



# Antep fıstığının derin öğrenme ile dış kabuk rengine göre sınıflandırılması

## Classification of pistachios based on outer shell color using deep learning

Hakan Aktaş<sup>1,\*</sup> 

<sup>1</sup> Niğde Ömer Halisdemir Üniversitesi, Bilgisayar Mühendisliği Bölümü, Merkez, Niğde, Türkiye

### Özet

Antep fıstığı, ticari değeri yüksek bir ürün olup; Türkiye bu alanda ciddi bir üretim ve ihracat potansiyeline sahiptir. Bu ürünlerin yetiştirilmesi kadar toplanması ve ayıklanması da bir o kadar önemli bir işlemdir. Antep fıstıklarının toplandıktan sonra dış kabuk renklerine göre sınıflandırılması fıstığın pazarlanmasından önce yapılması gereken önemli işlemlerden bir tanesidir. Bu çalışmada Antep fıstığının dış rengine göre ayıklanması için derin öğrenme teknikleri kullanılmıştır. Ayıkla işlemi için gerekli olan veri seti endüstriyel bir deney düzeneği kullanarak elde edilmiştir. AlexNet yapısı, elde edilen bu veri setleri ile eğitilip test edilmiştir. Yine farklı yüzdelerdeki ve sayılardaki eğitim, doğrulama ve test verilerinin test doğruluğuna etkisini araştırmak için iki farklı yüzde (%70,%15,%15 ve %60,%20,%20) ve üç farklı sayıda veri seti için ağ yapısı eğitilmiş ve test edilmiştir. En yüksek test doğruluğu %60,%20,%20 oranlarına ait eğitim, doğrulama ve test için sırasıyla 580x2, 193x2 ve 193x2 adet verinin kullanılması ile %98.44 olarak hesaplanmıştır. Ayıklama işlemi derin öğrenme teknikleri ile yüksek doğruluklarda gerçekleştirilmiş olup; geliştirilen endüstriyel veri seti ile eğitilmiş ağ yapıları endüstriyel ayıklama makinelerinde yüksek doğrulukta çalışabilecek seviyededir.

**Anahtar kelimeler:** Görüntü İşleme, Derin Öğrenme, Antep Fıstığı, Ayıklama Sistemleri

### 1 Giriş

2019 FAO verilerine göre dünya Antep fıstığı üretim alanları itibarıyla ülkemiz, İran'dan sonra ikinci sırada olduğundan hem bölge hem de ülke ekonomisi açısından önem arz etmektedir. Ancak verimi ve ihracatı açısından değerlendirildiğinde aynı başarıyı sağlayamamaktadır. TÜİK verilerine göre 2019/20 üretim döneminde Türkiye'de 80 bin ton Antep fıstığı üretimi gerçekleşirken Antep fıstığı ihracatı 2600 ton olarak gerçekleşmiştir. Üretim ve ihracat arasındaki farkın temel nedeni, üreticilerin modern üretim, işleme ve muhafaza tekniklerini doğru bir şekilde kullanmaması ve Antep fıstığını işleyecek tam entegre modern tesislerin sayısının yetersiz olmasıdır [1]. Antep fıstığının hasadından pazara ulaşıncaya kadar tüm işleme aşamalarında önemli kayıplar olabilmektedir. Bu kayıpların son yıllarda yeni teknolojilerle azaltılması mümkün olup üretim maliyetinin düşmesine olanak sağlamaktadır [2].

### Abstract

Pistachio is a product with high commercial value and Turkey has a serious production and export potential in this field. The harvesting and sorting of these products is as important process as their cultivation. Classification of pistachios according to their outer shell color after harvest is one of the important processes that must be done before presenting the pistachio to market. In this study, deep learning techniques were used to sort the pistachios according to their outer color. The data set required for the extract process was obtained using an industrial experimental setup. The AlexNet structure was trained and tested with these data sets. The network structure was trained and tested for two different percentages (70%, 15%, 15% and 60%, 20%, 20%) and three different data numbers to investigate the effect of training, validation and test data in different percentages and numbers on test accuracy. The highest test accuracy was calculated as 98.44% by using of 60%, 20%, 20% percentages and 580x2, 193x2 and 193x2 data for training, validation and testing, respectively. Classification process has been performed with deep learning techniques with high accuracy. Network structures trained with the developed industrial data set are at a level to obtain high accuracy in industrial sorting machines.

**Keywords:** Image Processing, Deep Learning, Pistachio, Sorting Systems

Hasat olgunluğuna gelmiş Antep fıstığı meyvelerinde renk değişimi gerçekleşmektedir. Olgun taze Antep fıstığının dış kabuğu mor olup, %78 oranında nem barındırmaktadır. Hasat sonrasında mor kabuklu Antep fıstığı meyvelerine kurutma ve kavlama işlemleri uygulanmaktadır. Kurutma işlemi mekanik kurutucular ile yapılabildiği gibi açık havada serilerek de yapılabilmektedir. Kavlatma ise meyvedeki mor kabuğun sert kabuktan ayrılacak şekilde çıkarılması işlemi olup depolama sonrasında yapılmaktadır [3].

Olgunlaşmamış Antep fıstıklarının kurutma ve kavlatma işleminde mor kabuklu meyvelerde mekanik zararların ve fizyolojik bozuklukların artması ürün kalitesini etkilediğinden doğru zamanda hasat edilmesi önem arz etmektedir [2]. Ancak Antep fıstığında hasattan sonra elde edilen tam olgunlaşmış düşük kalite ürün ile "boz" fıstık olarak adlandırılan ürün birbirinden farklıdır. Hasattan bir ay önce ürün tam olgunlaşmadan dalından toplanan ve rengi çok yeşil olan boz fıstık, aroması yüksek olduğundan tatlı

\* Sorumlu yazar / Corresponding author, e-posta / e-mail: haktas@ohu.edu.tr (H. Aktaş)

Geliş / Received: 28.01.2022 Kabul / Accepted: 04.04.2022 Yayınlanma / Published: 18.07.2022

doi: 10.28948/ngumuh.1064522

sektöründe kullanılan kaliteli bir üründür [4]. Düşük kalite ürünün ise bahçenin tamamı hasat olgunluğuna geldiğinde kısmen oluştuğu görülmektedir. Tüm meyveler aynı anda olgunlaşmadığı için hasat edilen yığın içinde rengi henüz mora dönmemiş meyveler de bulunmaktadır. Bu rengin oluşmaması genellikle boş veya yeterli olgunlukta olmadığına göstergesidir [2].

Kurutma işleminin mor kabuklarına zarar vermeden hızlı bir şekilde yapılması küf gelişimini önleme açısından büyük önem arz etmektedir. Hasat sonrasında kurutma ve kavlatma işlemlerinin doğru yapılmadığı takdirde ihracatın gerektirdiği koşulları yerine getirmesi mümkün olmamaktadır [3]. Kavlatma işlemi öncesinde taze Antep fıstığı meyvelerinin dış kabuk rengine göre sınıflandırılması kavlatma işlemlerinde oluşacak risklerin azaltmasına katkı sağlayacaktır. Böylece kavlatma işlemi sadece mor kabuklu tam olgun meyvelere uygulanacağından daha yüksek kalitede ürün oluşmasına olanak sağlayacaktır. Bu çalışmada derin öğrenme ve görüntü işleme tekniklerine dayalı Antep fıstığı meyvelerinin dış kabuk rengine göre sınıflandırılma uygulaması yapılmıştır.

Literatürde Antep fıstığı ürünlerinin görüntü işleme teknikleri ile sınıflandırılması konu alan çeşitli çalışmalar bulunmaktadır. Pearson ve ark. kabuk kusurlarına sahip fıstıkların ayıklanması için görüntüleme algoritmaları geliştirmiş ve %98'lik sınıflandırma doğruluğu elde etmiştir [5]. Gazanfari ve ark. dört grup Antep fıstığını 2 boyutlu şekillerine göre sınıflandırmak için yapay sinir ağlarına dayalı şekil tanıma yöntemlerini kullanmış ve %94.8 sınıflandırma doğruluğu elde etmiştir [6]. Haff ve Pearson, ayırma makineleri için kullanılacak optimal spektral bantları seçmek için yakın kızılötesi spektroskopisi (NIR) kullanan bir teknik geliştirdi. Önerilen yöntemin sıralama doğruluğunun, ticari olarak mevcut sıralama makinesinin sıralama doğruluğundan daha iyi performans gösterdiğini gösterdiler [7]. Ghezlbash ve ark. bilgisayar görüşüne dayalı fıstık ayıklama için uygun maliyetli bir akıllı sistem geliştirmiş, açık ve kapalı kabuklu fıstıklar için sırasıyla %92.7 ve %86.7 sınıflandırma doğruluğu elde etmiştir [8]. Sabancı ve ark. Siirt ve Uzun Antep fıstığı olmak üzere iki farklı çeşidi sınıflandırmak için yapay sinir ağları ile entegre görüntü işleme teknikleri ve Otsu Metodu kullandılar [9]. Nouri-Ahmadabadi ve ark. soyulmuş fıstık kabuklarının ve çekirdeklerinin ayıklanması için yapay görme ve destek vektör makinesinin entegrasyonu ile akıllı bir sistem geliştirdi. Renkli CCD kamera, sıralama birimi ve işlem biriminden oluşan sistemin elde edilen sınıflandırma doğrulukları, sistemin çevrim dışı ve çevrim içi karar verme birimi için sırasıyla %99.17 ve %94.33'tür [10]. Literatürde Antep fıstığını dış kabuk rengine göre derin öğrenme teknikleri ile ayıran bir çalışmaya rastlanmamıştır.

Bu çalışmada, Antep fıstığını dış kabuk rengine göre ayırmak için AlexNet ağ yapısı kullanılmıştır. AlexNet yapısını eğitmek için gerekli olan veri seti sıfırdan üretilmiştir. Veri setini oluşturmak için endüstriyel bir test düzeneği kullanılmıştır. Bu çalışmada ikinci kısımda veri setini oluşturmak için kullanılan materyal ve yöntem detaylı bir şekilde anlatılmıştır. Üçüncü bölümde ise bu veri setleri ile AlexNet yapısı eğitilip test edilmesi sonucu elde edilen

değerler detaylı bir şekilde incelenmiştir. Son bölümde ise sonuçlar ve gelecek çalışmalardan söz edilmiştir.

## 2 Materyal ve metod

### 2.1 Veri seti oluşturma

Antep fıstıkları depolama sonrası ve pazarlama öncesi kavlatma işlemine tabi tutulmaktadır. Kavlatma işlemine sadece dış kabuğu mor olan Antep fıstıklarının girmesiyle daha yüksek kalitede ürün elde edilmektedir. Bu çalışmada derin öğrenme teknikleri kullanılarak Antep fıstıklarının toplandıktan ve kurutulduktan sonra dış kabuk rengine göre sınıflandırmak için derin öğrenme teknikleri kullanılmıştır. Literatürdeki sınıflandırma ve ayıklama çalışmalarına bakıldığında kullanılan veri setleri elle oluşturulmuş veri setleridir. Bu çalışmada oluşturulacak veri setinin ve eğitilecek ağ yapısının endüstride de yüksek doğrulukta çalışabilmesi için Şekil 1'deki gibi bir deney düzeneği oluşturulmuştur.



Şekil 1. Deney düzeneği

Bu deney düzeneği fıstıkların koyulduğu haznedan, fıstıkların düşme bölgesine doğru ilerlediği oluktan, oluktaki titreşimi sağlayan vibrasyon motorundan, Basler marka 107649 acA1440-73gc 1440 x 1080 73 fps, color 1/3" CMOS kameradan ve kameranın pozlama zamanı ile senkron çalışabilen MJB imaging marka DTL-ic-1010 Diffuse Flat Dome Light aydınlatmadan oluşmaktadır. Yine veri setlerini oluşturmak ve ağ yapısını eğitip test etmek için Intel i7, 3.6 GHz, 32 GB DDR3 1600 MHz RAM, Nvidia RTX 3070 GPU, Windows 10 Pro özelliklerde bir masa üstü sistem kullanılmıştır.


Öncelikle hazne boş iken tamamen mor olduğundan emin olduğumuz (daha önce gözle kontrolü yapılmış) fıstıklar hazneye dökülmektedir. Hazneye döküldükten sonra vibrasyon motoruna kontrol kartından hareket verilmektedir. Fıstıklar hazne üzerinde ilerleyip oluğun ucundan aşağıya doğru serbest düşme yapmaktadırlar. Fıstıklar düşerken oluğun altında bulunan kamera anlık görüntülerini çekmektedir. Bu sayede veri setinde kullanılmak üzere görüntüler oluşturulmaktadır. Fıstıklar düşerken çekilmiş örnek görüntüler Şekil 2'deki gibidir.



Şekil 2. Örnek fıstık görüntüleri

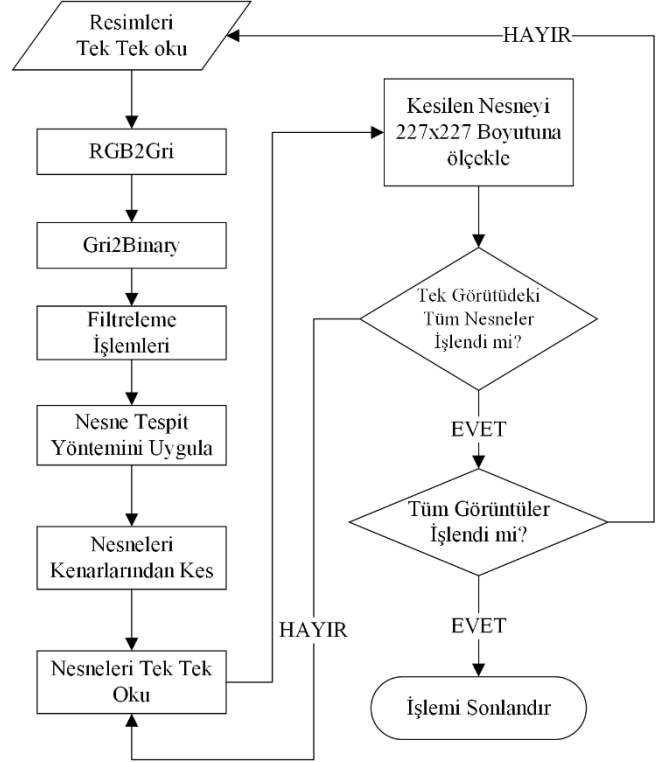
Şekil 2'den de görüleceği üzere fıstıklar serbest düşme yaparken x,y ve z ekseninde sürekli döndüklerinden dolayı çok farklı açılarda görüntülenmektedirler. Fıstıkların ayıklanması için endüstriyel bir düzenek geliştirildiğinde gerçek görüntüler yine bu şekilde olacaktır. Mor ve sarı kabuklu Antep fıstıklarına ait görüntüler bu şekilde çekilmiş olup toplamda 2426 adet sarı kabuklu, 1557 adet mor kabuklu Antep fıstığı görüntüsü hafızada kaydedilmiştir.

Veri seti oluşturmak için blob analizi etkin bir şekilde kullanılmıştır. Blob analizi nesnelere ait birçok bilgi vermekte olup; bu çalışmada blob analizinden elde edilen X\_min, X\_max, Y\_min, Y\_max ve centre of blob parametreleri kullanılacaktır. Örnek bir görüntü üzerinde blob analizinin uygulanması, Antep fıstığının görüntüden kesilmesi için gerekli parametrelerin gösterilmesi Şekil 3'deki gibidir.




Şekil 3. Blob Algoritması ile koordinatların bulunması

Tek bir görüntü üzerindeki fıstıkların(blobların) blob analizi ile bulunması ve kesilmesi işlemi kayıtlı olan tüm görüntülere uygulandığında kayıtlı görüntülerdeki fıstıkların tamamı tespit edilmiş, kenarlarından kesilmiş ve ağ yapısına uygun hale getirilmiş olacaktır. Bu işlem tek bir fıstık sınıfı için Şekil 4'de gösterildiği gibidir.



Şekil 4. Veri seti oluşturma algoritması

Şekil 4'e göre görüntülere nesne tespit yöntemi uygulanmadan önce görüntüleri ve küçük parçaları silmek için yoğun filtreleme işlemleri kullanılmıştır. Yine daha büyük parçacıklar ise blob analizinden sonra alanına göre bir threshold uygulanmış olup veri setlerine dahil edilmemişlerdir. Tüm bu işlemler uygulandıktan sonra mor kabuklu fıstıklara ait 966, sarı kabuklu fıstıklara ait 966 adet görüntü kesilmiş ve 227x227'ye boyutlandırılmıştır. Örnek fıstık görüntüleri Şekil 5'de gösterildiği gibi elde edilmiştir.



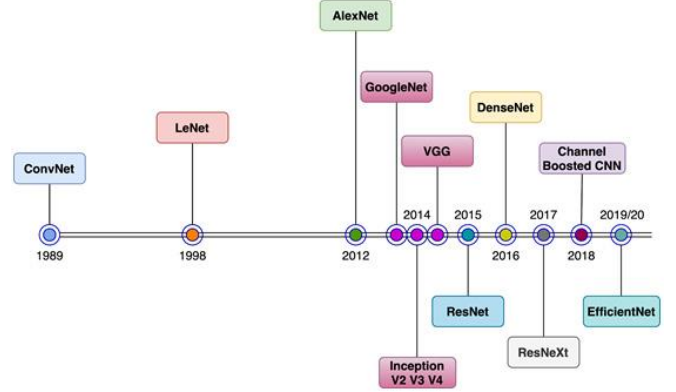
Şekil 5. Örnek 227x227 boyutundaki görüntüler

## 2.2 Derin öğrenme

Derin öğrenme, günümüzde birçok uygulamada kullanılan; yapay sinir ağlarının ilkelerine dayanan çoklu işlem katmanlarından oluşan bir hesaplama modelidir [11]. Derin öğrenmenin tarım alanında ise arazi örtüsü tanımlaması, hastalık tespiti, akıllı sulama, hassas hayvancılık, bitki sınıflandırması, haşere tanıma, yabancı ot tespiti ve fenotipleme gibi uygulamaları mevcuttur [12-13].

Son yıllarda hızlı GPU donanımı sayesinde makine öğrenimindeki hızlı gelişmelere bakıldığında, makine görme uygulamalarında gerçek kırılma, Derin Evrişimli Sinir Ağı (CNN) AlexNet sonrası olmuştur [14]. AlexNet'ten sonraki yıllarda VGGNet [15], Microsoft'un Artık Ağları (ResNet) (He ve diğerleri 2016), GoogleNet veya Inception mimarisi [16], Xception [17] vb. gibi birkaç derin öğrenme mimarisi geliştirildi. Şekil 6, CNN mimarilerinin evrimini özetlemektedir. Burada, AlexNet mimarisinin CNN'nin evrimini nasıl hızlandırdığı görülebilir [18].


Bu çalışmada, Alexnet mimarisi kullanılarak Antep fıstıkları dış kabuk rengine göre sınıflandırmış ve sınıflandırma performansı değerlendirilmiştir. Uygulamada kullanılan AlexNet yapısı Şekil 7'deki gibi olup; literatürde tanımlı olan ağ yapısı kullanılmış ve tam bağlı katmanlar 1024, 256 ve 6 çıkış katmanı da 2 olarak güncellenmiştir. Keras kütüphanesi ile oluşturulan ağ yapısında transfer öğrenme yöntemi kullanılmamış olup; geliştirilen ağ yapısı fıstık veri seti ile sıfırdan eğitilmiştir. Eğitim aşamasında kullanılan parametreler ise şu şekildedir: optimizer= SGD, learning rate = 1e-05, batch size = 64, loss\_function= categorical\_crossentropy.



Şekil 6. CNN yapılarındaki gelişim süreci[18]

## 3 Bulgular ve tartışma

Bu çalışmada Antep fıstıkları dış kabuk rengine göre derin öğrenme ağ yapıları ile sınıflandırılmıştır. Derin öğrenme ağları ile bu sınıflandırmaları yapabilmek için öncelikle bu sınıflara ait veri setleri oluşturulmuştur. İlk olarak blob analizi ile oluşturulan veri setinin tamamı kullanılarak eğitim ve test işlemleri yapılmıştır. Kullanılan veri setinin tamamı mor kabuklu fıstıklara ait 966, sarı kabuklu fıstıklara ait 966 adet kesilmiş ve 227x227'ye boyutlandırılmış fıstık görüntüsünden oluşmaktadır. Literatürde eğitim, doğrulama ve test veri setlerini oluştururken en yaygın kullanılan %70, %15, %15 ve %60, %20, %20 oranları seçilmiştir. Her sınıfa ait 966 adet Antep fıstığı görüntüleri, %70, %15, %15 oranı kullanarak, her sınıftan 676 adet görüntü eğitim için, 145 adet doğrulama için ve 145 adet test işlemi için ayrılmıştır.



Şekil 7. AlexNet yapısı

Bu veri seti kullanılarak gerçekleştirilen sınıflandırma sonuçları **Tablo 1**'de verilmiştir. Ağın daha fazla veri ve daha fazla tur sayısı ile eğitilmesiyle ağın doğruluğunun artması beklenen bir sonuçtur. Mevcut veri sayısı 966 ile sınırlı olup; ağın daha uzun süre eğitilmesi ile daha yüksek sonuç vermesi beklenmektedir. Ancak ağın eğitimindeki tur sayısı belirli bir sayıdan fazla olduğunda ağ öğrenmemeye başlamaktadır. Bunu engellemek ve maksimum tur sayısını rast gele değil de kod ile belirlemek adına bu çalışmada tur sayısını otomatik olarak sınırlandırmak için Keras kütüphanesine ait early stopping (erken durdurma) fonksiyonu kullanılmıştır. **Tablo 1**'e bakıldığında en yüksek doğruluk oranı %96.87 olarak hesaplanmıştır. Bu değer için hesaplanması için ağ yapısı 83 turda eğitilmiş ve tur sayısı erken durdurma fonksiyonu ile otomatik olarak hesaplanmıştır.

**Tablo 1.** 966 verinin kullanılması sonucu eğitim sonuçları

Tur Sayısı	Test Doğruluğu
10	%93.79
20	%93.44
50	%95.17
83 ED*	<b>%96.87</b>

ED: Erken Durdurma

Veri sayısının ağın test doğruluğuna etkisini araştırmak adına bir sonraki aşamada her sınıftan 338 adet görüntü eğitim için, 72 adet doğrulama için ve 72 adet görüntü test işlemi için kullanılmıştır. Bu veriler eşliğinde en yüksek test doğruluğu **Tablo 2**'deki gibi hesaplanmıştır. En yüksek test doğruluğu erken durdurma fonksiyonun hesapladığı 69 tur için %96.52 olarak hesaplanmıştır.

**Tablo 2.** 482 verinin kullanılması sonucu eğitim sonuçları

Tur Sayısı	Test Doğruluğu
10	%82.63
20	%84.02
50	%92.36
69 ED	<b>%96.52</b>

Son aşamada her sınıftan 67 adet görüntü eğitim için, 14 adet doğrulama için ve 14 adet görüntü test işlemi için kullanılmıştır. Kullanılan bu veriler eşliğinde en yüksek test doğruluğu %96,42 olarak hesaplanmıştır. Elde edilen sonuçlar **Tablo 3**'deki gibidir.

**Tablo 3.** 95 verinin kullanılması sonucu eğitim sonuçları

Tur Sayısı	Test Doğruluğu
10	%50.5
20	%64.28
50	%96.42
150 ED	<b>%96.42</b>

Literatürde farklı oranlarda eğitim, test ve doğrulama oranları kullanılmakta olup; bu çalışmada %70, %15, %15 oranları ve %60, %20, %20 oranlarının ve veri seti boyutunun test doğruluğuna etkisi incelenmiştir. %70, %15, %15 oranlarına ait test sonuçları **Tablo 1, 2 ve 3**'deki gibi olup tüm bu işlemler %60, %20, %20 oranları kullanılarak tekrar

yapıldığında farklı veri sayılarına ait test sonuçları **Tablo 4**'teki gibi bulunmuştur. En yüksek test doğruluğu tüm veriler (her sınıftan 580 adet görüntü eğitim için, 193 adet doğrulama için ve 193 adet test işlemi için) kullanıldığında %98.44 olarak hesaplanmıştır. Tüm bu sonuçlar **Tablo 4**'teki gibidir.

**Tablo 4.** %60, %20, %20 oranları ile farklı sayılardaki verilerin test doğruluğu sonuçları

%60 Eğitim, %20 Doğrulama, %20 Test					
Eğitim = 580x2, Doğrulama=193x2, Test=193x2		Eğitim = 290x2, Doğrulama=96x2, Test=96x2		Eğitim = 58x2, Doğrulama=19x2, Test=19x2	
Tur Sayısı	Test Doğruluğu	Tur Sayısı	Test Doğruluğu	Tur Sayısı	Test Doğruluğu
10	%93.52	10	%85.93	10	%76.31
20	%95.85	20	%93.75	20	%84.21
50	<b>%98.44</b>	50	%93.75	50	%92.10
71ED	%97.15*	96ED	%96.87	100ED	%94.52

Antep fıstığının rengine göre ayıklanması kısmen kolay bir problem gibi gözükse de ayıklama işleminin endüstriyel bir ortamda gerçekleştirilmesi ayıklama işlemini zorlaştırmaktadır. Literatürdeki derin öğrenme temelli ayıklama ve sınıflandırma çalışmalarına [9-10] bakıldığında daha çok masaüstünde oluşturulmuş veri setleri ile ağın eğitilmesi ve test edilmesi işlemleri yapılmaktadır. Bu veri setleri oluşturulurken sınıflandırılmak istenen nesnelere (tohum, bakliyat, kuruyemiş) görüntüleri sabit bir pozisyonda oluşturulmaktadır. Ancak uygulamada işler bu kadar kolay değildir. Endüstriyel bir ayıklama sisteminde ayıklanmak istenen nesne oluktan ya da konveyörden ilerlerken x, y, z eksenlerinde dönecekleri için çok farklı açılarda görüntüleri oluşacaktır. Hakan ve ark. yaptıkları çalışmada masaüstü veri seti ve endüstriyel veri seti ile eğitilmiş ağ yapılarını endüstriyel bir uygulamada test ettiklerinde; masaüstü veri seti ile eğitilen ağ yapısının test doğruluğu %61.75 buna karşılık endüstriyel veri seti ile eğitilen ağ yapısının test doğruluğu ise %96.54 olarak hesaplanmıştır [19].

#### 4 Sonuçlar ve gelecek çalışmalar

Bu çalışmada Antep fıstıklarının dış kabuklarına göre sınıflandırılması için derin öğrenme teknikleri kullanılmıştır. Literatürde yapılan çalışmalara bakıldığında derin öğrenme ile Antep fıstığı ayıklama ve sınıflandırma son zamanlarda çalışılan popüler konulardan bir tanesidir. Antep fıstıklarının dış kabuk renklerine göre sınıflandırılması için endüstriyel bir deney düzeneği geliştirilmiş ve bu düzenek kullanılarak veri setleri elde edilmiştir. Veri setlerinin oluşturulması için blob analiz yöntemi etkin bir şekilde kullanılmıştır. Elde edilen veri setleri ile AlexNet ağ yapısı farklı yüzdelere sahip eğitim, doğrulama ve test verileri ile eğitilip test edilmiştir. En yüksek test doğruluğu %60, %20, %20 yüzdelere sahip veri seti ile elde edilmiştir. Test doğruluğu %98.44 olarak hesaplanmıştır. Yine veri setlerinin farklı sayılarda olmasının test sonucuna etkisini araştırmak için 3 farklı sayıda veriye sahip veri setleri kullanılmıştır. Yüksek sayıda verinin eğitim ve doğrulamada kullanılması sonucunu test

doğruluğu yüksek hesaplanmıştır. Kullanılan veri sayısı onda birine indirildiğinde test doğruluğunda, %60, %20, %20 yüzdelerine sahip veri setleri için %98.44 – %94.52 = %3.92 ‘lik bir farka sebep olmuştur.

Elde edilen test sonuçları ayıklama sistemleri için yüksek doğruluk kriterini sağlamakta olup; gelecekteki çalışmalarda böylesi bir ayıklama sisteminin kurulması için sistemin gerçek zamanlı hale getirilmesi hedeflenmektedir. Sistemin gerçek zamanlı çalıştırılabilmesi için uygulamaya özel düşük işlem yüküne sahip ağ yapılarının araştırılması ve optimize edilmiş ağ yapılarının geliştirilmesi hedeflenmektedir.

#### Teşekkür

Veri setlerinin oluşturulması için Antep fıstıklarının toplanması ve ulaştırılmasında emeği geçen Haleplioğlu Şirketi ve Hacıbekirlioğlu şirketi (Sayın Mehmet Bostancı) ve nazik destekleri için Gaziantep İl Müdürlüğü'nden Sedat Gökoğlu'na (Ziraat Mühendisi) ve Dr. Öğr. Üyesi Tefide Kızıldeniz'e teşekkür ederim.

#### Çıkar çatışması

Yazar çıkar çatışması olmadığını beyan etmektedir.

#### Benzerlik oranı (iThenticate): %9

#### Kaynaklar

- [1] Y. E. Ertürk, M. K. Geçer, E. Gülsoy ve S. Yalçın, Antepfıstığı üretimi ve pazarlaması., Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 5(2), pp. 43-62, 2015.
- [2] İ. C. Bilim, R. Polat, K. Sarpkaya, N. Doğruer Kalkancı, N. Yıldırım ve A. Yaman, Antepfıstığı Entegre İşletme Tekniğinin Geliştirilmesi, <https://kutuphane.tarimorman.gov.tr/vufind/Record/18984/Description> Accessed 3 Jan 2022
- [3] Y. Gezginç ve A. D. Duman, Antep fıstığı işleme tekniği ve muhafazasının kalite üzerine etkisi, Gıda, c. 29(5), Eki. 2004
- [4] rekoltedunyasi.com, <https://rekoltedunyasi.com/arastirma/Antepfistigi-ile-ilgili-saptamalar/> Accessed 4 Jan 2022
- [5] T. C. Pearson, M. A. Doster and T. J. Michailides, Automated detection of pistachio defects by machine vision., Applied Engineering in Agriculture, 17(5), p. 729–732, 2001.
- [6] A. Ghazanfari, J. Irudayaraj, A. Kusalik and M. Romaniuk, Machine vision grading of pistachio nuts using Fourier descriptors, Journal of agricultural engineering research, 68(3), 247-252, 1997.
- [7] R. P. Haff and T. Pearson, Spectral band selection for optical sorting of pistachio nut defects, Transactions of the ASABE, 49(4), pp. 1105-1113, 2006. <https://doi.org/10.13031/2013.21716>
- [8] J. Ghezelbash, A. M. Borghaee, S. Minaei, S. Fazli and M. Moradi, Design and implementation of a low cost computer vision system for sorting of closed-shell pistachio nuts, African Journal of Agricultural Research, 8(49), pp. 6479-6484, 2013. <https://doi.org/10.5897/AJAR10.1162>
- [9] K. Sabancı, M. Köklü and M. F. Ünlersen, Classification of Siirt and long type pistachios (pistacia vera l.) by artificial neural networks., International Journal of Intelligent Systems and Applications in Engineering, p. 86–89, 2015. <https://doi.org/10.18201/ijisae.74573>
- [10] H. Nouri-Ahmadabadi, M. Omid, S. S. Mohtasebi and M. S. Firouz, Design, development and evaluation of an online grading system for peeled pistachios equipped with machine vision technology and support vector machine, Information Processing in Agriculture, 4(4), pp. 333-341, 2017. <https://doi.org/10.1016/j.inpa.2017.06.002>
- [11] E. C. Tetila, B. B. Machado, G. Astolfi, N. A. de Souza Belete, W. P. Amorim, A. R. Roel and H. Pistori, Detection and classification of soybean pests using deep learning with UAV images., Computers and Electronics in Agriculture, 179,105836, pp. 1-11, 2020. <https://doi.org/10.1016/j.compag.2020.105836>
- [12] Z. Ünal, Smart farming becomes even smarter with deep learning—A bibliographical analysis, IEEE Access, 8, pp. 105587-105609, 2020. <https://doi.org/10.1109/ACCESS.2020.3000175>
- [13] F. Kurtulmuş, Identification of sunflower seeds with deep convolutional neural networks, Journal of Food Measurement and Characterization, 15(2), pp. 1024-1033, 2021. <https://doi.org/10.1007/s11694-020-00707-7>
- [14] A. Krizhevsky, I. Sutskever and G. E. Hinton, Imagenet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems, 25, pp. 1097-1105., 2012.
- [15] K. Simonyan and A. Zisserman, Very deep convolutional networks for large-scale image recognition, International Conference on Learning Representations (ICLR 2015), San Diego, 2014.
- [16] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, Rethinking the inception architecture for computer vision, in In Proceedings of the IEEE conference on computer vision and pattern recognition, Las Vegas, USA, 2016. <https://doi.org/10.1109/CVPR.2016.308>
- [17] F. Chollet, Xception: Deep learning with depthwise separable convolutions, in In Proceedings of the IEEE conference on computer vision and pattern recognition, Honolulu, USA, 2017.
- [18] A. R. Jha, Mastering PyTorch, USA: Packt, 2021.
- [19] H. Aktaş, T. Kızıldeniz and Z. Ünal, Classification of pistachios with deep learning and assessing the effect of various datasets on accuracy. Journal of Food Measurement and Characterization, 1-14, 2022 <https://doi.org/10.1007/s11694-022-01313-5>

