



## International Journal of Engineering and Innovative Research

<http://dergipark.gov.tr/ijeir>

### ELMA BİTKİSİNDEKİ HASTALIKLARIN YAPAY ZEKÂ YÖNTEMLERİ İLE TESPİTİ VE YAPAY ZEKÂ YÖNTEMLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI

Bekir AKSOY<sup>1\*</sup>, Helin Diyar HALİS<sup>1</sup> Osamah Khaled Musleh SALMAN<sup>1</sup>

<sup>1</sup>Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Isparta, Türkiye.

<https://doi.org/10.47933/ijeir.772514>

\*Corresponding Author: [bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

(Received: 21.07.2020; Revised: 20.08.2020; Accepted: 28.08.2020)

**ÖZET:** Yapay zekânın hayatımıza girmesiyle tarım alanında yapılan yapay zekâ uygulamaları oldukça popüler hale gelmiştir. Tarım alanında karşılaşılan bitki hastalıkları üzerinde durulması gereken önemli bir konu olup bu problemin çözümü için yapay zekâdan yardım alınmaktadır. Çalışmada, elma bitkisindeki uyuz, siyah çürük ve pas hastalığına sahip yaprakların yapay zekâ ile tespiti için evrimsel sinir ağı (CNN) mimarileri kullanılmıştır. Çalışmada kullanılan CNN içerisinde yer alan AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve SqueezeNet1\_0 mimarilerinin karışıklık matrisine göre performansları değerlendirilerek en iyi doğruluk, duyarlılık, özgüllük ve F-skor değerleri bulunmuştur. Sonuç olarak test veri seti için yapay zekâ ile elma bitkisindeki hastalık tespitinde en iyi modelin duyarlılık, özgüllük, doğruluk ve F-skor için sırasıyla %97,64, %99,54, %99,52, %98,62 değerleri ile ResNet-34 olduğu belirlenmiştir.

**Anahtar Kelimeler:** Yapay zekâ, Tarım, Evrimsel sinir ağı

### IDENTIFICATION OF DISEASES IN APPLE PLANTS WITH ARTIFICIAL INTELLIGENCE METHODS AND COMPARISON OF THE PERFORMANCE OF ARTIFICIAL INTELLIGENCE METHODS

**ABSTRACT:** With the introduction of artificial intelligence into our lives, artificial intelligence applications in agriculture have become very popular. Plant diseases encountered in the field of agriculture are an important issue that should be emphasized and artificial intelligence is used for the solution of this problem. Convolutional Neural Network (CNN) architectures were used for the detection of leaves with scabies, black rot and rust diseases in apple plants with artificial intelligence. The best accuracy, sensitivity, specificity and F-score values were found by evaluating the performances of AlexNet, DenseNet-121, ResNet-34, VGG16-BN and SqueezeNet1\_0 models in the CNN architecture by using confusion matrix. As a result, in the detection of diseases in apple plants with artificial intelligence, the best sensitivity, specificity, accuracy and F-score on the test dataset were obtained with the ResNet-34 model, 97.64%, 99.54%, 99.52%, 98.62%, respectively.

**Keywords:** Artificial intelligence, Agriculture, Convolutional Neural Network (CNN)

## 1. GİRİŞ

Ziraat veya diğer bir anlamı ile tarım, bitkisel ve hayvansal ürünlerin üretilmesi, üretilen ürünlerin kalitesinin yükseltilmesi ve uygun şartlarda korunup işlenmesiyle ilgilenen bir bilim dalıdır [1]. Tarım sektörünün en temel amacı, insanlığın yaşamını sürdürebilmesi için gerekli olan ihtiyaçları karşılamaktır [2]. Tarım biliminin ana üretim dalları bitkisel ve hayvansal üretimlerdir [3]. Üretim aşamasında, artan nüfus akabinde artan taleplerin karşılanması ve iklim değişikliği sebebiyle gıda güvenliğinin sağlanması oldukça önemlidir [4, 5].

Tarımsal üretimde karşılaşılan bitki hastalıkları üzerinde durulması gereken önemli bir konudur. Bitki hastalıklarına fungal, bakteriyel ve viral hastalıklar neden olmaktadır [6]. Bitki hastalıkları, tarım sektöründe kayıplar yaşanmasına sebebiyet vermektedir. Bu doğrultuda ise bitki hastalıklarının tespiti, problemin çözümü için ilk ve en önemli aşamadır [7]. Hastalığın doğru ve zamanında tespit edilebilmesi, verim ve kalitenin düşmemesi için bitki korumaya yönelik uygulamalar artmıştır [7, 8]. Bitki hastalıklarında karşılaşılan problemlerin çözümü için kullanılan tekniklerin gelişmesiyle yapay zekâ yöntemi kullanılmaya başlanmıştır [9].

Yapay zekâ, insan zekâsını taklit ederek insan gibi davranış gösteren, mantık yürütebilen, kazandığı tecrübeler doğrultusunda kendini geliştirebilen ve eyleme dönüştüren yazılımsal ve donanımsal sistemler bütünüdür [10, 11]. Sosyal ve ekonomik faaliyetlerini önemli derecede etkileyen yapay zekâ, farklı alanlarda karmaşık olan verileri çeşitli yöntemler ile analiz ederek daha anlaşılabilir olması için yorumlamaktadır [12, 13].

Yapay zekâ kavramı ilk kez 1956 yılında Dartmouth konferansında geçmesine karşın bu alandaki çalışmalar oldukça eskiye dayanmaktadır [14]. 1921 yılında Karel Capek tarafından yapay zekâyâ sahip robotlar ve insanlığın ortak toplumsal sorunlarını ele alınan RUR adlı bilim kurgu tiyatro oyununda robot kelimesi literatüre tanıtılmıştır [15]. 1941 yılında elektronik bilgisayarın doğuşunun ardından makinelerin zekâ ile donatılma konusu ele alınmıştır [16].

1950 yılında Alan Turing, “Makineler düşünebilir mi?” sorusunu cevapladığı ve makinelerin düşünebilme olasılığı hakkında dönüm noktası olarak kabul edilen makalesinde literatüre Turing testi olarak geçen bir öneride bulunmuştur [17]. Turing testinde birkaç insandan oluşan deney grubu bilgisayar ile etkileşime girmekte ve belli bir süre yazışma sonrasında sorgulayıcıya hangisinin insan hangisinin makine zekâsı olduğu sorulmaktadır. Bu test sonucunda bilgisayar kendini sorgulayıcıya insan olduğuna ikna ettiği takdirde düşünme yeteneğine sahip olduğu kabul edilmektedir [18, 19].

Yapay zekânın belli bir dönem popülerliğini kaybetmesinin ardından 1997 yılında IBM Deep Blue yazılımı ilk kez satranç alanında büyük şampiyon olan Gary Kasparov’u yenmiş ve bu sayede tekrar popüler bir konu haline gelmiştir [20]. Yapay zekâ, 1950’lerden günümüze kadar önemli başarılar elde ederek gelmiş ve günümüzde insan beyninden ilham alan algoritmalar ile makinelerin kendi kendine öğrenme uygulamaları oldukça önemli hale gelmiştir [21].

Yapay zekâ, eğitim [22], tıp [23], otomotiv [24], siber güvenlik [25], bankacılık ve finansal hizmetler [26] gibi farklı birçok alanda kullanılmaktadır. Yapay zekânın kullanıldığı önemli alanlardan birisi de bitki hastalıklarının tespitidir. Günümüze kadar yapay zekânın farklı teknikleri kullanılarak bitki hastalıkları alanında çalışmalar yapılmıştır [27]. Bitkide oluşan

herhangi bir hastalık genellikle bitkinin yaprağından tespit edilmektedir. Bu doğrultuda yapılan çalışmalarda, sağlıklı ve hastalıklı yaprak görselleri makinenin eğitimi için kullanılmaktadır [28]. Yapay zekâ ile yaprak hastalıkları tanıma üzerine yapılan akademik çalışmalar incelendiğinde;

Wicaksono ve ark. [29] elma yaprağı hastalığının tespiti üzerine evrimsel sinir ağları (ing. Convolutional Neural Network-CNN) yöntemini kullanmışlardır. Çalışmalarında, PlantVillage veri seti kullanılarak uyuz, siyah çürük, sedir pas hastalığı ve sağlıklı yaprak görüntülerinden oluşan toplam 3151 görüntü verisi kullanmışlardır. Çalışmada evrimsel sinir ağlarının LeNet-5 mimarisi kullanılarak 50,75 ve 100 epoch sayıları için eğitim verilerinde %99,2 ortalama doğruluk, test sonucunda %94,9 oranında ortalama doğruluk elde etmişlerdir.

Cruz ve ark. [30] çalışmalarında, latince ismi “vitis vinifera” bitkisi olan üzümde görülen asma sarılığı (ing. grapevine yellows) hastalığının yapay zekâ ile tespiti üzerinde çalışmışlardır. Bu hastalık sonucu bitki düzensiz olarak olgunlaşarak yaprağında renk değişikliği göstermeye başlamaktadır. Çalışmalarında, asma görüntüleri etiketlenmiş olan açık kaynak PlantVillage veri setini kullanmışlardır. Çalışmalarında sonuç olarak, hastalığı tespit etmek için CNN yöntemi kullanarak en iyi performansın ResNet-101 ile ResNet-50 olduğunu belirtmişlerdir.

Shruthi ve ark. [31] bitki hastalıklarını tespit etmek ve sınıflandırmak amacıyla çalışmalarında destek vektör makineleri (ing. Support Vector Machine-SVM), yapay sinir ağları (YSA), k-en yakın komşu algoritması (k-NN), fuzzy sınıflandırıcı ve CNN’i kullanan çalışmaları incelemişlerdir. Çalışmada kullanılan beş farklı model birbirleriyle karşılaştırılmış ve sonuç olarak CNN yönteminin en yüksek doğruluk oranını verdiğini ifade etmişlerdir. Bu derleme makalesinde %96.3 ortalama doğruluk ile en yüksek doğruluk elde edilen çalışma (Sladoyevic ve ark. 2016) tarafından CNN sınıflandırıcı ile gerçekleştirilen çalışma olduğu görülmüştür.

Fang ve ark. [32] çalışmalarında elma yaprağı hastalığının belirlenmesi için CNN modelinin içerisinde yer alan VGG16 mimarisi kullanmışlardır. Çalışmada kullanılan modelde sınıflandırma doğruluğunu arttırmak için merkez kaybı fonksiyonu ile softmax kayıp fonksiyonu birlikte kullanılmıştır. Veri kümesi olarak antraknoz yaprak yanıklığı, sedir pas, yaprak pas, gri nokta, siyah nokta ve siyah çürük hastalığına sahip olan 5373 hastalıklı yaprak görüntüsü ve 1683 sağlıklı yaprak görüntüsü kullanılmıştır. Çalışmada sonuç olarak önerilen VGG16 modeli ile %95 - %99,70 arasında doğruluk elde edilmiştir.

Baranwal ve ark. [33] tarafından gerçekleştirilen çalışmada, elma yaprağı hastalığı tespiti için CNN içerisinde yer alan GoogLeNet mimarisinden yararlanılmıştır. 22 katmandan oluşan bu mimari, PlantVillage veri kümesinin alt kümesi üzerinde doğrulanmıştır. Veri seti olarak siyah çürük, uyuz ve pas hastalığına sahip 1526 hastalıklı yaprak görüntüleri ve sağlıklı yaprak görüntüleri kullanılmıştır. Çalışmada sonuç olarak önerilen GoogLeNet modelinin ortalama %98,42 doğruluk oranına sahip olduğu görülmüştür.

Alruwaili ve ark. [34] çalışmalarında bitki hastalığının tespiti için CNN içerisinde yer alan AlexNet mimarisini kullanmışlardır. Çalışmada, 14 farklı bitki türü ve 26 farklı hastalığın toplam 54.306 görüntüsü bulunan PlantVillage veri setini kullanmışlardır. Sonuç olarak önerilen AlexNet modeli ile %99,11 doğruluk, %99,49 hassasiyet, %99,29 oranında F1 skoru elde ederek AlexNet mimarisinin farklı bitki hastalıklarını etkin bir şekilde saptadığını ortaya koymuşlardır.

Ferentinos [35] çalışmasında, bitki hastalıklarının teşhisi için derin öğrenme modelleri geliştirmiştir. Çalışmada CNN kullanılarak modelin eğitim ve testi için açık kaynak ve 87.848 görüntüden oluşan veri seti kullanmıştır. Bu görüntüler 25 farklı bitki türünün 58 farklı hastalığını içermektedir. Çalışmada, AlexNet, AlexNetOWTBn, GoogLeNet, Overfeat, VGG modelleri kullanarak en yüksek başarı oranı VGG ile %99,53 olarak elde edilmiştir.

Khitthuk ve ark. [36] renkli görüntülerde bitki hastalık tanısı koymak üzerine yapay zekâ sistemi üzerinde çalışmışlardır. Çalışmalarında, hastalık özellik çıkarma işlemi için istatistik tabanlı gri düzey eş oluşum matrisi (ing. Gray-Level Co-Occurrence Matrix-GLCM) metodu kullanılarak her bir imgeden parametreler elde edilmiştir. Hastalık sınıflandırması için ise denetimsiz sinir ağı olan ARTMAP kullanılmıştır. Veri seti olarak pas, uyuz, tüylü küf hastalığı olan ve hastaliksız toplam 346 üzüm yaprağı görüntüsü kullanılmıştır. Çalışmada sonuç olarak, %90'nın üzerinde doğruluk elde etmişlerdir.

Singh ve Misra [37] çalışmalarında, bakteriyel hastalığı olan gül ve fasulye yaprağı, güneş yanığı hastalığı olan limon yaprağı ve erken yanık hastalığı olan muz yaprağını görüntü segmentasyonu olan genetik algoritma ile tespitini gerçekleştirmişlerdir. Çalışmada, önerilen algoritma ile SVM kullanıldığında genel doğruluk %95,71 oranında elde edilmiştir.

Sladoyeviç ve ark. [38] tarafından CNN kullanılarak geliştirilen model sağlıklı yaprağı ve 13 farklı bitki hastalığını tanıyabilmektedir. Çalışmada kullanılan veri setinde 13 farklı hastalık ve sağlıklı görüntülerin olduğu sınıf haricinde daha doğru sınıflandırma yapabilmek amacıyla arka plan görüntülerin olduğu sınıfta bulunmaktadır. Veri setinde bulunan 30880 görüntü eğitim, 2589 görüntü test için kullanılmıştır. CNN' in geliştirilmesi için 8 öğrenme katmanı, 5 evrimsel ve 3 tam bağlı katman içeren Caffe çerçevesi kullanılmıştır. Sonuç olarak model, %91 ile %98 arasında hassasiyet ve %96,3 doğruluk elde etmiştir.

Nachtigall ve ark. [39] çalışmalarında CNN kullanarak elma ağacındaki bozuklukları otomatik olarak tespit etmişlerdir. Çalışmada, maxigala, fuji suprema ve pink lady üç elma ağacı türündeki potasyum eksikliği, magnezyum eksikliği, uyuz hasarı, glomeralla lekeli ve herbisit hasarı olan beş bozukluk üzerine çalışma gerçekleştirmişlerdir. Veri kümesi olarak Brezilya'nın güney kesimindeki meyve bahçelerinden 1970 hastalıklı yaprak görüntüsü, 569 sağlıklı yaprak görüntüsü kullanmışlardır. CNN ile gerçekleştirilen çalışmada %97,3 doğruluk oranında sonuç elde edilmiştir.

Acar [40] çalışmasında, bitkinin kökleri ve yapraklarına gıda alımını durduran bir mantar hastalığı olan pas hastalığının yapay zekâ yöntemiyle tespiti üzerine çalışmıştır. Çalışmasında zambak çiçeği yaprak görüntülerinde pas hastalığı olup olmadığına dair GLCM ve gabor dalgacık dönüşümü (ing. Gabor Wavelet Transform-GWT) tabanlı sınıflandırıcıları öznelik çıkarma metodu olarak kullanılarak bir sistem tasarlanmıştır. Çalışmada veri seti olarak 32 sağlıklı görüntü, 21 hastalıklı görüntü üzerinde k-NN, çok katmanlı algılayıcı ve en küçük kareler SVM kullanmıştır. Sonuç olarak çalışmasında, GLCM tabanlı k-NN ve çok katmanlı YSA ile %88,9 oranında başarı elde ederek bitkideki pas hastalığını doğru tespit etmiştir.

Çalışmanın ilk bölümünde kısaca tarım, bitki hastalıkları, yapay zekâ ve yapay zekânın tarihçesinden, ikinci bölümünde yapay zekâ kullanılarak bitki hastalığı tespiti ile ilgili yapılan çalışmalardan bahsedilmiştir. Çalışmanın üçüncü bölümünde çalışmada kullanılan derin öğrenme modelleri, veri seti ve performans değerlendirme ölçütleri detaylı olarak açıklanmıştır. Çalışmanın dördüncü bölümünde ise elde edilen doğruluk, duyarlılık, özgüllük

ve F-skor deęerleri tablolar halinde verilmiřtir. alıřmanın sonu blmnde ise elma yapraklarında meydana gelen uyuz, siyah rk ve pas hastalıęı iin AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve Squeezenet1\_0 yapay zekâ modellerinin performans karřılařtırması yapılmıřtır.

## 2. MATERİYAL VE METOT

### 2.1. Materyal

Gerekleřtirilen alıřmada veri bilimciler ve makine ęrenimi uygulayıcı topluluęu olan aık eriřim internet sitesi [41] (<https://www.kaggle.com/>) ‘dan alınan veri seti kullanılmıřtır. Veri seti, elma yapraęına ait toplam 3171 adet grnt ile oluřturulmuřtur. Alınan veri setinde uyuz, siyah rk, pas hastalıęı ve saęlıklı olmak zere drt farklı elma yaprak sınıfı mevcuttur. Veri seti CNN modeli ierisinde yer alan, AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve Squeezenet 1\_0 olmak zere beř farklı mimari kullanılarak eęitilmiřtir. Elde edilen sonular duyarlılık, zgllk, doęruluk ve F-skor olmak zere drt farklı performans deęerlendirme ltne gre deęerlendirilmiřtir. alıřmada kullanılan derin ęrenme modelleri, veri seti ve performans deęerlendirme ltleri hakkında detaylı bilgiler ařaęıda verilmiřtir.

#### 2.1.1. Derin ęrenme

Derin ęrenme, son yıllarda makine ęrenimi konusunda heyecan verici bir eęilim olarak karřımıza ıkmaktadır [42]. Derin ęrenme klasik makine ęrenmesinin geniřletilmiř bir halidir. Bu geniřletilme modele daha fazla derinlik eklenerek verileri birkaç hiyerarřik yolla temsiline izin veren fonksiyonların kullanılması olarak tanımlanmaktadır [43]. Derin ęrenme modellerinin yksek hiyerarřik yapısı ve geniř ęrenme kapasitesi sınıflandırma ve tahminlerin tutarlılıkla yapılmasına olanak saęlamaktadır [44]. YSA’nın ok katmanlı ve ok nronlu hali olan derin sinir aęlarının en nemli zellięi probleme uygun olarak otomatik znitelik ıkarımı yapılması ve bu zniteliklerin aęın ęrenmesiyle oluřmasıdır [45].

CNN mimarisi; derin ęrenmenin eřitli algoritmaları arasında poplerlięi ile ne ıkmaktadır [46]. CNN beynin grsel korteksinden ilham alarak temel olarak grnty sınıflandırmak, benzerlikleri kmelemek ve nesne tanıma yapmak iin kullanılmaktadır [47, 48]. Bu mimari, grnty eřitli katmanlarla iřleyerek evriřim katmanları, doęrusal olmayan katmanlar, havuz katmanları ve tamamen baęlı katmanlardan oluřmaktadır [49]. Őekil 1’de rnek bir CNN mimarisinin temel yapısı gsterilmektedir [47]. Evriřim katmanı en yoęun matematiksel iřlemin gerekleřtięi katman olup grntdeki dřk ve yksek seviyeli zellikleri saptamak iin grntye bazı filtreler uygulamakta, aktivasyon katmanı olarakta adlandırılan doęrusal olmayan katmanda sisteme doęrusal olmayanlıęın tanıtılması gerekleřtirilmekte ve genellikle en iyi sonucu verdięi iin ReLu fonksiyonu kullanılmaktadır. Havuzlama katmanı aę iindeki parametrelerin azaltılması iin zellik haritalarının boyutlarını kltterek sistem zerindeki aęrılık sayısını azaltmaktadır. Tamamen baęlı katmanlar ise giriř ve ıkıř katmanları arasında baę kurarak modelde sınıflandırıcı grevi stlenmektedir [50,51].



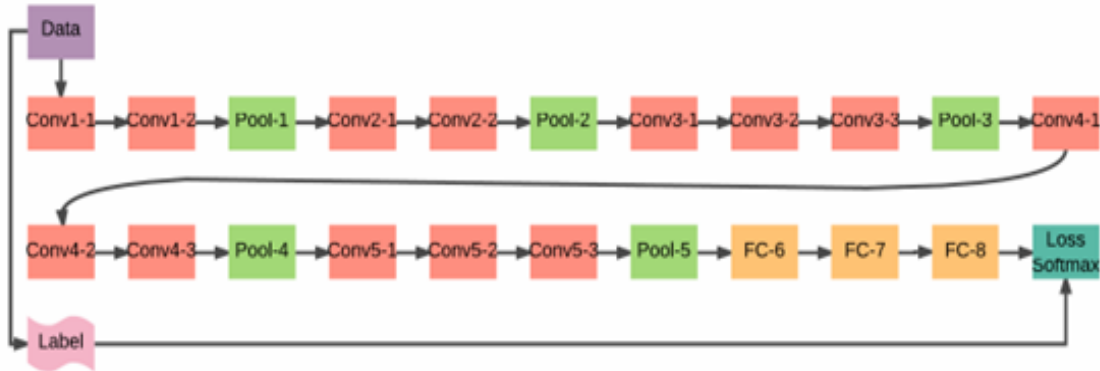
hatasını azaltmak için çok sayıda katman içeren bloklar kullanılmakta ve referanslandırılmamış işlevleri öğrenmek yerine artık değerler sonraki katmanlara eklenmektedir. ResNet mimarisinde katmanlar arasındaki atlama işlemi sayesinde ise kaybolan gradyan problemi de çözülmektedir [63, 64].

#### 2.1.1.4. SqueezeNet

CNN modelinde kullanılan bir diğer popüler mimari ise SqueezeNet mimarisidir [65]. SqueezeNet mimarisi Iandola ve ark. tarafından 2016 yılında sunulmuştur [66]. Bu mimarinin amacı daha az parametreye sahip bir sinir ağı oluşturmak ve mimari 50 kat daha az parametre ile AlexNet düzeyinde doğruluk sağlamaktadır [67]. SqueezeNet mimarisinin avantajı ise daha verimli dağıtılmış katmanlar sayesinde sinir ağındaki iş yükü azalmakta ve bu sayede daha hızlı çalışmaktadır [67, 68].

#### 2.1.1.5. VGG16-BN

VGG-16 mimarisi Simonyan ve Zisserman tarafından sunulmuştur [69]. VGG16, tamamen bağlı ağı eğiten yaklaşık 138 milyon parametreye sahip büyük ölçekli görüntü tanıma modelidir [70]. VGG16 mimarisi 16 katmandan (13 evrişim, 3 tam bağlı katman) oluşmakta ve nesne sınıflandırma uygulamalarında kullanılmaktadır [71]. Şekil 3'de VGG16 mimarisinin görünümü verilmiştir [72].




Şekil 3. VGG16 mimarisi [72].

#### 2.1.2. Veri seti

Önerilen mimariler bitki hastalığı tespit sisteminde kullanılan PlantVillage veri seti üzerinde eğitilmiştir. Kullanılan veri seti 14 farklı ürün için 54.306 etiketli görüntü içermektedir. Çalışmada, PlantVillage veri setinde bulunan 3171 elma yaprağı görüntüsü kullanılmaktadır. Şekil 4'de elma yapraklarında meydana gelen uyuz, siyah çürük, pas hastalığına sahip örnek görüntüler ve sağlıklı yaprak görüntüsü gösterilmektedir.





**Şekil 4.** PlantVillage veri setinden örnek elma yaprağı görüntüleri a)uyuz b)pas c)siyah çürük d)sağlıklı.

Çalışmada kullanılan yaprak görüntüleri %65 eğitim, %15 doğrulama ve %20 test veri kümesi için ayrılmaktadır. Tablo 1’de elma yaprağı veri kümesinde bulunan hastalıklı ve sağlıklı yaprak görüntüleri detaylı olarak gösterilmektedir.

**Tablo 1.** Elma Yapracağı Veri Seti.

Veri	Uyuz hastalığı olan yaprak görüntüsü	Siyah çürük hastalığı olan yaprak görüntüsü	Pas hastalığı olan yaprak görüntüsü	Sağlıklı yaprak görüntüsü	Toplam
Eğitim veri seti	410	404	179	1.070	2.063
Doğrulama	94	93	41	246	474
Test veri seti	126	124	55	329	634

### 2.1.3. Performans değerlendirme ölçütleri

Modellerin performansını değerlendirmek için sıklıkla karmaşıklık matris (confusion matrix) yöntemi kullanılmaktadır. Tablo 2’de gösterilen karmaşıklık matrisi gerçek sınıf ve sınıflandırıcının tahmin ettiği sınıf olmak üzere iki boyuta sahiptir [73]. Karmaşıklık matrisi sayesinde birçok sınıflandırma performansı tanımlanabilmektedir [74].

**Tablo 2.** Karmaşıklık Matrisi.

GERÇEK DEĞER	TAHMİN EDİLEN DEĞER		
		POZİTİF	NEGATİF
	POZİTİF	DOĞRU POZİTİF (True positive-TP)	YANLIŞ POZİTİF (False positive-FP)
NEGATİF	YANLIŞ NEGATİF (False negative-FN)	GERÇEK NEGATİF (True negative-TN)	

Duyarlılık (Sensitivity) modelin girdilerden pozitif sınıf etiketini tahmin etmedeki olasılığını göstermektedir. Duyarlılık, Eşitlik 1’de verilen matematiksel ifade kullanılarak hesaplanmaktadır.



$$Duyarluluk = \frac{DP}{DP+YP} \quad (1)$$

Özgüllük (Spesifite) modelin girdilerden negatif sınıf etiketini tahmin etmedeki olasılığını göstermektedir. Özgüllük, Eşitlik 2'de verilen matematiksel ifade kullanılarak hesaplanmaktadır.

$$Özgüllük = \frac{DN}{DN+YN} \quad (2)$$

Doğruluk (Accuracy) modelin genel olarak doğru olup olmadığını belirlemede kullanılmaktadır. Doğruluk, Eşitlik 3'de verilen matematiksel ifade kullanılarak hesaplanmaktadır.

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

F-Skor (F-Score) kesinlik ve duyarlılık performans değerlendirme ölçütlerini birlikte değerlendirme imkânı sağlayan bir değerlendirme ölçütüdür. F skor Eşitlik 4'de verilen matematiksel ifade kullanılarak hesaplanmaktadır [75].

$$F - Skor = \frac{2DP}{2DP+YP+YN} \quad (4)$$

Denklemleri verilen ölçütler ikili sınıflandırma yapılırken kullanılmaktadır. Üç veya daha fazla sınıftan oluşan uygulamalarda performans değerlendirirken her sınıf için hesaplanan ölçümlerin ortalaması alınmaktadır [76]. Doğru ve yanlış sınıflandırmanın oranlarını gösteren matrisler üzerinde ortalama doğruluk, özgüllük, duyarlılık ve F-Skor değeri Eşitlik 5, 6, 7, 8'de verilen matematiksel ifadeler kullanılarak hesaplanmaktadır [76,77].

$$Ortalama Doğruluk = \frac{\sum_{i=1}^l \frac{DP_i+DN_i}{DP_i+YN_i+YP_i+DN_i}}{l} \quad (5)$$

$$Ort. Özgüllük = \frac{\sum_{i=1}^l \frac{DN_i}{DN_i+YN_i}}{l} \quad (6)$$

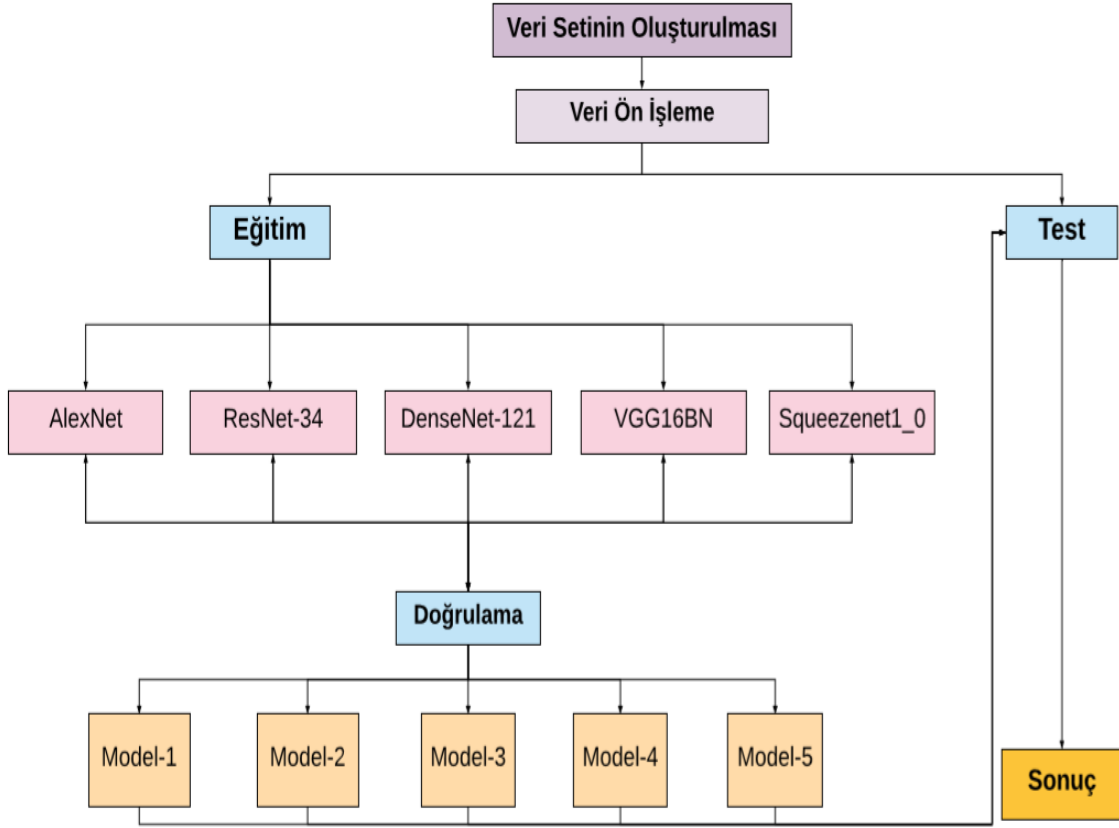
$$Ort. Duyarluluk = \frac{\sum_{i=1}^l \frac{DP_i}{DP_i+YN_i}}{l} \quad (7)$$

$$Ort. F - deęeri = \frac{\sum_{i=1}^l \frac{2DP_i}{2DP_i+YP_i+YN_i}}{l} \quad (8)$$

## 2.2. Metot

Gerçekleştirilen çalışmanın iş akış diyagramı Şekil 5'de verilmiştir. İlk aşamada açık kaynaklı internet sitesi Kaggle'da yer alan PlantVillage veri setinden 3171 adet elma yaprağı görüntüsü alınarak veri seti oluşturulmuştur. Veri seti içerisinde uyuz, siyah çürük, pas hastalığı olan ve sağlıklı yaprak görüntüleri etiketlenmiştir. Dört farklı sınıf bulunan veri setinde eğitim için toplam 2.063 görüntü, doğrulama için 474 görüntü ve test için 634 görüntü kullanılmıştır. İkinci aşama olan veri ön işleme aşamasında ise normalizasyon işlemi gerçekleştirilmiştir. Üçüncü aşamada görüntüler AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve Squeezenet1\_0 derin öğrenme modelleri eğitilerek en doğru yöntem tespit edilmiştir. Tüm modeller için elde edilen eğitim oranları optimize edilerek 0.005 olarak belirlenmiştir.

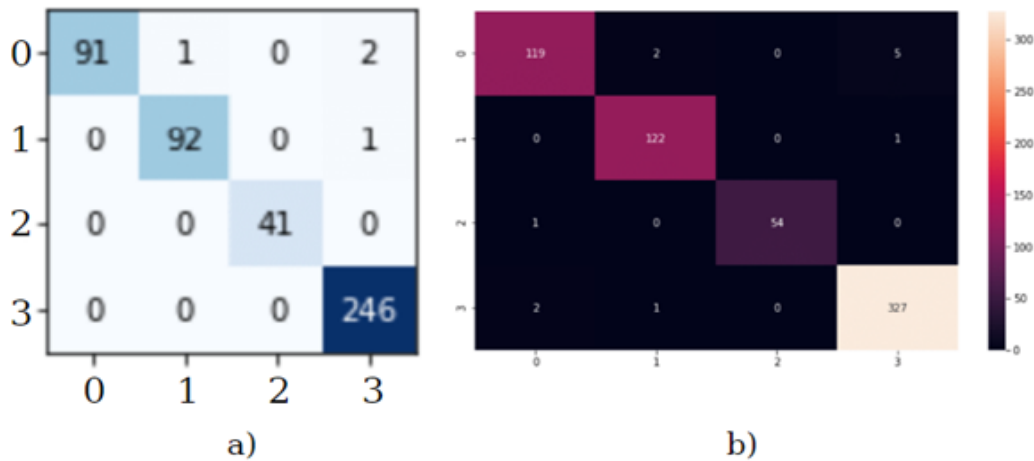
Eđitilen modeller üzerinde hem dođrulama hem test işlemleri uygulanarak modelin dođruluđu test edilmiştir.



Şekil 5. İş akış diyagramı.

### 3. ARAŞTIRMA BULGULARI

Çalışmada AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve SqueezeNet1\_0 olmak üzere beş farklı derin öğrenme yöntemi kullanılarak elma bitkisine ait uyuz, siyah çürük, pas hastalığı olan ve sağlıklı yaprak olmak üzere dört sınıf eğitilmiştir. Eğitilen modeller üzerinde hem dođrulama hem de test işlemleri uygulanarak aşağıdaki sonuçlar elde edilmiştir. İlk olarak AlexNet modelinin dođrulama ve test veri seti için karmaşıklık matrisi Şekil 6'da verilmiştir.



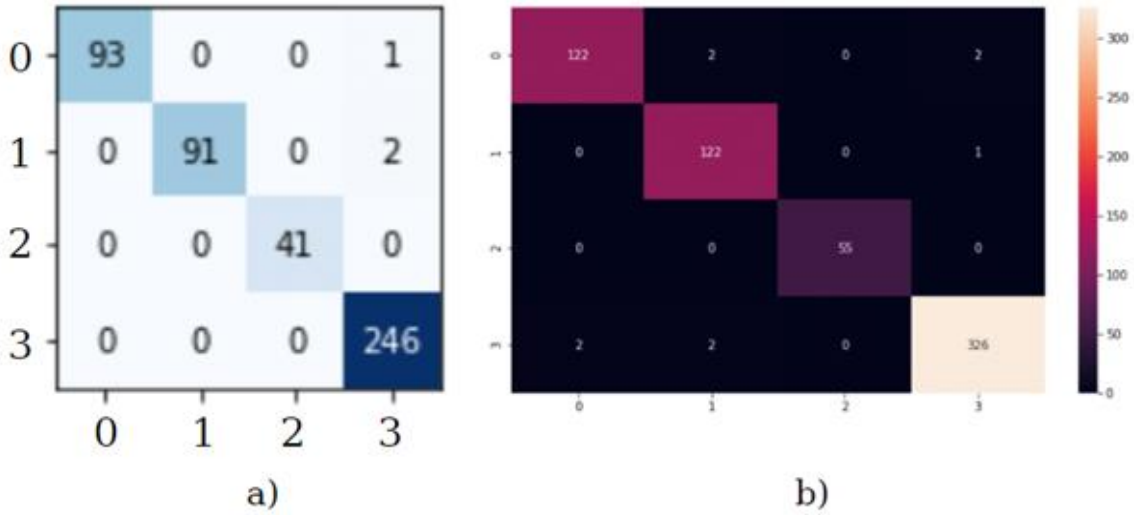
Şekil 6. AlexNet modeli(a) dođrulama veri seti için (b) test veri seti için karmaşıklık matrisi.

Karmaşıklık matrisinde sıfırinci indeks elma yaprağındaki uyuz hastalığını, birinci indeks siyah çürük hastalığını, ikinci indeks pas hastalığını ve üçüncü indeks sağlıklı yaprak görüntülerini göstermektedir. AlexNet modelinin performans değerlendirme ölçütleri Tablo 3’de gösterilmektedir.

**Tablo 3.** AlexNet Performans Değerlendirme Ölçütleri.

Veri	Duyarlılık	Özgüllük	Doğruluk	F-Skor
Doğrulama veri seti	0,96316	0,99075	0,99156	0,97566
Test veri seti	0,91855	0,97995	0,98099	0,94677

DenseNet-121 modelinin doğrulama ve test veri seti için karmaşıklık matrisi Şekil 7’de verilmiştir.



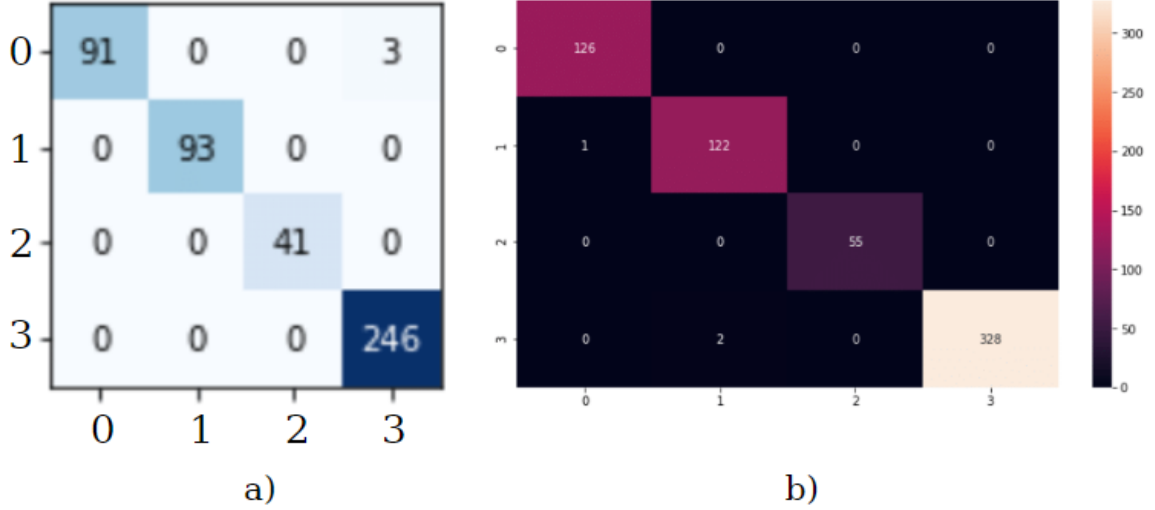
**Şekil 7.** DenseNet-121 modeli (a) doğrulama veri seti için (b) test veri seti için karmaşıklık matrisi.

DenseNet-121 modelinin performans değerlendirme ölçütleri Tablo 4’de gösterilmektedir.

**Tablo 4.** DenseNet-121 Performans Değerlendirme Ölçütleri.

Veri	Duyarlılık	Özgüllük	Doğruluk	F-Skor
Doğrulama veri seti	0,97196	0,99300	0,99367	0,98163
Test veri seti	0,93584	0,98562	0,98580	0,95990

ResNet-34 modelinin doğrulama ve test veri seti için karmaşıklık matrisi Şekil 8’de verilmiştir.



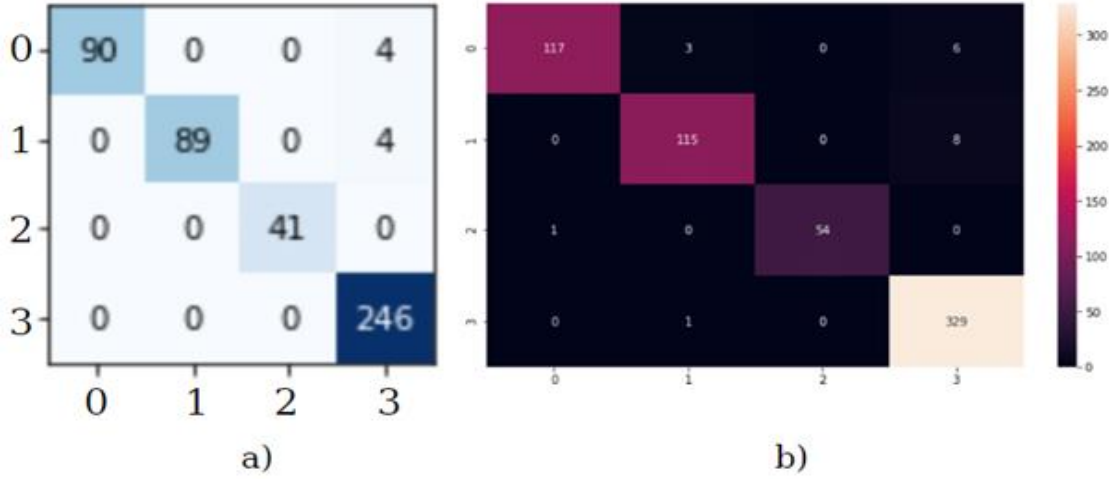
Şekil 8. ResNet-34 modeli (a) doğrulama veri seti için (b) test veri seti için karmaşıklık matrisi.

ResNet-34 modelinin performans değerlendirme ölçütleri Tablo 5’de gösterilmektedir.

Tablo 5. ResNet-34 Performans Değerlendirme Ölçütleri.

Veri	Duyarlılık	Özgüllük	Doğruluk	F-Skor
Doğrulama veri seti	0,97212	0,99300	0,99367	0,98163
Test veri seti	0,97646	0,99542	0,99526	0,98624

VGG16-BN modelinin doğrulama ve test veri seti için karmaşıklık matrisi Şekil 9’da verilmiştir.



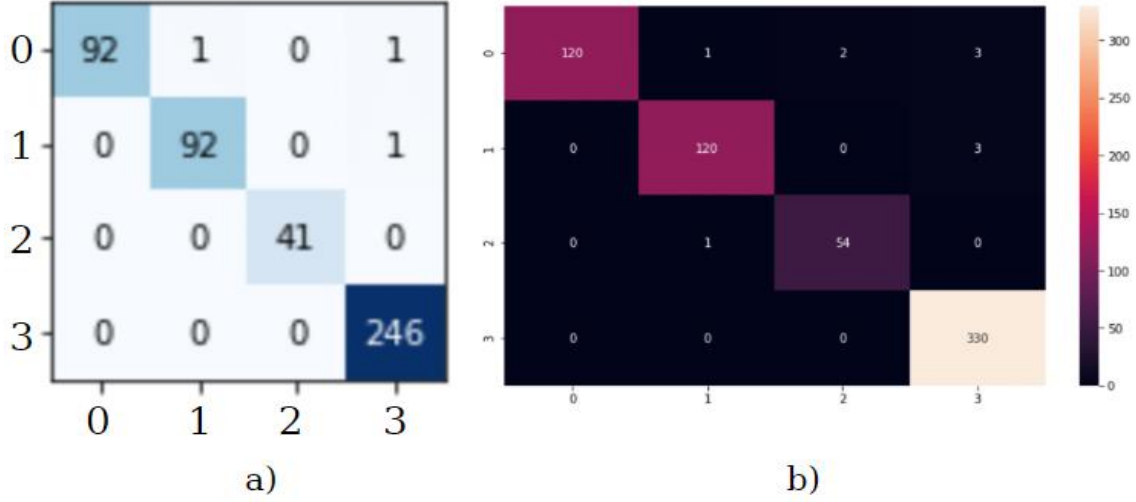
Şekil 9. VGG16-BN modeli (a) doğrulama veri seti için (b) test veri seti için karmaşıklık matrisi.

VGG16-BN modelinin performans değerlendirme ölçütleri Tablo 6’da gösterilmektedir.

Tablo 6. VGG16-BN Performans Değerlendirme Ölçütleri.

Veri	Duyarlılık	Özgüllük	Doğruluk	F-Skor
Doğrulama veri seti	0,92991	0,98135	0,98312	0,95238
Test veri seti	0,88302	0,96712	0,97003	0,91809

SqueezeNet1\_0 modelinin doğrulama ve test veri seti için karmaşıklık matrisi Şekil 10'da verilmiştir.



Şekil 10. SqueezeNet1\_0 modeli (a) doğrulama veri seti için (b) test veri seti için karmaşıklık matrisi.

SqueezeNet1\_0 modelinin performans değerlendirme ölçütleri Tablo 7'de gösterilmektedir.

Tablo 7. SqueezeNet1\_0 Performans Değerlendirme Ölçütleri.

Veri	Duyarlılık	Özgüllük	Doğruluk	F-Skor
Doğrulama veri seti	0,97193	0,99300	0,99367	0,98163
Test veri seti	0,93508	0,98249	0,98422	0,95508

Tablo 8'de, AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve SqueezeNet1\_0 modelleri için duyarlılık, özgüllük, doğruluk ve F-skor değerleri verilmiştir.

Tablo 8. AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve SqueezeNet1\_0 Performans Değerlendirme Ölçütleri.

Model	Duyarlılık		Özgüllük		Doğruluk		F-Score	
	Doğrulama	Test	Doğrulama	Test	Doğrulama	Test	Doğrulama	Test
AlexNet	0,96316	0,91855	0,99075	0,97995	0,99156	0,98099	0,97566	0,94677
DenseNet-121	0,97193	0,93562	0,99300	0,98562	0,99367	0,98580	0,98163	0,95990
<b>ResNet-34</b>	<b>0,97212</b>	<b>0,97646</b>	<b>0,99300</b>	<b>0,99542</b>	<b>0,99367</b>	<b>0,99526</b>	<b>0,98163</b>	<b>0,98624</b>
VGG16-BN	0,92991	0,88302	0,98135	0,96712	0,98312	0,97003	0,95238	0,91809
SqueezeNet1_0	0,97193	0,93508	0,99300	0,98249	0,99367	0,98422	0,98163	0,95508

#### 4. SONUÇ

Çalışmada CNN içerisinde yer alan AlexNet, DenseNet-121, ResNet-34, VGG16-BN ve Squeezenet1\_0 mimarileri elma bitkisi hastalıklarının tespiti için kullanılmıştır. Elde edilen sonuçlar dört farklı performans değerlendirme ölçütüne göre değerlendirilerek aşağıdaki sonuçlar elde edilmiştir.

- Modeller performans değerlendirme ölçütü olan karışıklık matrisine göre değerlendirilmiştir. Değerlendirme sonucunda modelin uyuz, siyah çürük, pas hastalığı olan ve sağlıklı yaprakları tespit edebildiği görülmüştür.
- Modeller duyarlılık, özgüllük, doğruluk ve F-skor performans değerlendirme ölçütlerine göre değerlendirilmiştir. Değerlendirme sonucunda doğrulama veri setinde duyarlılık için en iyi sonucun %97.21 ile ResNet-34, özgüllük için %99.3 ile DenseNet-121, ResNet-34 ve Squeezenet1\_0, doğruluk için %99.3 ile DenseNet-121, ResNet-121 ve Squeezenet1\_0 ve son değerlendirme ölçütü olan F-skor için ise %98.16 ile DenseNet-121, ResNet-121 ve Squeezenet1\_0 olduğu ortaya konulmuştur.
- Değerlendirme sonucunda test veri setinde duyarlılık, özgüllük, doğruluk ve F-skor için en iyi sonucun sırasıyla %97.64, %99.54, %99.52, %98.62 değerleri ile ResNet-34 mimarisi olduğu ortaya konulmuştur.

Sonuç olarak yapay zekâ ile elma bitkisindeki hastalık tespitinde en iyi modelin ResNet-34 mimarisi olduğu belirlenmiştir.

#### Teşekkür

Çalışmada kullanılan PlantVillage veri setininin açık kaynak verilerini internet sitelerinde (Kaggle) kullanıma açan herkese teşekkürü bir borç biliriz.

#### KAYNAKÇA

- [1] Direk, M. Tarım tarihi ve deontoloji. 2th ed: 2012.
- [2] Türker MMÖÜ, Akdemir B, Acar AÇAI., Öztürk R, Eminoğlu MB. Tarımda dijital çağ. Türkiye Ziraat Mühendisliği IX. Teknik Kongresi Bildiriler Kitabı-1. Ankara: Ankara Üniversitesi Basın Yayın Müdürlüğü; 2020. p. 55-78.
- [3] Tümenbatur A. (2019). Tarım-gıda bütünleşik tedarik zinciri tasarımı: domates ürünü uygulaması. İstanbul: Maltepe Üniversitesi; 2019.
- [4] Hayaloğlu P. İklim değişikliğinin tarım sektörü ve ekonomik büyüme üzerindeki etkileri. Gümüşhane University Electronic Journal of the Institute of Social Science/Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi. 2018; 9(25):1-12.
- [5] Özaydın G, Çelik Y. Tarım sektöründe arge ve inovasyon. Tarım Ekonomisi Dergisi. 2019; 25(1):1-13.
- [6] Korkmaz F, Topkaya Ş, Yanar Y. Tokat Kabakgil üretim alanlarında enfeksiyon oluşturan virüslerin belirlenmesi. Gaziosmanpaşa Bilimsel Araştırma Dergisi. 2018;7(2):46-56.
- [7] Eğilmez D, Boyraz N. Aksaray ili buğday ve arpa ekim alanlarındaki fungal hastalıkların son yıllardaki görünümü üzerine bir araştırma. Bahri Dağdaş Bitkisel Araştırma Dergisi. 2019; 8(2):322-335.
- [8] Canhilal R, Tiryaki O. Kayseri ve civarında bitki koruma uygulamaları: problemler ve çözüm önerileri. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi. 2010; 26(2):88-101.
- [9] Altas Z, Ozguven MM, Yanar Y. Determination of sugar beet leaf spot disease level (cercoospora beticola sacc.) with image processing technique by using drone. Current Investigations in Agriculture and Current Research. 2018;5(3):621-631.
- [10] Russell SJ, Norvig P. Artificial intelligence: a modern approach. 3rd ed. Pearson Education Inc:New Jersey;2016.
- [11] Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. Stroke and Vascular Neurology. 2017;2(4):230-243.
- [12] Lu H, Li Y, Chen M, Kim H, Serikawa S. Brain intelligence: go beyond artificial intelligence. Mobile Networks and Applications. 2018;23(2):368-375.

- [13] Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts, HJ. Artificial intelligence in radiology. *Nature Reviews Cancer*. 2018;18(8):500-510.
- [14] El Naqa I, Haider MA, Giger ML, & Ten Haken RK. Artificial Intelligence: reshaping the practice of radiological sciences in the 21st century. *The British Journal of Radiology*. 2020; 93(1106): 1-15.
- [15] Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism*. 2017; 69(1):36-40.
- [16] Çoban T. Sinemada yapay zeka. Ordu: Ordu Üniversitesi Sosyal Bilimler Enstitüsü; 2018.
- [17] Warwick K, Shah H. Can machines think? a report on turing test experiments at the royal society. *Journal of experimental & Theoretical artificial Intelligence*. 2016;28(6):989-1007.
- [18] Sindhuja R. Artificial intelligence and its applications in various fields. *International Journal for Research Trends and Innovation*. 2018;3(8)
- [19] Sucu İ, Ataman E. Dijital evrenin yeni dünyası olarak yapay zeka ve her filmi üzerine bir çalışma. *Yeni Medya Elektronik Dergisi*. 2020; 4(1):40-52.
- [20] Evans GW. *Artificial intelligence: where we came from, where we are now, and where we are going*. Victoria: University of Victoria; 2017.
- [21] Jaakkola H, Henno J, Mäkelä J, Thalheim B. Artificial intelligence yesterday, today and tomorrow. 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2019. Opatija Croatia: IEEE;2019. p. 860-867.
- [22] Wang, F., & Tao, X. (2018, December). Visual Analysis of the Application of Artificial Intelligence in Education. In 2018 International Joint Conference on Information, Media and Engineering (ICIME) (pp. 187-191). IEEE.
- [23] Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature medicine*, 25(1), 44-56.
- [24] Luckow, A., Kennedy, K., Ziolkowski, M., Djerekarov, E., Cook, M., Duffy, E., ... & Smith, M. C. (2018, December). Artificial intelligence and deep learning applications for automotive manufacturing. In 2018 IEEE International Conference on Big Data (Big Data) (pp. 3144-3152). IEEE.
- [25] Süzen, A. A. (2020). Developing a multi-level intrusion detection system using hybrid-DBN. *Journal of Ambient Intelligence and Humanized Computing*, 1-11.
- [26] Wall, L. D. (2018). Some financial regulatory implications of artificial intelligence. *Journal of Economics and Business*, 100, 55-63.
- [27] Odası ZM. Türkiye ziraat mühendisliği 1x. teknik kongresi bildiriler kitabı-1. 2020.
- [28] Korkut UB, Göktürk ÖB, Yıldız O. Detection of plant diseases by machine learning. 26th Signal Processing and Communications Applications Conference, SIU 2018. Izmir Turkey: IEEE;2018. p. 1-4.
- [29] Wicaksono G, Andryana S. Aplikasi pendeteksi penyakit pada daun tanaman apel dengan metode convolutional neural network. *Journal of Information Technology and Computer Science*. 2020; 5(1):9-16.
- [30] Cruz A, Ampatzidis Y, Pierro R, Materazzi A, Panattoni A, De Bellis L, Luvisi A, et al. Detection of grapevine yellows symptoms in *vitis vinifera* L. with artificial intelligence. *Computers and electronics in agriculture*. 2019;157:63-76.
- [31] Shruthi U, Nagaveni V, Raghavendra BK. A review on machine learning classification techniques for plant disease detection. 5th International Conference on Advanced Computing & Communication Systems, ICACCS 2019. Coimbatore, India: IEEE; 2019. p. 281-284.
- [32] Fang T, Chen P, Zhang J, Wang B. Identification of apple leaf diseases based on convolutional neural network. In *International Conference on Intelligent Computing 2019*. Cham: Springer; 2019. p. 553-564.
- [33] Baranwal S, Khandelwal S, Arora A. Deep learning convolutional neural network for apple leaves disease detection. *Proceedings of International Conference on Sustainable Computing in Science, Technology and Management, SUSCOM 2019*. India: SSRN;2019. p. 260-267.
- [34] Alruwaili M, Abd El-Ghany S, Shehab A. An enhanced plant disease classifier model based on deep learning techniques. *International Journal of Engineering and Advanced Technology*. 2019;9(1):7159-7164.
- [35] Ferentinos KP. Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*. 2018;145:311-318.
- [36] Khitthuk C, Srikaew A, Attakitmongkol K, Kumsawat P. Plant Leaf Disease Diagnosis from Color Imagery Using Co-Occurrence Matrix and Artificial Intelligence System. *International Electrical Engineering Congress, IEECON 2018*. Thailand: IEEE; 2019. p. 1-4.
- [37] Singh V, Misra AK. Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information processing in Agriculture*. 2017;4(1):41-49.
- [38] Sladojevic S, Arsenovic M, Anderla A, Culibrk D, Stefanovic D. Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience*. 2016
- [39] Nachtigall LG, Araujo RM, Nachtigall GR. Classification of apple tree disorders using convolutional neural Networks. 28th International Conference on Tools with Artificial Intelligence, ICTAI 2016. San Jose, CA, USA: IEEE;2016. p. 472-476.



- [40] Acar E. Yapay zeka yöntemleriyle bitki yaprak imgelerinde pas hastalıklarının tespiti [yüksek lisans tezi]. Diyarbakır: Dicle Üniversitesi; 2015
- [41] <https://www.kaggle.com/abdallahalidev/plantvillage-dataset> (Erişim Tarihi: 18.05.2020)
- [42] Ravi D, Wong C, Deligianni F, Berthelot M, Andreu-Perez J, Lo B, Yang GZ. Deep learning for health informatics. *Journal of biomedical and health informatics, IEEE*. 2016;21(1):4-21.
- [43] Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*. Elsevier. 2015;61:85-117.
- [44] Pan SJ, Yang Q. A survey on transfer learning. *Transactions on knowledge and data engineering, IEEE*. 2009;22(10):1345-1359.
- [45] Kızrak MA, Bolat B. Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 2018;11(3):263-286.
- [46] Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Chen T, et al. Recent advances in convolutional neural networks. *Pattern Recognition*. 2018;77,:354-377.
- [47] Min S, Lee B, Yoon S. Deep learning in bioinformatics. *Briefings in bioinformatics*. 2017;18(5):851-869.
- [48] Milletari F, Navab N, Ahmadi SA. V-net: Fully convolutional neural networks for volumetric medical image segmentation. *Fourth International Conference on 3D Vision, 3DV 2016*. ABD: IEEE; 2016. p. 565-571.
- [49] Hanbay K. Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform. *Journal of the faculty of engineering and architecture of gazı university*. 2020;35(1):443-456.
- [50] Niepert M, Ahmed M, Kutzkov K. Learning convolutional neural networks for graphs. In *International conference on machine learning*. Germany:2016. p. 2014-2023.
- [51] Kurt F. Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi [yüksek lisans tezi]. Ankara:Hacettepe Üniversitesi; 2018
- [52] Lu S, Lu Z, Zhang YD. Pathological brain detection based on AlexNet and transfer learning. *Journal of computational science*. 2019;30:41-47.
- [53] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*. Kanada:2012. p. 1097-1105.
- [54] Özgür A, Fatih NAR. Derin öğrenme yöntemleri kullanarak ekin ile yabancı otların birbirinden ayırt edilmesi. *International Conference on Computer Technologies and Applications in Food and Agriculture*. Konya: ICCTAFA;2019. p. 76-89
- [55] Ballester P, Araujo RM. On the performance of GoogLeNet and AlexNet applied to sketches. In *Thirtieth AAAI Conference on Artificial Intelligence*. Phoenix: AAAI;2016. p. 1124-1128.
- [56] Xiao L, Yan Q, Deng S. Scene classification with improved AlexNet model. In *2017 12th International Conference on Intelligent Systems and Knowledge Engineering (ISKE)*. Nanjing:IEEE;2017. p. 1-6.
- [57] Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidike P, Nasrin MS, et al. The history began from alexnet: A comprehensive survey on deep learning approaches. *Cornell University Computer Vision and Pattern Recognition*. 2018; 1: 1-39.
- [58] Kumar R. Adding binary search connections to improve densenet performance. *5th International Conference on Next Generation Computing Technologies*. Dehradun: NGCT-2019;2019. SSRN: <https://ssrn.com/abstract=3545071>
- [59] Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu:IEEE;2017. p. 4700-4708.
- [60] Li X, Shen X, Zhou Y, Wang X, Li TQ. Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). *PloS One*. 2020;15(5):e0232127.
- [61] He K, Zhang X, Ren S, Sun J.. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision*. USA: IEEE;2015.p. 1026-1034.
- [62] Venkatesh G, Nurvitadhi E, Marr D. Accelerating deep convolutional networks using low-precision and sparsity. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. New Orleans: IEEE;2017. p. 2861-2865.
- [63] Korfiatis P, Kline TL, Lachance DH, Parney IF, Buckner JC, Erickson BJ. Residual deep convolutional neural network predicts MGMT methylation status. *Journal of Digital Imaging*. 2017;30(5):622-628.
- [64] Fu Y, Aldrich C. Flotation froth image recognition with convolutional neural networks. *Minerals Engineering*.2019;132:183-190.
- [65] Iandola FN, Han S, Moskewicz MW, Ashraf K, Dally WJ, Keutzer, K. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and< 0.5 MB model size. *3th International Conference on Learning Representations*. Toulon: ICLR;2016. p.1-13.

- [66] Zavan FHDB, Bellon ORP, Silva L, Medioni GG. Benchmarking parts based face processing in-the-wild for gender recognition and head pose estimation. *Pattern Recognition Letters*.2019;123:104-110.
- [67] Özyurt F, Sert E, Avcı D. An expert system for brain tumor detection: Fuzzy C-means with super resolution and convolutional neural network with extreme learning machine. *Medical Hypotheses*.2020;134:1-8.
- [68] Pathak D, El-Sharkawy M. ReducedSqNet: A shallow architecture for CIFAR-10. In 2018 International Conference on Computational Science and Computational Intelligence (CSCI). Las Vegas:IEEE;2018. p. 380-385.
- [69] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 3th International Conference on Learning Representations. San Diego: ICLR;2014. p.1409.1556.
- [70] Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. In European conference on computer vision. Zurich: Springer;2014. p. 818-833.
- [71] Demir U, Ünal G. Inpainting by deep autoencoders using an advisor network. 25th Signal Processing and Communications Applications Conference (SIU). Antalya: IEEE;2017. p. 1-4.
- [72] Qassim H, Verma A, Feinzimer D. Compressed residual-VGG16 CNN model for big data places image recognition. 8th Annual Computing and Communication Workshop and Conference. Las Vegas: IEEE;2018. p. 169-175.
- [73] Ruuska S, Hämäläinen W, Kajava S, Mughal M, Matilainen P, Mononen J. Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural Processes*. 2018;148:56-62.
- [74] Deng X, Liu Q, Deng Y, Mahadevan S. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*. 2016;340:250-261.
- [75] Peldek S, Becerikli Y. Recognition of human action in motion detected images with GMACA. *Journal of the Faculty of Engineering and Architecture of Gazi University*. 2019; 34(2):1025-1043.
- [76] Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks. *Information processing and management*. 2009; 45(4): 427- 437.
- [77] Ballabio D, Grisoni F, Todeschini R. Multivariate comparison of classification performance measures. *Chemometrics and Intelligent Laboratory Systems*. 2018;174:33-44. (2018).