tümen, V., Söylemez, Ö.F. and Ergen, B. (2017) Facial emotion recognition on a dataset using convolutional neural network, 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), Malatya, Turkey, 1-5. doi: 10.1109/IDAP.2017.8090281
41. Uçar, A. ve Bingöl, M.S. (2018) Derin öğrenmenin Caffe kullanılarak grafik işleme kartlarında değerlendirilmesi, *Dicle Mühendislik Fakültesi Dergisi*, 9(1), 39-49. (in Turkish)
42. Vageeswaran, P., Mitra, K. and Chellappa, R. (2012) Blur and illumination robust face recognition via set-theoretic characterization, *IEEE transactions on image processing*, 22(4), 1362-1372. doi: 10.1109/TIP.2012.2228498
43. Wang, S., Zhang, Y., Ji, G., Yang, J., Wu, J. and Wei, L. (2015) Fruit classification by wavelet-entropy and feedforward neural network trained by fitness-scaled chaotic ABC and biogeography-based optimization, *Entropy*, 17(8), 5711-5728. doi: 10.3390/e17085711
44. Xiao, T., Li, H., Ouyang, W. and Wang, X. (2016) Learning deep feature representations with domain guided dropout for person re-identification, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, USA, 1249-1258. doi: 10.1109/CVPR.2016.140
45. Yang, J.B., Nguyen, M.N., San, P.P., Li, X.L. and Krishnaswamy, S. (2015) Deep Convolutional Neural Networks on Multichannel Time Series for Human Activity Recognition, In *Twenty-Fourth International Joint Conference on Artificial Intelligence*, Buenos Aires, Argentina, 3995-4001.
46. Yiğit, A. (2017). İş Süreçlerinde İnsan Görüsünü Derin Öğrenme ile Destekleme, Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne. (in Turkish)
47. Zhang, T., Tang, Y.Y., Fang, B., Shang, Z. and Liu, X. (2009) Face recognition under varying illumination using gradientfaces, *IEEE Transactions on Image Processing*, 18(11), 2599-2606. doi: 10.1109/TIP.2009.2028255
48. Zhang, W., Zhang, Y., Zhai, J., Zhao, D., Xu, L., Zhou, J., Li, Z. and Yang, S. (2018) Multi-source data fusion using deep learning for smart refrigerators, *Computers in Industry*, 95, 15-21. doi: 10.1016/j.compind.2017.09.001
49. Zheng, Y., Yang, C. and Merkulov, A. (2018) Breast cancer screening using convolutional neural network and follow-up digital mammography, in *Proc. SPIE San Francisco 10669*, Computational Imaging III, doi: 10.1117/12.2304564
50. Zhu, J.Y., Zheng, W.S., Lu, F. and Lai, J.H. (2017) Illumination invariant single face image recognition under heterogeneous lighting condition, *Pattern Recognition*, 66, 313-327. doi: 10.1016/j.patcog.2016.12.029

