



## Faster R-CNN Kullanarak Elmalarda Çürük Tespiti

### Bruise Detection in Apples using Faster R-CNN

Onur Cömert <sup>\*1</sup> , Mahmut Hekim <sup>2</sup> , Kemal Adem <sup>3</sup> 

<sup>1</sup> Mekanik Müh., Mühendislik ve Doğa Bil. Fakültesi, Tokat Gaziosmanpaşa Üniversitesi, 60150 Tokat, TÜRKİYE

<sup>2</sup> Elektrik-Elektronik Müh., Müh. ve Doğa Bil. Fakültesi, Tokat Gaziosmanpaşa Üniversitesi, 60150 Tokat, TÜRKİYE

<sup>3</sup> Enformatik Bölümü, Tokat Gaziosmanpaşa Üniversitesi, 60150 Tokat, TÜRKİYE

Başyuru/Received: 12/10/2018

Kabul/Accepted: 05/12/2018

Son Versiyon/Final Version: 31/01/2019

#### Öz

Bu çalışmada, elmalardan alınan görüntüler üzerinde evrimsel sinir ağı yöntemlerinden olan Faster R-CNN kullanılarak elmaların çürük ve sağlam olarak sınıflandırılması amaçlanmaktadır. Önerilen modelde işlem adımları sırasıyla görüntü alma-önişleme, çürük bölgelerin tespit edilmesi ve elmaların sınıflandırılması şeklindedir. Görüntü alma-önişleme aşamasında, tasarlanan bir görüntü alma platformu içerisinde bulunan NIR kamera kullanılmıştır. Çalışmada 100'ü çürük ve 100'ü sağlam olan toplam 200 adet elmanın her birinin 6 farklı açıdan toplam 1200 adet görüntü elde edilmiştir. Önişleme aşamasında, bu görüntülere sırasıyla uyarlamalı histogram eşitleme, kenar bulma, morfolojik işlemler uygulanmıştır. Önişlem uygulanarak görünürlüğü iyileştirilen yeni görüntüler kullanılarak eğitilen Faster R-CNN modeli ile çürük bölgeler tespit edilmiştir. Sınıflandırma aşamasında, çürük ve sağlam elmaların tespit edilmesinde %84,95 doğru sınıflandırma oranına ulaşılmıştır. Sonuç olarak, önerilen modelin meyve suyu gıda sanayisinde çürük ve sağlam elmaların otomatik olarak tespit edilmesinde kullanılabileceği düşünülmektedir.

#### Anahtar Kelimeler

“Çürük, elma, görüntü işleme, Faster R-CNN”

#### Abstract

In this study, it is aimed to classify of the apples as bruised and robust by using Faster R-CNN which is one of the convolutional neural network methods on images taken from apple fruit. In the proposed model, the process steps are the image acquisition-preprocessing, the determination of the caries regions, and the classification of the apples. During the image acquisition-preprocessing phase, a NIR camera is used, which is located within a designed image acquisition platform. In the study, a total of 1200 images were obtained from 6 different angles of each of a total of 200 apples, 100 of which were bruised and 100 of which were robust. In the pre-processing phase, adaptive histogram equalization, edge detection, morphological operations are applied to these images, respectively. Caries were identified with the Faster R-CNN model trained using new images with improved visibility by applying preprocessing. In classification phase, 84.95% correct classification rate has been reached in the detection of bruised and robust apples. As a result, it is thought that the proposed model can be used for automatic detection of bruised and robust apples in juice food industry.

#### Key Words

“Bruised, apple, image processing, Faster R-CNN”

## 1. GİRİŞ

Meyve suyu, sağlıklı, olgun, taze ve temiz meyvelerden mekanik yolla elde edilen, o meyvenin, tat, koku ve renk gibi anatomik özelliklerine sahip ve fiziksel yolla bozulmaya karşı dayanıklı duruma getirilen içecektir. Meyve suları, berrak meyve suları, bulanık meyve suları ve nektarlar olarak üç gruba ayrılabilir. Berrak meyve suları vişne, üzüm, elma ve nardan yapılıdır. Berrak meyve suyu yapımında meyvelerin işlenmeye hazırlanması aşamasında meyve suyuna dönüştürülecek olan ürünün toz, toprak, yaprak ve kırıntılarının uzaklaştırılması için havuzlarda yıkama işlemi yapılır. Daha sonra yürüyen bantlarda kalite kontrol işçileri tarafından çürük, sağlam, ezik veya ham şeklinde ayıklama yapılır (Barrett, 2014; Artık, 2017). Fakat ayıklama işleminde insan faktöründen dolayı tam bir standart yakalayabilmek zordur. Bu nedenle bu işlemin görüntü işleme teknolojisi kullanılarak makineler tarafından otomatik olarak yapılması hem işlemin hızlanması hem de maliyetinin azalması bakımından önemlidir (Pandey ve diğ., 2013). Görüntü işleme teknolojisinin kullanılabilmesi için de görüntü alma cihazları ve yazılımlar gerekmektedir.

Gıda sanayi sektöründe meyve suyuna dönüştürülecek olan elmaların sağlam ve çürük olarak ayrıştırılması işlemi geleneksel olarak el ile yapılmaktadır. Ancak birim zamanda ayrıştırılacak olan meyve sayısının çok fazla olması ve insan faktörleri nedeniyle yanlış sınıflandırmalar söz konusu olabilmektedir. Bu işlemin makineler tarafından otomatik olarak yapılması işlemi hızlandırmak, maliyeti düşürmek ve hataları en aza indirmek bakımından önemlidir.

Elmalarda çürük tespitini zorlaştıran en önemli unsurlardan birisi çürük kısımlar ile elmanın kendi anatomik bölgelerinden olan sap çanak kısımlarının karıştırılmasıdır. Bu yüzden, literatürde yapılmış çalışmalarda ya görüntüler elmaların sap-çanak bölgesi gözükmeyecek şekilde alınmış ya da alınan görüntülerde öncelikle elmanın sap ve çanak kısımlarının tespit edilip görüntüden çıkarılmasına odaklanılmıştır. Xing ve Baerdemaeker (2005) yaptıkları çalışmada Jonagold elmalarında çürük tanıma için 400-1000 nm dalga boyu aralığında hiperspektral görüntüleme sistemi oluşturmuşlardır. Çalışma toplam 160 tane elma üzerinde yapılmıştır. İlk olarak görüntülerde arka plan basit eşikleme işlemi ile kaldırılmıştır. Daha sonra 5 ve 10 piksellik ortalama filtre ile yumuşatma uygulanmıştır. Yüzeyin yumuşaklığı, çürükler, sap ucu ve çanak kısmından sağlam bölgeyi ayırmak için bir özellik olarak düşünülmüştür. Elma kenarlarının pürüzsüzlüğü, sağlam ve çürüğü ayırmak için kullanılmıştır. Sağlam elmalar için doğru sınıflandırma %86,4 iken çürükler 1 günlük olduğunda %77,5 olmuştur. Sağamların hiç biri sap ve çanak olarak yanlış sınıflandırılmamıştır ama çürüklerin %2,5 i sap ve çanak olarak yanlış sınıflandırılmıştır. Görüntülerde sap ve çanak %98,3 oranında doğru sınıflandırılmıştır. Mohana ve Prabhakar (2015), 600 farklı renkli görüntü üzerinde şekilsel tanımlayıcıları kullanarak elmaların sap ve çanak bölgelerinin tanınması üzerine bir çalışma yapmışlardır. Segmentasyon aşamasında çoklu eşikleme kullanmışlar, bu aşamada elde edilen nesnelere Multi-fractal, Fourier ve Radon tanımlayıcıları kullanarak şekilsel özellikler çıkarmışlardır. Bu özellikleri de Destek Vektör Makinesi (SVM), ANN, k-En Yakın Komşuluk (k-NN), Doğrusal Ayırıcı Sınıflandırıcı (LDC) ve AdaBoost sınıflayıcılara vererek test etmişler ve SVM sınıflayıcı ile sap-çanak bölgesini elmanın çürük ve yaralarından %94 doğruluk ile ayırt etmişlerdir. Dubey ve Jalal (2016), elma hastalıklarının renk, doku ve şekil tabanlı özellikleri ile tanınması üzerine bir çalışma yapmışlardır. Elma yüzeyindeki kusurların bölütlenmesinde  $L^*a^*b^*$  renk uzayı kullanmışlar, veri seti olarak farklı hastalıkların bulunduğu 4 sınıf etiketine sahip 320 adet elma görüntüsü almışlardır. Hastalıklı meyve kısımları K-means kümeleme yardımıyla tespit etmişler, bölütlenmiş görüntü üzerinde renk, doku ve şekil tabanlı özellikler çıkartmışlar ve Destek Vektör Makinesi ile elmalar hastalıklı ve sağlıklı olarak ortalama %95,95 doğruluk ile elmaları sınıflandırmışlardır. Sa ve diğ. (2016), Faster R-CNN modelini kullanarak meyve algılama üzerine bir çalışma yapmışlardır. Hem NIR hem de RGB görüntüleri birlikte kullanarak yedi farklı meyve üzerinde sistemin performansını test etmişlerdir. NVIDIA GPU ile her bir meyve için eğitim zamanı 4 saat sürmüştür ve sonuç olarak görüntülerde meyveleri %83 oranında doğru olarak tespit edebilmişlerdir. Fuentes ve diğ. (2017), Faster R-CNN kullanarak domates görüntüleri üzerinde hastalık ve zararlıların yerinin ve türünün tespiti üzerine bir çalışma yapmışlardır. Çalışmada farklı çözünürlükte ve farklı büyüklükteki domateslerden yaklaşık 5000 adet görüntü elde etmişler, Veri çoğaltma (Data Augmentation) yöntemi kullanarak eğitim verisinin çoğaltılmasını ve çeşitlendirilmesini sağlamışlardır. Veri setinin %80'i eğitim, %10'u doğrulama ve %10 test işlemi için kullanmışlardır. Deneysel çalışmalarda veri çoğaltma işleminin başarı oranını %35 artırdığını göstermişlerdir. Yapılan testler sonucunda %83-%90 arasındaki doğruluk oranı ile hastalık ve zararlıları tespit edebilmişlerdir. Lu ve Lu (2017), histogram tabanlı otomatik eşikleme yardımıyla elmaların çürüklerinin tespiti üzerine bir çalışma yapmışlardır. Görüntüleri, yapılandırılmış aydınlatma yansıtımlı görüntüleme kullanarak 730nm dalga boyunda 4 türde toplam 120 elmadan elde etmişlerdir. Görüntülerde elmalar yatay pozisyonda olduğundan sap ve çanak kısımları görünmemektedir. Görüntüler üzerinde sırasıyla, Medyan filtre, otomatik eşikleme, açma ve doldurma işlemlerini uygulamışlardır. Eşikleme aşamasında görüntüler üzerinde 9 farklı otomatik eşikleme yöntemi denemişler ve Inter-mode, Ridler ve Otsu tekniklerinin %90 doğruluk oranı ile en iyi sınıflandırma başarısına sahip olduğunu saptamışlardır. Ridler tekniği kullanıldığında Pozitif yanlış ve negatif yanlış oranının ortalamada %6,7 ile en düşük olduğunu, Unimode ve Ridler tekniklerinin birlikte kullanılması durumunda ise bu oranın %5,8'e kadar düştüğünü tespit etmişlerdir. Zhang ve diğ. (2017), elma görüntüleri üzerinde optik özellikler ve destek vektör makinesi kullanılarak elmaların çürüklük seviyesine göre sınıflandırılması üzerinde çalışmışlardır. Çalışmada 155 adet Fuji türü elma kullanmışlar, bu elmalardan bir mikrotom ile 3mm kalınlığında ve 2cm çapında doku örnekleri almışlardır. 400-1050nm dalga boylarında örneklerin geçirgenliğini ve yansıtıcılığını Entegre Küre Sistemi ile ölçmüşlerdir. Elde ettikleri özellikleri destek vektör makinesine vererek yaptıkları sınıflandırmanın başarısını %92,5 olarak tespit edilmiştir. Zarifneshat ve diğ. (2017), elmanın çürük hacimini tahmin etmek için ANN kullanmışlardır. Gerçek ve tahmini test verilerini önerdikleri ANN 'ye uygulamışlardır. İstatistiksel

analizden, tahmini test verilerinin %95 doğruluk ile tespit etmişlerdir. Tablo 1’de literatürde yapılmış bazı çalışmaların kullandıkları yöntemler ve başarı oranları sunulmuştur.


**Tablo 1.** Literatürde yapılmış çalışmalar

Yazar	Yıl	Amaç	Yöntem	Başarı Oranı (%)
Xing ve Baerdemaeker (2005)	2005	Elmalarda çürük tespiti	Yumuşatma, eşikleme, Hyperspectral	86,4
Mohana ve Prabhakar (2015)	2015	Elmalarda sap ve çanak bölgelerinin tanınması	Multifractal, Fourier ve Radon dönüşümleri, SVM, ANN, k-NN, LDC ve AdaBoost sınıflayıcıları	94
Dubey ve Jalal (2016)	2016	Elma hatalarının otomatik tanınması için görüntü işleme çözümü	Lab-HSV Renk Uzayları, Kmeans kümeleme, SVM	93
Sa ve diğ. (2016)	2016	NIR ve RGB görüntülerde meyve algılama	Faster R-CNN	83
Fuentes ve diğ. (2017)	2017	Domateslerde hastalık ve zararlıların tespiti	Faster R-CNN	83-90
Lu ve Lu, (2017)	2017	Elmalarda çürük tespiti	Hyperspectral görüntüleme, otomatik eşikleme, açma ve doldurma işlemleri, Intermod, Ridler, Ünimode ve Otsu eşikleme	90
Zhang ve diğ., (2017)	2017	Elmaları çürüklük seviyelerine göre sınıflandırma	SVM, Hyperspectral	92,5

Bu çalışmada, elma meyvelerinden 830nm uzun dalga geçiren (long pass) filtreye sahip NIR kamera ile alınan görüntüler üzerinde evrimsel sinir ağı (ESA) yöntemi kullanılarak elmaların çürük ve sağlam şeklinde sınıflandırılması amaçlanmıştır. Literatür araştırmaları sonucunda elma meyvelerinde Faster R-CNN kullanılarak çürük tespiti üzerine yapılan ilk çalışma olduğu görülmektedir.

## 2. MATERYAL VE METOT

Literatürde elmalarda çürük tespiti üzerine yapılan çalışmalar incelendiğinde genellikle hiperspektral ve multispektral görüntüleme sistemlerinin kullanıldığı görülmektedir (Mohana ve Prabhakar, 2015; Lu ve Lu, 2017; Zhang ve diğ. 2017). Bu sistemler elma yüzeylerindeki çürüklerin daha iyi tespit edilmesini kolaylaştıracak spektral bölgenin belirlenmesini mümkün kılmaktadır. Ancak, bu sistemler hem yüksek maliyetlidir hem de laboratuvar ortamlarının dışında kullanımı pek mümkün değildir. Bu nedenle, görüntü alma aşamasında, tasarlanan ve içerisinde bir NIR kamera buluna görüntü alma platformu kullanılmıştır. Çalışmada, Türkiye’de en çok yetiştirilen elmalardan çürük ve sağlam örnekler toplanarak görüntü veri kümesi oluşturulmuştur. Veri kümesinde 100 adet çürük ve 100 adet sağlam olmak üzere toplam 200 adet elma kullanılmış, her bir elmanın 6 farklı yönünden toplam 1200 adet görüntü elde edilmiştir. Şekil 1’de alınan elma görüntülerinden örnekler verilmiştir.




**Şekil 1.** (a) sağlam elma; (b) çürük elma.

Şekil 1’de verilen elma görüntüleri önışlem uygulanmamış ham görüntülerdir. Önışleme aşamasında sırasıyla kırpma, uyarlamalı histogram eşitleme, kenar bulma ve morfolojik işlemler yapılarak sınıflandırma başarısını artırmak amaçlanmıştır. Önışlem yapılan görüntüler üzerinde ise bir derin öğrenme algoritması olan ESA modeli eğitilmiş, daha sonra bu model ile çürük bölgeler tespit edilerek elmalar sınıflandırılmıştır.

### 2.1. Evrişimsel Sinir Ağı (ESA) Modeli

Derin öğrenme modelleri, pek çok araştırma alanında olduğu gibi tarım teknolojilerinde de yaygın olarak kullanılan güçlü bir araç haline gelmiştir (Kamilaris ve Prenafeta-Boldú, 2018). En çok kullanılan modeller; Otomatik kodlayıcılar, Kısıtlı Boltzman Makineleri ve evrişimsel sinir ağlarıdır. ESA, görüntüler üzerinde sıkça kullanılan özelleşmiş bir derin öğrenme mimarisidir (Özcan, 2014). Geleneksel sinir ağlarından en önemli farkı görüntüden öznetelik çıkartılmasını kendisinin yapmasıdır. Geleneksel sinir ağlarına göre eğitim zamanı çok uzun olmasına rağmen birçok görüntü işleme probleminde oldukça başarılı sonuçlar vermektedir. ImageNet2012 ’de Krizhevsky ve diğ. (2012) ’nin derin öğrenme tekniğiyle birinci olmasının ardından, derin öğrenmenin görüntü sınıflandırmadaki başarısı görülmüş ve ertesi yıllarda yapılan ImageNet yarışmalarında birçok katılımcı derin öğrenme tekniğini kullanmış ve benzer başarıyı elde etmişlerdir.

Derin öğrenmenin görüntü işleme alanında en yaygın kullanılan modeli olan ESA mimarisi genel olarak eğitilebilen birçok katmandan oluşmaktadır. Şekil 2’de ESA mimarisinin genel yapısı görülmektedir.

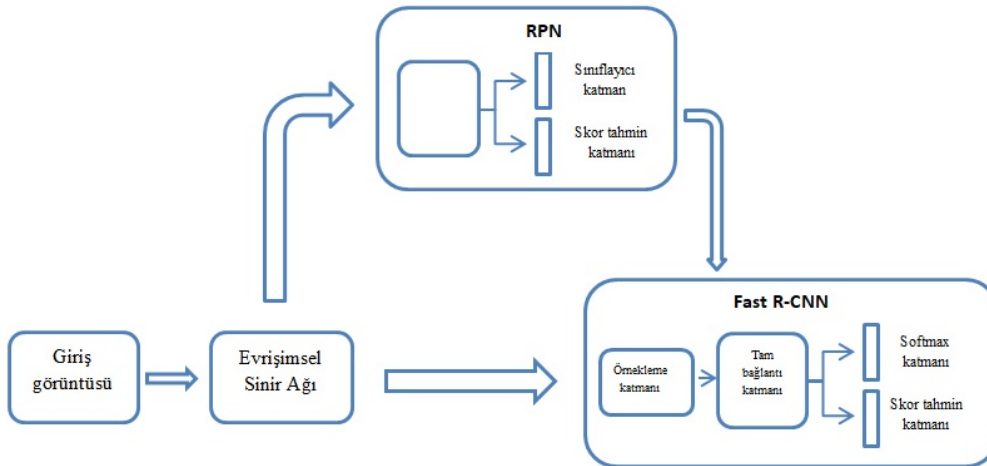


Şekil 2. ESA mimarisinin genel yapısı

Şekil 2 ‘de görüldüğü gibi, ESA mimarisi birbirini takip eden evrişim, alt-örneklemeye katmanları ve son olarak da tam bağlantılı softmax ağından oluşmaktadır. Görüntü ilk olarak parçalara ayrılır ve her bir parça üzerinde filtre uygulanır. Filtre işleminden sonra resimde küçülme olur. Bu işlem sonucunda elde edilen pikseller anlamlandırılarak problem çözülmeye çalışılır (Bengio ve diğ. 2016). Çalışmamızda ESA mimarisi üzerine kurulmuş bir yaklaşım olan Faster R-CNN (Fast Region-based Convolutional Neural Network) metodu kullanılmıştır.

### 2.2. Faster R-CNN

Faster R-CNN, RPN (Ren ve diğ. 2017) ile Fast R-CNN modellerinin (Girshick, 2015) birleştirilmiş halidir. Şekil 3 'te Faster R-CNN yapısını oluşturan RPN ve Fast R-CNN bölgeleri görülmektedir. RPN'in getirdiği yenilik, doğrudan örneklemeye katmanına bağlanılabilesidir. Böylece Faster R-CNN, güçlü yapısı ile görüntülerde baştan sona nesne tespitini gerçekleştirmek için bir çalışma ortamı sunar (Ren ve diğ. 2017).



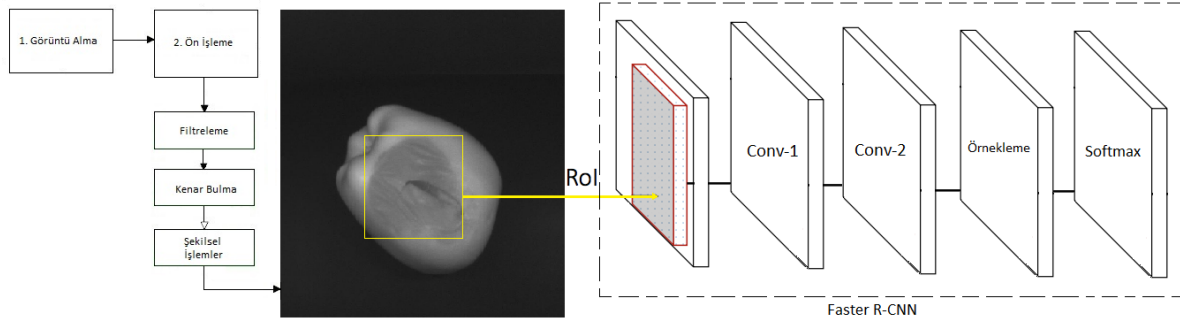
Şekil 3. Çalışmada kullanılan Faster R-CNN mimarisi (Yang ve diğ. 2017)

RPN tam olarak evrişimsel bir sinir ağıdır. Girdisi bir görüntü olan önerilen bölgeleri çıkartmak için kullanılır ve önerilen bölgelere aynı zamanda skorlar (tahmin etme doğruluğu) verilir. Önerilen bölgelerin sınıflama katmanı ve skor değerlerini tahmin katmanı aşamasında Fast R-CNN ağına birleştirilir. Fast R-CNN ağına da iki çıkış katmanı bulunmaktadır. Bunlardan ilki Softmax sınıflayıcı katmanı diğeri ise tespit edilen bölgenin tespit edilme doğruluğunu veren regresyon katmanıdır (Yang ve diğ. 2017).

Faster R-CNN ile giriş görüntüsü sınıflandırma süreci boyunca sadece bir kez hesaplanır ve daha sonra tespit edilmesi gereken bölgelerin buldukları yeri belirleyen kutuların sınırlarını düzeltir. Daha da fazlası, evrişimsel katmanların paylaşılması sayesinde, nesne tespitinin performansını geliştirmek için derin bir evrişimsel ağ eğitilebilir.


### 3. BULGULAR VE TARTIŞMA

Çalışmamızda ESA mimarisi üzerine kurulmuş bir yaklaşım olan Faster R-CNN modeli kullanılmıştır. Uygulama, Matlab yazılım ortamında Intel i7 6700HQ işlemci ve NVIDIA® GeForce® GTX 950M grafik kartı olan bir bilgisayar üzerinde koşturulmuştur. Şekil 4'te uygulamanın işlem adımları görülmektedir.



Şekil 4. Sistemin çalışma adımları

Şekil 4'te görüldüğü gibi, görüntüler üzerinde bir ön işleme uygulanmıştır. Bu aşamada önce görüntüde ilgilenilmeyen kısımlar kırılmış, daha sonra elma ile arka plan bölütlenmiş ve elmanın arka planı tamamen beyaz (255) hale getirilmiştir. Yapılan deneylerde bu durumun çürük tespitinin başarısını artırdığı görülmüştür. Bu işlem Şekil 5'de görülmektedir.



Şekil 5. Ön işleme adımları


Daha sonra görüntülerde elmanın sadece çürük bölgeleri dikdörtgen bir şekilde etiketlenmiş, bu etiketlerden oluşan görüntü veri seti Faster R-CNN modeline giriş olarak verilmiştir. Bu modelde bulunan iki evrişim katmanının her birinde 3x3 boyutlarında 32 filtre, doldurma değeri 1 ve adım sayısı 1, örnekleme katmanında ise 3x3 filtre boyutu ve adım sayısı 2 olarak belirlenmiştir. Tam bağlantılı katmanda sınıflayıcı olarak softmax kullanılmıştır. Görüntü veri kümesinin %70 'i eğitim kalan %30 'u ise test aşamasında kullanılmıştır. Ağın eğitimi 420 etiketlenmiş çürük elma görüntüsü üzerinde 12 saat sürmüştür. Çalışmada kullanılan modelin karışıklık matrisi Tablo 2'de verilmektedir.



**Tablo 2.** Çalışmada kullanılan modelin karışıklık matrisi

	Çürük	Sağlam
Çürük	155	25
Sağlam	29	151

Tablo 2 'de görüldüğü gibi gerçekte çürük olan 180 elma görüntüsünün 155 tanesi çürük olarak tespit edilmiş, kalan 25 adet görüntü sağlam olarak yanlış sınıflandırılmıştır. Aynı şekilde, gerçekte sağlam olan 180 elma görüntüsünün 151 tanesi sağlam olarak tespit edilmiş ve kalan 29 görüntü ise çürük olarak yanlış sınıflandırılmıştır. Modelin doğru sınıflandırma oranı %84,95 olmuştur. Şekil 6'da modelin test sonuçları görüntüler üzerinde etiketlenmiştir.

**Şekil 6.** Etiketlenmiş test sonuçları

Şekil 6'da etiketler çürük olarak tespit edilmiş bölgeleri ifade etmektedir. Etiketler üzerindeki rakamlar ise etiketlenen bölgenin çürük olma ihtimalini yüzde olarak göstermektedir. Önerilen model ile elde edilen başarı oranının Tablo 1 'de görüldüğü gibi literatürdeki bazı çalışmalardan düşük olmasının en önemli sebebi ilgili çalışmalarda hiperspektral ve multispektral görüntüleme sistemlerinin kullanılmasıdır (Mohana ve Prabhakar, 2015; Lu ve Lu, 2017; Zhang ve diğ. 2017). Ancak, bu sistemler hem yüksek maliyetlidir hem de laboratuvar ortamlarının dışında kullanımı pek mümkün değildir. Bu nedenle çalışmada daha düşük maliyetli olan NIR kamera görüntüleme sistemi ile birlikte derin öğrenme yaklaşımlarından Faster R-CNN modeli denenmiştir.

#### 4. SONUÇ

Bu çalışmada bir ESA modeli olan Faster R-CNN kullanılarak elmalar üzerindeki çürük bölgelerin tespiti yapılmıştır. Görüntü verisi olarak 200 adet elmanın 6 farklı açısından alınan 1200 adet görüntü kullanılmıştır. Deneysel çalışmalar sonucunda tek başına Faster R-CNN modeli kullanıldığında başarı oranının çok yüksek olmadığı tespit edilmiştir. Bunun en önemli sebebi elmaların anatomik bölgelerinden olan sap-çanak bölgelerinin çürük olarak sınıflandırılmasıdır. Bu nedenle bu bölgelerin görüntüde göz ardı edilmesi gerekmektedir. Ancak bu şekilde başarı oranları yükseltilebilir. Bir sonraki çalışmada planladığımız en önemli hedef, elmanın anatomik bölgelerinden olan sap-çanak kısımlarının görüntüden atılması yolu ile sınıflandırma başarısının artırılmasıdır. Bunun için ilk olarak, derin öğrenme ile elmanın sap-çanak kısımları tespit edilecek ve görüntüden atılacaktır. Daha sonra görüntü işleme ile kalan çürük bölgelerin kolayca tespit edilip sınıflandırılması sağlanacak, böylece görüntü işleme ve derin öğrenmenin birlikte kullanıldığı hibrit bir yaklaşım önerilmiş olacaktır. Bu çalışmada önerilen modelin

makineye uyarlanması durumunda, meyve suyu gıda sanayisinde elmaların otomatik olarak ayrıştırılması amacıyla kullanılabilmesi düşünülmektedir.

## REFERANSLAR

- Artık, N. (2018). Meyve ve sebze üretim teknolojisi. Ankara Üniversitesi Ders Notları. Erişim: [http://acikders.ankara.edu.tr/pluginfile.php/8059/mod\\_resource/content/0/1.%20hafta.pdf](http://acikders.ankara.edu.tr/pluginfile.php/8059/mod_resource/content/0/1.%20hafta.pdf)
- Barrett, D. M., Somogyi, L., & Ramaswamy, H. S. (2004). Processing fruits: science and technology, New York, USA, CRC press, 2, 455-480.
- Bengio, Y., Goodfellow, I., & Courville, A. (2016). Deep Learning, Cambridge, İngiltere, MIT yayınevi, 9, 326-366.
- Dubey, S. R., & Jalal, A. S. (2016). Apple disease classification using color, texture and shape features from images, Signal, Image and Video Processing, 10(5), 819-826.
- Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition, Sensors, 17(9), 2022.
- Girshick, R. (2015). Fast r-cnn, Proceedings of the IEEE international conference on computer vision, Santiago, Chile, 1440-1448.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey, Computers and Electronics in Agriculture, 147, 70-90.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks, In Advances in neural information processing systems, 1097-1105.
- Lu, Y., & Lu, R. (2017). Histogram-based automatic thresholding for bruise detection of apples by structured-illumination reflectance imaging, Biosystems Engineering, 160, 30-41.
- Mohana, S. H., & Prabhakar, C. J. (2015). Stem-Calyx Recognition of an Apple using Shape Descriptors. Signal & Image Processing : An International Journal (SIPIJ), 5(6), 17-31.
- Özcan, H. (2014). Çok Düşük Çözünürlüklü Yüz İmgelerinde Derin Öğrenme Uygulamaları, Yüksek Lisans Tezi, Bilgisayar Müh. Bölümü, Deniz Harp Okulu, İstanbul, Türkiye.
- Pandey, R., Naik, S., & Marfatia, R. (2013). Image processing and machine learning for automated fruit grading system: a technical review, International Journal of Computer Applications, 81, 29-39.
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis & Machine Intelligence, 6, 1137-1149.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). Deepfruits: A fruit detection system using deep neural networks, Sensors, 16(8), 1222.
- Xing, J., & Baerdemaeker, J. D. (2005). Bruise detection on 'Jonagold' apples using hyperspectral imaging, Postharvest Biology and Technology, 37(2), 152-162.
- Yang, S., Fang, B., Tang, W., Wu, X., Qian, J., & Yang, W. (2017). Faster R-CNN based microscopic cell detection, In Security, Pattern Analysis, and Cybernetics (SPAC), Shenzhen, China, 345-350.
- Zarifneshat, S., Rohani, A., Ghassemzadeh, H. R., Sadeghi, M., Ahmadi, E., & Zarifneshat, M. (2012). Predictions of apple bruise volume using artificial neural network. Computers and electronics in agriculture, 82, 75-86.
- Zhang, S., Wu, S., Zhang, S., Cheng, Q., & Tan, Z. (2017). An effective method to inspect and classify the bruising degree of apples based on the optical properties, Postharvest Biology and Technology, 127, 44-52.