

## Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi

Orhan YAMAN<sup>1\*</sup>, Türker TUNCER<sup>2</sup>

<sup>1,2</sup> Adli Bilişim Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

\*<sup>1</sup> orhanyaman@firat.edu.tr, <sup>2</sup> turkertuncer@firat.edu.tr

(Geliş/Received: 13/08/2021;

Kabul/Accepted: 30/10/2021)

**Öz:** Derin öğrenme yöntemlerinin gelişmesi akıllı tarım uygulamalarını olumlu yönde etkilemiştir. Ağaç ve bitki yapraklarındaki hastalıkların tespit edilmesi, meyve ve sebze rekolteilerinin tahmin edilmesi gibi birçok alanda derin öğrenme ve makine öğrenmesi kullanılmaktadır. Bu çalışmada derin öğrenme ve özellik seçme yöntemi kullanılarak yaprak hastalığı tespit edilmiştir. Önerilen yöntem için ceviz yapraklarından oluşan 726 görüntü toplanmıştır. Bu görüntüler sağlıklı ve hastalıklı olmak üzere iki sınıftan oluşmaktadır. Bu görüntülerden özellik çıkarımı yapmak için derin öğrenme modelleri kullanılmıştır. 17 adet derin öğrenme modeli test edilmiş ve en iyi iki model seçilmiştir. Bu iki model DarkNet53 ve ResNet101 olarak belirlenmiştir. Bu iki modelden elde edilen özellikler birleştirilmiştir. Böylece hibrit bir özellik çıkarımı oluşturulmuştur. Özellik seçimi için ReliefF algoritması kullanılmıştır. Böylece en ağırlıklı özellikler seçilmiştir. Seçilen özelliklerin sınıflandırılması için Destek Vektör Makinesi (DVM) algoritması kullanılmıştır. Önerilen yöntem ile %99.58 doğruluk hesaplanmıştır.

**Anahtar kelimeler:** Yaprak Hastalığı Tespiti, Derin Özellik Çıkarma, ReliefF, DenseNet53, ResNet101.

### Deep Feature Extraction and Machine Learning Method for Leaf Disease Detection in Plants

**Abstract:** The development of deep learning methods has positively affected smart agriculture practices. Deep learning and machine learning are used in many areas such as detecting diseases in tree and plant leaves, predicting fruit and vegetable yields. In this study, leaf disease has been detected by using deep learning and feature selection methods. For the proposed method, a total of 726 images of walnut leaves were collected. These images consist of two classes, healthy and diseased. Deep learning models have been used to extract features from these images. 17 deep learning models were tested and the best two models were selected. These two models are designated as DarkNet53 and ResNet101. The features from these two models are combined. Thus, hybrid feature extraction has been created. ReliefF algorithm is used for feature selection. Thus, the most weighty features have been selected. Support Vector Machine (SVM) algorithm is used for the classification of selected features. With the proposed method, 99.58% accuracy has been calculated.

**Key words:** Leaf Disease Detection, Deep Feature Extraction, ReliefF, DenseNet53, ResNet101.

### 1. Giriş

Yapay zekâ ve makine öğrenmesi uygulamaları günümüzde tarım alanında da kullanılmaktadır. Seraların izlenmesi, analiz edilmesi, yabancı otların kontrol edilmesi, bitki ve toprak izleme gibi birçok alanda yapay zeka kullanılarak tarımdaki verimliliğin artırılması amaçlanmıştır. Bitkilerin sürekli olarak izlenmesi ve analiz edilmesi üretim kalitesini de arttırmaktadır. Bitki yaprak ve meyvelerde oluşan hastalıkların tespit edilmesi üretimi etkilemektedir. Ağaçlardaki yaprak ve meyve hastalıklarının erken tespiti ve zamanında yapılacak ilaçlama ile üretimin düşmesi önlenmektedir. Aksi halde bu hastalık diğer ağaçlara da bulaşarak büyük zararlara neden olmaktadır. İnsansız Hava Araçları (IHA) kullanılarak alınan görüntülerden hastalık tespiti yapılabilmekte ve doğru bir şekilde ilaçlama gerçekleştirilmektedir.

Yapay zekâ ve makine öğrenme algoritmaları günümüzde yaygın olarak kullanılmaktadır [1]. Son zamanlarda, literatürde derin öğrenme modelleri tercih edilmektedir. Çünkü derin öğrenme sınıflandırmada yüksek başarı sağlamaktadır. Bu çalışmada yaprak hastalıklarının tespit edilmesine odaklanılmıştır. Bu nedenle ceviz yapraklarından oluşan bir veri seti elde edilmiştir. Bu veri seti 365 hastalıklı ve 361 sağlıklı olmak üzere toplamda 726 görüntü içermektedir. Hastalıklı ve sağlıklı yapraklar toplanarak görüntülenmiştir. Bu görüntülerden derin öğrenme modelleri kullanılarak özellik çıkarımı yapılmıştır. Başarı oranının yüksek olması için hibrit bir model kullanılmıştır. Çok sayıda derin öğrenme modeli içerisinde en başarılı olan iki model seçilmiştir. Bu modellerden elde edilen özellikler birleştirilmiş ve birleştirilen özellikler içerisinde en anlamlı özellikler seçilmiştir. Seçilen özellikler DVM algoritması ile sınıflandırılmıştır. Önerilen yöntem ile yüksek sonuçlar elde

\* Sorumlu yazar: [orhanyaman@firat.edu.tr](mailto:orhanyaman@firat.edu.tr). Yazarların ORCID Numaraları: <sup>1</sup> 0000-0001-9623-2284, <sup>2</sup> 0000-0002-5126-6445

edilmiştir. Bu çalışmadaki temel motivasyon ağaç üzerindeki hastalıklı bölgelerin tespit edilerek bölgesel ilaçlamanın yapılabilmesidir. Bu durumda ağaca az miktarda ilaç verilerek hastalıklar yok edilecektir. Ağaçlar daha az ilaca maruz kalarak meyvelerdeki kalite artacaktır.

Literatürde yaprak hastalıklarının tespiti ve sınıflandırılması için birçok yöntem vardır. Bitki yaprak ve meyvelerinde çok sayıda hastalık türü bulunmaktadır [2–4]. Bu hastalıkların erken tespit edilmesi ve müdahale edilmesi gerekmektedir. Aksi takdirde sebze ve meyvelerde verim kaybına neden olmaktadır. Yaprak hastalıklarının tespit edilmesi ve sınıflandırılması için derin öğrenme tabanlı birçok yöntem geliştirilmiştir [5–7]. Literatürde yapılan diğer çalışmalar Tablo 1’de özetlenmiştir. Tabloda çalışmaya ait metot, görüntü sayısı ve performans kriteri sunulmuştur.

**Tablo 1.** Literatürde yapılan çalışmaların özeti


Referans	Yıl	Yöntem	Görüntü sayısı	Bitki Türleri	Sınıf Sayısı	Performans metrikleri
Ganatra ve dig. [8]	2020	Görüntü işleme ve makine öğrenmesi	14956	Domates, Biber, Patates	38	Doğruluk, Kesinlik, Duyarlılık, F-Skor
Ahmad ve dig. [9]	2020	Konvolüsyonel Sinir Ağları	2364	Domates	4	Doğruluk, Kesinlik, Duyarlılık, F-Skor
Sibiya ve dig. [10]	2019	Konvolüsyonel Sinir Ağları	-	Mısır	4	Doğruluk
Wang ve dig. [11]	2017	Derin öğrenme (VGG16)	2086	Elma	4	Doğruluk
Türkoğlu ve dig. [12]	2019	AlexNet + DVM	1965	Kayısı, Ceviz, Şeftali, Kiraz	8	Doğruluk, Duyarlılık, F-Skor
Meena ve dig. [13]	2018	Görüntü işleme + DVM	60	-	2	Doğruluk
Durmus ve dig. [14]	2017	AlexNet	-	Domates	10	Doğruluk
Mohanty ve dig. [15]	2016	GoogleNet	54306	Çeşitli sebze ve meyve yaprakları	38	Doğruluk
Mohameth ve dig. [16]	2020	ResNet50 + DVM	54000	Çeşitli sebze ve meyve yaprakları	36	Doğruluk, F-Skor
Rajesh ve dig. [17]	2020	Karar ağacı	1000	Domates, Limon, Gül, Papaya, Muz	5	Doğruluk
Das ve dig. [18]	2020	DVM	14000	Domates	8	Doğruluk
Panigrahi ve dig. [19]	2020	Rasgele Orman	3852	Mısır	4	Doğruluk, Kesinlik, Duyarlılık, F-Skor
Tiwari ve dig. [20]	2020	VGG19 + Lojistik Regrasyon	2152	Patates	3	Doğruluk
Jiang ve dig. [21]	2019	VGG-INCEP	26377	Elma	5	Doğruluk
Divakar ve dig. [22]	2021	DenseNet	3642	Elma	4	Doğruluk, Kesinlik, F-Skor

Literatürde çeşitli bitkilere ait hastalıkların tespiti için birçok yöntem sunulmuştur. Bu çalışmalar genellikle görüntü işleme, makine öğrenmesi ve derin öğrenme tabanlıdır [23,24]. Geliştirilen yöntemlerin bazıları gömülü sistemler üzerinde uygulanarak bir ürün haline dönüştürülmüştür [25]. Mattihalli ve dig. [26] yaprak hastalıklarının tespit edilebilmesi için gömülü sistem tabanlı bir yöntem geliştirmiştir. Raspberry pi modül geliştirme kartı ile kameradan alınan görüntüler üzerinde hastalık tespiti yapmıştır. Ayrıca geliştirme kartı üzerine yerleştirilen sıcaklık, nem gibi verileri alarak otomatik sulama ve ilaçlama gerçekleştirmektedir. Hem hastalık tespiti hem de akıllı tarım için bir model geliştirmiştir. Nalawade ve dig. [27] ESP geliştirme kartı ve sensörler kullanarak akıllı tarım uygulaması geliştirmiştir. Bunun yanı sıra bitkilerdeki yaprakların hastalıklarını tespit edebilen bir yöntem geliştirmiştir. Önerilen yöntemde yaklaşık %98.07 doğruluk sağlamıştır. Chouhan ve dig. [28] bitkilerdeki yaprak hastalığının tespiti için Nesnelerin İnterneti (IoT) ve bulanık tabanlı bir model geliştirmiştir. Yaprak hastalıklarının tespiti için geliştirilen yöntem ile yaklaşık %80.66 doğruluk hesaplamıştır.

## 2. Materyal ve Metot


Bu çalışmada sağlıklı ve hastalıklı ceviz yapraklarından yeni bir veri seti oluşturulmuştur. 361 sağlıklı ve 365 hastalıklı ceviz yaprakları toplanarak beyaz bir zemin üzerine yerleştirilmiş ve görüntüler elde edilmiştir

([https://github.com/orhanyaman/leaf\\_images.git](https://github.com/orhanyaman/leaf_images.git)). Toplanan sağlıklı ve hastalıklı ceviz yapraklarına ait örnek görüntüler Şekil 1’de gösterilmiştir



Şekil 1. Ceviz yaprağı veri setine ait örnek görüntüler (a) Sağlıklı (b) Hastalıklı

Şekil 1’de verilen sağlıklı ve hastalıklı görüntülerin sınıflandırılması için derin özellik çıkarım tabanlı bir yöntem önerilmiştir. Önerilen yöntemin blok şeması Şekil 2’de görülebilmektedir.



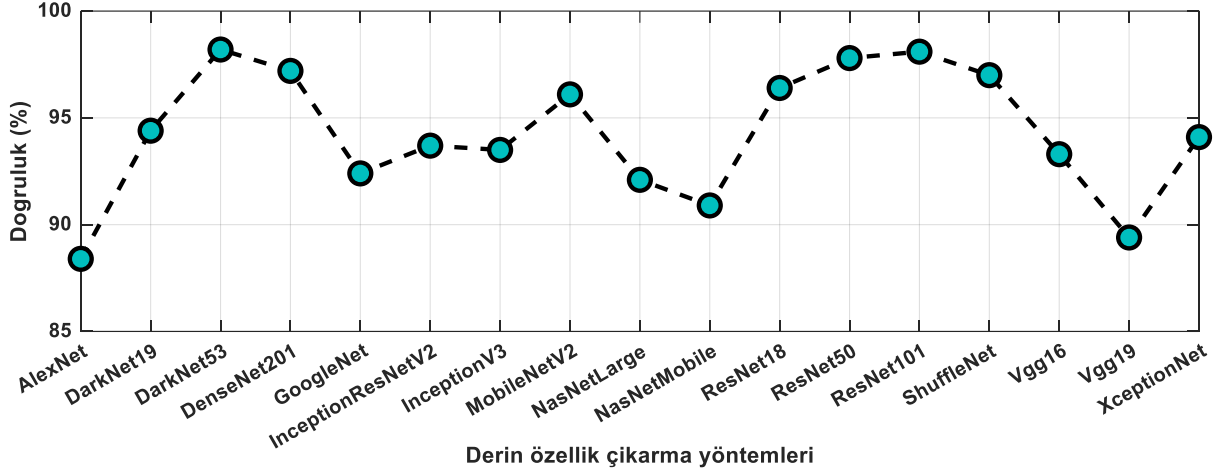
Şekil 2. Önerilen yöntemin blok şeması

Önerilen yöntem üç ana bölümden oluşmaktadır. Birinci bölüm, derin özellik çıkarım yöntemleri kullanılarak özellik çıkarımı yapmak ve özellikleri birleştirmektir. İkinci bölüm, çıkarılan özelliklerden en ağırlıklı özelliklerin seçilmesidir. Üçüncü bölüm ise seçilen özelliklerin sınıflandırılmasıdır. Önerilen yöntemin sözde kodu Tablo 2’de gösterilmiştir.

Tablo 2. Önerilen yöntemin sözde kodu

Prosedür: <i>FusedDeep – Özellik seçme (Im)</i>	
<b>Giriş</b>	Yaprak görüntüsü veri seti ( <i>IM</i> ) 726 adet görüntü
<b>Çıkış</b>	Tahmin edilen değerler ( <i>pv</i> )
00:	<i>D</i> boyutundaki yaprak görüntü veri setinin yüklenmesi
01:	<b>for</b> <i>k</i> =1 <b>to</b> <i>d</i> <b>do</b> // Her yaprak görüntüsünün okunması.
02:	$feature^1 = DN53(Im)$ ; // DarkNet53 kullanılarak özellik çıkarımı
03:	$feature^2 = RN101(Im)$ ; // ResNet101 kullanılarak özellik çıkarımı
04:	<b>for</b> <i>i</i> =0 <b>to</b> 1 <b>do</b>
05:	$X(k, 1000 * i + 1: 1000 * (i + 1)) = feature^{(i+1)}$ // Özellik birleştirme
06:	<b>end for</b> <i>i</i>
07:	<b>end for</b> <i>k</i>
11:	$last = IRF(X, taget)$ ; // ReliefF kullanarak en anlamlı özelliklerin seçilmesi
13:	$pv = DVM(last, taget, 10)$ ; //Seçilen özelliklerin DVM algoritması ile sınıflandırılması

Literatürde derin öğrenme ile nesne tanıma, sınıflandırma ve özellik çıkarımı için birçok çalışma vardır [29–31]. Derin öğrenme genellikle konvolüsyon ve havuzlama adımlarından oluşmaktadır. Bu adımların art arda yerleştirilmesiyle derin öğrenme modeli oluşturulmaktadır. Bu çalışmada AlexNet, DarkNet19, DarkNet53, DenseNet201, GoogleNet, InceptionResNetV2, InceptionV3, MobileNetV2, NasNetLarge, NasNetMobile, ResNet18, ResNet50, ResNet101, ShuffleNet, VGG16, VGG19 ve XceptionNet derin öğrenme modelleri test edilmiştir. Bu derin öğrenme modellerinden elde edilen özellikler DVM algoritması ile sınıflandırılmıştır. Sınıflandırma için MATLAB 2020A programında Classification Learner Toolbox kullanılmıştır ve 10-Kat Çapraz Doğrulama seçilmiştir. Sınıflandırma sonuçları Şekil 3'te gösterilmiştir.



Şekil 3. 10-Kat Çapraz Doğrulama kullanılarak derin öğrenme modellerinden elde edilen sonuçlar

Şekil 3'te görülebileceği gibi en yüksek sonuçlar DarkNet53 ve ResNet101 modelleri ile hesaplanmıştır. DarkNet53 modeli ile %98.2 ve ResNet101 modeli ile %98.1 doğruluk hesaplanmıştır. Özellik çıkarımı için en yüksek doğruluğa sahip DarkNet53 ve ResNet101 modelleri birlikte kullanılmıştır. Bu iki derin öğrenme modellerinde elde edilen özellikler birleştirilmiş ve hibrit bir yöntem sunulmuştur. DarkNet53 modeli ile her görüntüden 1024 adet özellik, ResNet101 modeli ile her görüntüden 1000 özellik çıkarılmıştır. Özelliklerin birleştirilmesi sonucunda 726 görüntü için 726×2024 boyutunda özellik matrisi elde edilmiştir. Birleştirilen bu özelliklerden en ağırlıklı olanların seçilmesi için ReliefF algoritması kullanılmıştır.


Relief algoritması özellik seçme yöntemidir [32]. Kira et al. [33] tarafından geliştirilen bu algoritma, literatürde yaygın olarak kullanılmaktadır [33]. Bu algoritma iki sınıflı veri seti için başarılı sonuçlar vermektedir. Kononenko çoklu sınıfa sahip veri setleri için ReliefF algoritmasını geliştirmiştir [34]. Bu yöntem ilk olarak tüm özneliklerin ağırlıklarını 0 olarak belirlemektedir. Her bir adımda veri setinden rastgele bir veri seçer ve bu veri ile aynı sınıfa ait en yakın  $k$  adet veri bulmaktadır. Böylece her sınıfa ait en yakın verileri hesaplamaktadır. Burada  $k$  değeri sınıf sayısının bir eksiğidir. Daha sonra her bir özelliğe ait ağırlıklar bu veriler kullanılarak güncellenir. Son adımda belirlenen şartı sağlamayan özellikler veri setinden atılarak yeni veri seti oluşturulmaktadır. Denklem 1, 2 ve 3'te relief algoritması verilmiştir.

$$W(X^a) = W(X^a) - \frac{\sum_{j=1}^k \text{distance}(A, R_i, H_j)}{m \cdot k} + \frac{\sum_{C \neq \text{class}(R_i) \left[ \frac{P(C)}{1 - P(\text{class}(R_i))} \sum_{j=1}^k \text{distance}(A, R_i, M_j) \right]}{m \cdot k} \quad (1)$$

$$\text{distance}(A, I_1, I_2) = \begin{cases} 0, & I_1 = I_2 \\ 1, & I_1 \neq I_2 \end{cases} \quad (2)$$

$$\text{distance}(A, I_1, I_2) = |I_1 - I_2| * \frac{1}{\max(A) - \min(A)} \quad (3)$$

Bu denklemlerde verilen  $W(X^a)$   $a$ 'nıncı özneliğin ağırlığını,  $k$  sınıf sayısının bir eksiğini,  $m$  döngü sayısını,  $R_i$   $i$ 'ninci döngüde seçilmiş olan veriyi,  $H_j$  seçilen veri ile aynı sınıfa ait  $j$ 'ninci yakın veriyi,  $M_j$   $j$ 'ninci sınıfa ait seçilen veriye en yakın olan veriyi ifade etmektedir.  $726 \times 2024$  adet özelliğin ağırlıkları hesaplanmıştır. Böylece  $726 \times 1246$  özellik seçilmiştir. Seçilen özelliklerin üç boyutlu gösterimi Şekil 4'te verilmiştir.



Şekil 4. Relief algoritması ile seçilen özelliklerin üç boyutlu gösterimi

Şekil 4'teki grafik 726 görüntü için seçilen rastgele üç özelliği kullanılarak elde edilmiştir. Seçilen  $726 \times 1246$  özellik DVM algoritması kullanılarak sınıflandırılmıştır.

### 3. Deneysel Sonuçlar

Bu çalışmada önerilen yöntemin sonuçları MATLAB 2020A programı kullanılarak hesaplanmıştır. Özellik çıkarımı için kullanılan derin öğrenme modelleri birleştirilerek Relief algoritması ile özellikler seçilmiştir. Seçilen özellikler Classification Toolbox kullanılarak sınıflandırılmıştır. Sınıflandırma için DVM algoritması kullanılmıştır. DVM algoritması ile diğer makine öğrenmesi algoritmalarına göre daha yüksek doğruluk hesaplanmıştır. Önerilen yöntemin hata matrisi sonucu Şekil 5'te gösterilmiştir.

Doğru sınıf	1	362	3
	2	0	361
		1	2
		Tahmin sınıfı	

Şekil 5. Önerilen yöntemin hata matrisi sonucu

Şekil 5'te görülebileceği gibi sınıflandırma başarısının yüksektir. Yöntemin performans sonuçlarını elde etmek için doğruluk, kesinlik, duyarlılık, geometrik ortalama ve F-skor parametreleri hesaplanmıştır. Bu performans metrikleri, gerçek pozitiflerin (TP), yanlış pozitiflerin (FP), gerçek negatiflerin (TN) ve yanlış negatiflerin (FN) sayısı kullanılarak hesaplanır [35]. Kullanılan performans ölçülerinin matematiksel gösterimleri denklem 4-8'de gösterilmiştir.

$$\text{Dogruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Duyarluluk} = \frac{TP}{TP+FN} \quad (6)$$

$$\text{Geometrik ortalama} = \sqrt{\frac{TP*TN}{(TP+FN)*(TN+FP)}} \quad (7)$$

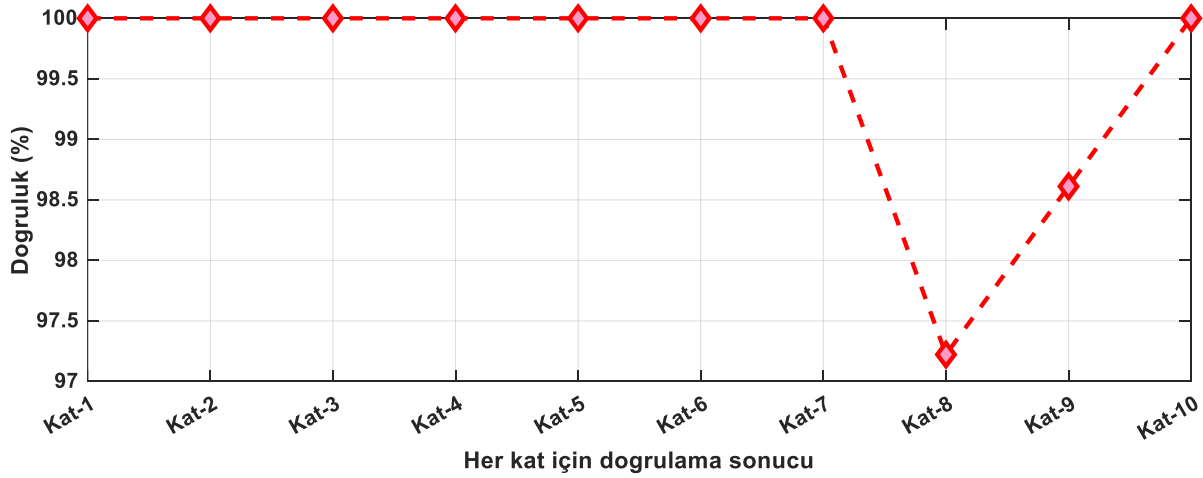
$$F - \text{skor} = \frac{2TP}{2TP+FP+FN} \quad (8)$$

Önerilen yöntemde kullanılan derin öğrenme, özellik seçme ve sınıflandırma algoritmaları kullanılmış ve sonuçlar hesaplanmıştır. Bu sonuçların analiz edilebilmesi için sınıflandırma algoritmaları 1000 iterasyon çalıştırılmıştır. 1000 iterasyon sonucunda maksimum, minimum, ortalama ve standart sapma hesaplanmıştır. Önerilen yöntemin performans sonuçları Tablo 3'te gösterilmiştir.

**Tablo 3.** Önerilen yöntemin performans sonuçları

	Doğruluk	Kesinlik	Duyarluluk	Geometrik ortalama	F-Skor
<b>Maksimum</b>	99.58	99.58	99.58	99.58	99.58
<b>Minimum</b>	98.76	99.18	99.17	99.17	99.18
<b>Ortalama</b>	99.13	99.48	99.48	99.48	99.48
<b>Standart sapma</b>	0.13	0.06	0.06	0.06	0.064

Tablo 3'te görülebileceği gibi ceviz yapraklarında hastalığın tespiti %99.58 olarak hesaplanmıştır. Maksimum kesinlik, duyarlılık, geometrik ortalama ve F-Skor değerleri %99.58 olarak elde edilmiştir. Elde edilen sonuçlar 10 kat çapraz doğrulama yapılarak hesaplanmıştır. Önerilen yöntemin her kat doğrulama sonucu Şekil 6'da verilmiştir.



**Şekil 6.** Önerilen yöntemin her kat doğrulama sonucu

Şekil 6'da görülebildiği gibi Kat-8 ve Kat-9 sonuçları diğer Katlara göre düşüktür. Kat-8 ve Kat-9 haricindekiler %100 olarak hesaplanmıştır.

#### 4. Tartışma

Bu çalışmada derin öğrenme modelleri ile hibrit bir yöntem geliştirilmiştir. İki sınıflı yeni bir veri seti kullanılmış ve ceviz yapraklarındaki hastalıklar tespit edilmiştir. Literatürde birçok meyve ve sebze yapraklarındaki hastalıklar tespit edilmiştir. Literatürde PlantVillage veri seti yaygın olarak kullanılmaktadır. Bu veri setinde birçok sebze ve meyve yapraklarına ait hastalık türleri mevcuttur. Önerilen yöntem hem yeni veri seti ile hem de literatürde yaygın olarak kullanılan PlantVillage veri seti ile test edilmiş ve performans sonuçları hesaplanmıştır.



**Tablo 4.** Önerilen yöntem ile literatürdeki sonuçların karşılaştırılması

Referans	Veri seti	Görüntü sayısı	Sınıf Sayısı	Doğruluk (%)	Kesinlik	Duyarlılık	F-Skor
Ganatra ve dig. [8], 2020	PlantVillage	14956	38	73.38	72.88	72.90	71.98
Ahmad ve dig. [9], 2020	Laboratuvar tabanlı	2364	4	99.6	99.6	99.6	99.5
Sibiya ve dig.[10], 2019	PlantVillage	-	4	92.85	-	-	-
Wang ve dig.[11], 2017	-	2086	4	90.4	-	-	-
Türkoğlu ve dig.[12], 2019	-	1965	8	95.5	-	94.34	94.58
Meena ve dig.[13], 2018	PlantVillage	60	2	90	-	-	-
Durmus ve dig.[14], 2017	PlantVillage	-	10	95.65	-	-	-
Mohanty ve dig.[15], 2016	PlantVillage	54306	38	99.35	-	-	-
Mohameth ve dig.[16], 2020	PlantVillage	54000	36	98.01	-	-	97.13
Rajesh ve dig.[17], 2020	-	1000	5	95	-	-	-
Das ve dig.[18], 2020	PlantVillage	14000	8	87.6	-	-	-
Panigrahi ve dig.[19], 2020	Mısır veriseti	3852	4	79.23	81	79	78
Tiwari ve dig.[20], 2020	PlantVillage	2152	3	97.8	-	-	-
Jiang ve dig.[21], 2019	-	26377	5	97.14	-	-	-
Divakar ve dig.[22], 2021	Plant Pathology 2020-FGVC7”	3642	4	92.28	91.93	-	91.24
Önerilen Yöntem	Ceviz yaprağı veriseti	<b>726</b>	<b>2</b>	<b>99.58</b>	<b>99.58</b>	<b>99.58</b>	<b>99.58</b>
	PlantVillage	<b>16011</b>	<b>10</b>	<b>99.46</b>	<b>99.37</b>	<b>99.35</b>	<b>99.35</b>

Tablo 4’te görülebildiği gibi bitki yapraklarındaki hastalığın tespiti iki ile 38 sınıf arasında değişmektedir. Önerilen yöntem iki sınıf ve 736 görüntüden oluşan ceviz yaprağı veri setinde uygulanmış ve %99.58 doğruluk sağlamıştır. Önerilen yöntemin başarısını literatürle karşılaştırmak için literatürde yaygın olarak kullanılan PlantVillage veri seti test edilmiştir. PlantVillage veri setinde 10 sınıf 16011 görüntü kullanılarak yaklaşık %99.46 doğruluk sağlanmıştır. Sibiya ve dig.[10] çalışmasında PlantVillage veri setini kullanmış ve dört sınıf için yaklaşık %92.85 doğruluk hesaplamıştır. Meena ve dig.[13] çalışmasında PlantVillage veri setini kullanmış ve iki sınıf için %90 başarı sağlamıştır. Mohanty ve dig.[15] ve Mohameth ve dig.[16] çalışmalarında PlantVillage veri setini kullanmış ve yaklaşık 54000 görüntü için sırasıyla %99.35 ve %98.01 başarı hesaplamışlardır. Literatürde PlantVillage veri setini kullanan çalışmalar ile karşılaştırıldığında önerilen yöntemin başarılı sonuç verdiği görülmektedir.

#### 4. Sonuçlar ve Gelecek Çalışmalar

Bu çalışmada bitki yapraklarındaki hastalıkların tespit edilebilmesi için derin özellik çıkarımı ve makine öğrenmesi tabanlı bir yöntem geliştirilmiştir. Önerilen yöntemin test edilebilmesi için ceviz yapraklarından oluşan 726 görüntü ve iki sınıflı bir veri seti toplanmıştır. Görüntüler üzerinde DarkNet53 ve ResNet101 modelleri ile özellik çıkarımı yapılmıştır. Elde edilen özellikler birleştirilerek ReliefF algoritması ile en ağırlıklı özellikler seçilmiştir. Seçilen özellikler ise DVM algoritması ile sınıflandırılmıştır. Ceviz yaprağı veri seti için %99.58 doğruluk hesaplanmıştır. Önerilen yöntemin başarısını literatür ile karşılaştırmak için literatürde yaygın olarak kullanılan PlantVillage veri seti test edilmiştir. PlantVillage veri seti için önerilen yöntem %99.46 başarı sağlanmıştır. Akıllı tarım uygulamalarında bitkilerdeki hastalığın tespit edilebilmesi için geliştirilen bu yöntemin başarılı sonuçlar verdiği görülmektedir. Gelecek çalışmalarda gömülü sistemler üzerinde gerçek zamanlı çalışabilecek bir model geliştirilmesi hedeflenmektedir. Gömülü sistem üzerinde çalıştırılacak model bir insansız ilaçlama araçlarına yerleştirilerek sadece hastalıklı yaprakların ilaçlanması ön görülmektedir. Böylece tarımsal alanlarda bilinçli ilaçlama yapılarak daha az ilaç kullanımı sağlanacak ve daha sağlıklı ürün üretimi yapılacaktır.



**Kaynaklar**

- [1] Aydemir, E., and Gulsecen, S. (2019) Arranging bus behaviour by finding the best prediction model with artificial neural networks. *Teh. Vjesn.*, 26 (4), 885–892.
- [2] Singh, V., and Misra, A.K. (2017) Detection of plant leaf diseases using image segmentation and soft computing techniques. *Inf. Process. Agric.*, 4 (1), 41–49.
- [3] Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., and Batra, N. (2020) PlantDoc: A dataset for visual plant disease detection. *ACM Int. Conf. Proceeding Ser.*, 249–253.
- [4] Rao, A., and Kulkarni, S.B. (2020) A Hybrid Approach for Plant Leaf Disease Detection and Classification Using Digital Image Processing Methods. *Int. J. Electr. Eng. Educ.*, 1–19.
- [5] Radovanovic, D., and Dukanovic, S. (2020) Image-Based Plant Disease Detection: A Comparison of Deep Learning and Classical Machine Learning Algorithms. *2020 24th Int. Conf. Inf. Technol. IT 2020*, (February), 1–4.
- [6] Dhakal, A., and Shakya, S. (2018) Image-Based Plant Disease Detection with Deep Learning. *Int. J. Comput. Trends Technol.*, 61 (1), 26–29.
- [7] Hammad Saleem, M., Khanchi, S., Potgieter, J., and Mahmood Arif, K. (2020) Image-based plant disease identification by deep learning meta-architectures. *Plants*, 9 (11), 1–23.
- [8] Ganatra, N., and Patel, A. (2020) A multiclass plant leaf disease detection using image processing and machine learning techniques. *Int. J. Emerg. Technol.*, 11 (2), 1082–1086.
- [9] Ahmad, I., Hamid, M., Yousaf, S., Shah, S.T., and Ahmad, M.O. (2020) Optimizing pretrained convolutional neural networks for tomato leaf disease detection. *Complexity*, 2020.
- [10] Sibiya, M., and Sumbwanyambe, M. (2019) A Computational Procedure for the Recognition and Classification of Maize Leaf Diseases Out of Healthy Leaves Using Convolutional Neural Networks. *AgriEngineering*, 1 (1), 119–131.
- [11] Wang, G., Sun, Y., and Wang, J. (2017) Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning. *Comput. Intell. Neurosci.*, 2017.
- [12] Türkoğlu, M., and Hanbay, D. (2019) Plant disease and pest detection using deep learning-based features. *Turkish J. Electr. Eng. Comput. Sci.*, 27 (3), 1636–1651.
- [13] Meena Prakash, R., Saraswathy, G.P., Ramalakshmi, G., Mangaleswari, K.H., and Kaviya, T. (2018) Detection of leaf diseases and classification using digital image processing. *Proc. 2017 Int. Conf. Innov. Information, Embed. Commun. Syst. ICIECS 2017*, 2018-Janua, 1–4.
- [14] Durmus, H., Gunes, E.O., and Kirci, M. (2017) Disease detection on the leaves of the tomato plants by using deep learning. *2017 6th Int. Conf. Agro-Geoinformatics, Agro-Geoinformatics 2017*, 0–4.
- [15] Mohanty, S.P., Hughes, D.P., and Salathé, M. (2016) Using deep learning for image-based plant disease detection. *Front. Plant Sci.*, 7 (September), 1–10.
- [16] Mohameth, F., Bingcai, C., and Sada, K.A. (2020) Plant Disease Detection with Deep Learning and Feature Extraction Using Plant Village. *J. Comput. Commun.*, 08 (06), 10–22.
- [17] B. Rajesh, M. Vishnu Sai Vardhan, L.S. (2020) Leaf Disease Detection and Classification by Decision Tree. *Mach. Learn. Found.*, (ICOED), 705–708.
- [18] Das, D., Singh, M., Mohanty, S.S., and Chakravarty, S. (2020) Leaf Disease Detection using Support Vector Machine. *Proc. 2020 IEEE Int. Conf. Commun. Signal Process. ICCSP 2020*, 1036–1040.
- [19] Kshyanaprava Panda Panigrahi, Himansu Das, A.K.S., and Moharana, S.C. (2020) Maize Leaf Disease Detection and Classification Using Machine Learning Algorithms. *Prog. Comput. Anal. Networking*, Springer, Singapore, 659–669.
- [20] Tiwari, D., Ashish, M., Gangwar, N., Sharma, A., Patel, S., and Bhardwaj, S. (2020) Potato Leaf Diseases Detection Using Deep Learning. *Proc. Int. Conf. Intell. Comput. Control Syst. ICICCS 2020*, (Iciccs), 461–466.
- [21] Jiang, P., Chen, Y., Liu, B., He, D., and Liang, C. (2019) Real-Time Detection of Apple Leaf Diseases Using Deep Learning Approach Based on Improved Convolutional Neural Networks. *IEEE Access*, 7, 59069–59080.
- [22] Divakar, S., Bhattacharjee, A., and Priyadarshini, R. (2021) Smote-DL: A Deep Learning Based Plant Disease Detection Method. *2021 6th Int. Conf. Conver. Technol. I2CT 2021*, 4–9.
- [23] Dhaware, C.G., and Wanjale, K.H. (2017) A modern approach for plant leaf disease classification which depends on leaf image processing. *2017 Int. Conf. Comput. Commun. Informatics, ICCCI 2017*, 31–34.
- [24] Kumar, S., Prasad, K., Srilekha, A., Suman, T., Rao, B.P., and Vamshi Krishna, J.N. (2020) Leaf disease detection and classification based on machine learning. *Proc. Int. Conf. Smart Technol. Comput. Electr. Electron. ICSTCEE 2020*, 361–365.
- [25] Dharanika, T., Ruban Karthik, S., Sabhariesh Vel, S., Vyaas, S., and Yogeshwaran, S. (2021) Automatic Leaf Disease Identification and Fertilizer Agrobot. *2021 7th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2021*, 1341–1344.
- [26] Mattihalli, C., Gedefaye, E., Endalamaw, F., and Necho, A. (2018) Plant leaf diseases detection and auto-medicine. *Internet of Things*, 1–2, 67–73.
- [27] Nalawade, R., Nagap, A., Jindam, L., and Ugale, M. (2020) Agriculture Field Monitoring and Plant Leaf Disease Detection. *2020 3rd Int. Conf. Commun. Syst. Comput. IT Appl. CSCITA 2020 - Proc.*, 226–231.
- [28] Chouhan, S.S., Singh, U.P., and Jain, S. (2021) Automated Plant Leaf Disease Detection and Classification Using Fuzzy Based Function Network. *Wirel. Pers. Commun.*, (0123456789).
- [29] Ertam, F. (2019) An efficient hybrid deep learning approach for internet security. *Phys. A Stat. Mech. its Appl.*, 535, 122492.

- [30] Yaman, O., Tuncer, T., and Tasar, B. (2021) DES-Pat: A novel DES pattern-based propeller recognition method using underwater acoustical sounds. *Appl. Acoust.*, 175, 107859.
- [31] Baygin, M., Yaman, O., Tuncer, T., Dogan, S., Datta, P., and Acharya, R. (2021) Biomedical Signal Processing and Control Automated accurate schizophrenia detection system using Collatz pattern technique with EEG signals. *Biomed. Signal Process. Control*, 70 (June), 102936.
- [32] Tuncer, T., Dogan, S., and Ozyurt, F. (2020) An automated Residual Exemplar Local Binary Pattern and iterative ReliefF based COVID-19 detection method using chest X-ray image. *Chemom. Intell. Lab. Syst.*, (January).
- [33] Kira, K., and Rendell, L.A. (1992) Feature selection problem: traditional methods and a new algorithm. *Proc. Tenth Natl. Conf. Artif. Intell.*, 129–134.
- [34] Kononenko, I. (1994) Estimating attributes: Analysis and extensions of RELIEF. *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, 784 LNCS, 171–182.
- [35] Çelik, F., and Aydemir, E. (2021) Prediction of difficult tracheal intubation by artificial intelligence: a prospective observational study. *Duzce Med. J.*, 23 (1), 47–54.