



Automatic Detection and Classification of Some Vineyard Diseases with Faster R-CNN Model

Ziya Altaş^{1,a,*}, Mehmet Metin Özgüven^{1,b}, Kemal Adem^{2,c}

¹Department of Biosystems Engineering, Tokat Gaziosmanpaşa University, Türkiye

²Department of Computer Engineering, Sivas Science and Technology University, Türkiye

*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 26/10/2022 Accepted : 20/11/2022</p> <p><i>Keywords:</i> Deep Learning Faster R-CNN Vineyards Plant Diseases Vineyard Diseases</p>	<p>Türkiye is one of the countries with the most important vineyard areas in the world, where the most grape production is made. Vineyard diseases are one of the most important reasons that adversely affect the productivity in viticulture. In this study, some vineyard diseases were detected and classified using the Faster R-CNN deep learning model, which is an artificial intelligence approach. These diseases are powdery mildew, downy mildew, dead arm disease, grapevine leaf roll-associated virus disease (GLRaV) and grapevine fan leaf nepovirus (GFLV) diseases that are common and cause economic problems. The proposed method is trained and tested using 11000 images. At the end of the study, the overall accuracy rate was found to be 92%. The proposed approach gave better results than similar methods in the literature. Therefore, it was concluded that the method can be used reliably in the detection and classification of some vineyard diseases.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 11(1): 97-103, 2023

Bazı Bağ Hastalıklarının Faster R-CNN Modeli ile Otomatik Tespit Edilmesi ve Sınıflandırılması

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 26/10/2022 Kabul : 20/11/2022</p> <p><i>Anahtar Kelimeler:</i> Derin Öğrenme Faster R-CNN Bağcılık Bitki Hastalıkları Bağ Hastalıkları</p>	<p>Türkiye, üzüm üretiminin en çok yapıldığı dünyanın en önemli bağ alanlarına sahip olan ülkelerdendir. Bağcılıkta verimliliği olumsuz etkileyen en önemli sebeplerden birisi bağ hastalıklarıdır. Bu çalışmada, bir yapay zekâ yaklaşımı olan Faster R-CNN derin öğrenme modeli kullanılarak bazı bağ hastalıkları tespit edilmiş ve sınıflandırılmıştır. Bu hastalıklar yaygın olarak görülen ve ekonomik sorun oluşturan külleme, mildiyö, ölü kol hastalığı ile asma yaprak kıvrılma virüs hastalığı (GLRaV) ve asma kısa boğum virüs (GFLV) hastalıklarıdır. Önerilen yöntem 11000 görüntü kullanılarak eğitilmiş ve test edilmiştir. Çalışma sonunda genel doğruluk oranı %92 bulunmuştur. Önerilen yaklaşım, literatürdeki benzer yöntemlerden daha iyi sonuçlar vermiştir. Bu nedenle yöntemin, bazı bağ hastalıklarının tespit edilmesi ve sınıflandırılmasında güvenilir bir şekilde kullanılabileceği sonucuna varılmıştır.</p>

^a kayseri_ziya@hotmail.com

^b <https://orcid.org/0000-0001-9900-0606>

^c metin.ozguven@gop.edu.tr

^d <https://orcid.org/0000-0002-6421-4804>

^e kemaladem@sivas.edu.tr

^f <https://orcid.org/0000-0002-3752-7354>



Giriş

Dünya nüfusunun hızla artması ve kentleşme, tarım alanlarının ve kişi başına düşen su gibi doğal kaynakların azalmasına yol açmaktadır. Bu nedenle tarımsal üretimde verimliliği artırmak için teknolojik ve genetik yöntemlerin kullanılması zorunlu hale gelmiştir (Ozguven, 2018; Özgüven, 2018). Bitki verimliliğini etkileyen en önemli faktörlerden biri bitki hastalıklarıdır. Bitki hastalıklarının zamanında tespit edilip önlenememesi, bitki veriminde ve kalitesinde önemli düşüşlere yol açmakta ve yetiştiriciler için önemli ekonomik kayıplara neden olmaktadır. Hastalıkların güvenilir ve zamanında tespiti, bu tür kayıpları önemli ölçüde azaltabilmektedir (Adem ve ark., 2022). Bu nedenle, bitki hastalıklarının hızlı ve doğru bir şekilde belirlenmesi ve hastalık şiddetinin değerlendirilmesi, zamanında önleme ve yönetim stratejilerinin uygulanması için esastır (Rossi, 1995; Bock ve ark., 2010; Gavhale ve Ujwalla, 2014; Ampatzidis ve ark., 2017; Cruz ve ark., 2017; Ma ve ark., 2018; Wang ve Qi, 2019).

Bağcılık için dünyanın en elverişli iklim kuşağı üzerinde bulunan ülkemiz, kültür asma (*Vitis vinifera* L.) ve bağcılık kültürünün anavatanı olması nedeniyle zengin bir gen potansiyeline ve asmanın heterozigotik yapısından dolayı çok geniş çeşit ve tip zenginliğine sahiptir. Ülkemiz bağcılığında iklimin uygun olmasından dolayı eski zamanlardan beri asma olarak isimlendirilen (*Vitis* sp.) bitki yetiştiriciliği yapılmaktadır. Asma, toprak ve iklim bakımından fazla seçici olmaması ve asmadan üzüm ve yaprak gibi ürünlerin ekonomik olarak değerlendirilme imkanına sahip olması nedeniyle birçok ailenin geçim kaynağını oluşturmaktadır. Ancak birçok hastalık bağlarda kalite ve verimi düşürerek ekonomik sorunlar meydana getirmektedir (Karabat, 2014; Altaş ve ark., 2021).

Türkiye, 2020 yılı istatistiklerine göre 6.950.930 ha'lık dünya bağ alanları içinde 400.980 ha'lık bağ alanı varlığı ve 78.034.332 ton'luk dünya yaş üzüm üretiminin 4.208.980 ton'luk kısmıyla önemli bir bağ yetiştiriciliği yapılan bir ülke konumundadır (FAO, 2022). TÜİK verilerine göre 2021 yılında ülkemizde üretilen toplam yaş üzümün %50,59'u sofralık, %38,96'sı kurutmalık, %10,43'ü şıralık-şaraplık olarak çeşitli gıda ürünlerinin elde edilmesi amacıyla kullanılmaktadır. Üzümün diğer değerlendirme ürünlerinden pekmez, sucuk, reçel, köfter (pekmez lokumu), pestil (bastık), samsa vb. ürünlerde yoğun olarak tüketilmektedir. Dünyada üretim alanı olarak İspanya, Çin, Fransa, İtalya ve Türkiye ilk beş büyük üretici ülke olarak göze çarpmaktadır. Ülkeler üzüm üretim miktarı açısından değerlendirildiğinde ise Çin, İtalya, ABD, Fransa, İspanya ve Türkiye olarak sıralanmaktadır (Şekil 1). Bu ülkelerden Fransa ve İspanya şaraplık üzüm üretimi ile ön plana çıkarken, İtalya sofralık ve şaraplık, ABD ve Çin sofralık, kurutmalık ve şaraplık ve Türkiye ise hem sofralık hem de kurutmalık üzüm üretimi ile öne çıkmaktadır. Arjantin, Şili ve Güney Afrika Cumhuriyeti Güney yarım kürede bağcılığın gelişmiş olduğu diğer ülkelerdir ve buralarda da sırasıyla sofralık, şaraplık ve kurutmalık amaçlı üretim önem taşımaktadır (Karabat, 2014).

Derin öğrenme tekniği, makine öğreniminin bir alt kategorisidir. Makine öğrenmesinde nicel veya kategorik analiz yapmak için farklı algoritmalar ve yöntemler kullanılmaktadır. Bu tür algoritmalar, tahminler ve çıkarımlar yapmak için verilerin karmaşık modeliyle başa çıkabilen matematiksel modeller kullanılmaktadır. Derin

öğrenme, veri yapısının karmaşıklığını yönetmek için katmanlarda depolanan bilgilerin soyut dönüşümlerine dayanan daha geniş bir araç setinden yararlanmaktadır. Bu nedenle derin öğrenme, verilerin temsilinden öğrenmeye dayanmaktadır (Song ve Lee, 2013). Derin öğrenme tekniğinde, büyük miktarda etiketlenmiş eğitim verisinden görüntülerden ilgili özellikler otomatik olarak çıkarılmakta ve sınıflandırma gibi bir görevin otomatik olarak nasıl gerçekleştirileceği öğretilmektedir (Ayon ve Islam, 2019; Özgüven, 2019; Asraf ve ark., 2020; Islam ve ark., 2020; Islam ve ark., 2021). Şekil 2'de bir örnek bir derin öğrenme uygulamasının genel akışı gösterilmektedir. İlk olarak, veri seti toplanmakta, ardından genellikle eğitim seti %80 ve test seti %20 olacak şekilde iki parçaya bölünmektedir. Daha sonra, derin öğrenme modelleri sıfırdan veya transfer öğrenme tekniği kullanılarak eğitilmekte ve modellerin önemini belirtmek için eğitim/doğrulama grafikleri elde edilmektedir. Görüntülerin sınıflandırılması için performans ölçütleri kullanılmaktadır. Son olarak, görüntüleri algılamak, yerelleştirmek veya sınıflandırmak için görselleştirme teknikleri/haritalamaları kullanılmaktadır (Saleem ve ark., 2019). Derin öğrenmede ön işleme gerek kalmadan evrişimli yapay sinir ağı (CNN) modeli oluşturulabilmekte ve sınıflandırmalar diğer makine öğrenmesi yöntemlerine göre daha hızlı ve daha doğru yapılabilmektedir (Adem, 2018; Adem ve Közkurt, 2019).

Derin öğrenme yöntemi, bitki hastalıklarını ve zararlılarının tanımlanıp zarar seviyelerinin belirlenmesi ile bitki büyüme ve gelişiminin izlenmesiyle daha etkili bitki koruma için fırsatlar sunmaktadır (Ozguven, 2020). Bu nedenle son zamanlarda tüm bitkide ve/veya yaprak, gövde, meyve gibi farklı bitki kısımlarında hastalığın otomatik tespiti için görüntü işleme teknikleri ve derin öğrenme tekniklerinin kullanımı birçok araştırmacı tarafından kapsamlı bir şekilde incelenmiştir (Ozguven ve Adem, 2019; Gayathri ve ark., 2020; Yadav ve ark., 2021; Ozguven ve Altas, 2022).

Bu çalışmada, yaygın olarak görülen ve ekonomik sorun oluşturan külleme, mildiyö, ölü kol hastalığı ile asma yaprak kıvrılma virüs hastalığı (GLRaV) ve asma kısa boğum virüs (GFLV) hastalık görüntülerine nesne tespitinde en yaygın kullanılan Faster R-CNN derin öğrenme modeli uygulanmış ve sınıflandırma işlemi gerçekleştirilmiştir. Çalışmada performans metriği olarak Accuracy, Precision, Recall, F1 Score değerleri elde edilerek başarı değerlendirilmesi yapılmıştır. Önerilen yaklaşım, literatürdeki benzer yöntemlerden daha iyi sonuçlar vermiştir. Bu çalışmanın temel katkısı, fungal ve viral hastalıklardan oluşan beş farklı bağ hastalığı için büyük miktarda yeni bir veri seti oluşturulması ile hastalık tespiti ve sınıflandırılmasında derin öğrenme modelinin kullanılmasıdır.

Materyal ve Yöntem

Görüntülerdeki veya videolardaki nesnelerin örneklerini bulmak için en temel bilgisayarlı görme tekniği olan nesne algılama (object detection) bitki hastalıklarının tespiti için yaygın olarak kullanılmaktadır. İnsanlar, resimlere veya videoya bakarken, ilgilendikleri nesnelere birkaç dakika içinde tanıyabilmekte ve bulabilmektedir. Nesne algılamanın amacı, bu zekayı bir bilgisayar

kullanarak çoğaltmaktır. Nesne algılama için en iyi yaklaşım, uygulamaya ve çözmeye çalışılan soruna bağlıdır. Derin sinir ağları iki şekilde eğitilebilir. Birincisi, yeni bir ağ modeli oluşturarak bu ağı veri seti ile eğitmektir. İkincisi ise veri setini önceden eğitilmiş bir ağ ile özelleştirerek kullanmak ve eğitim sürecini gerçekleştirmektir. Bu çalışmada bağ yaprak, sürgün ve salkım görüntülerindeki hastalıklı bölgelerin tespit edilmesi ve sınıflandırılması için önceden eğitilmiş Faster R-CNN derin öğrenme modeli kullanılmıştır.

Sistem Yapılandırması

Derin öğrenme teknikleri için çok sayıda etiketli eğitim görüntüsü gerekmektedir. Çok sayıdaki görüntüden bir modeli eğitmek için gereken süreyi azaltmak ve doğru sonuçlar almak için GPU kullanılması önerilmektedir. Bu çalışma Intel i9 10850K, 64 GB RAM, Nvidia Quadro RTX 4000 donanım ve MATLAB 2021a platformuna sahip bir bilgisayarda gerçekleştirilmiştir.

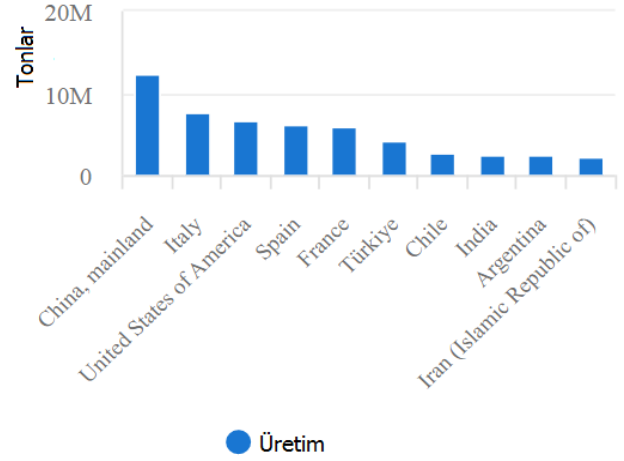
Veri Seti ve Ön işleme

Bir yetiştirme dönemi boyunca düzenli aralıklarla sağlıklı ve hastalıklı bağ yaprak, sürgün ve salkım görüntüleri hastalığın ilk seyriden itibaren Gopro Hero 7 Black Model kamera ile 4000×3000 piksel çözünürlükte toplanmıştır. Çalışmada kullanılan toplam 11000 görüntü; 2420 sağlıklı görüntü, 3215 külleme hastalığı, 1375 mildiyö hastalığı, 1729 ölü kol hastalığı, 1136 GLRaV (asma yaprak kıvrılma virüs hastalığı) ve 1125 GLFV (asma kısa boğum virüs hastalığı) hastalık görüntüsünden oluşmaktadır. Veri setleri işleme tabi tutulmadan önce bazı görüntülerdeki gürültülerin giderilmesi için ön işleme tabi tutulmuştur. Gürültüler giderildikten sonra tüm görüntüler, ayrı ayrı 6 sınıfta etiketlenmiştir. Her bir sınıfta görüntü sayısının %70'i eğitimde %10'u doğrulamada ve %20'si de teste kullanılmıştır. Toplam görüntünün 7700'ü eğitimde, 1100'ü ise eğitim doğruluğunu kontrol etmek için doğrulamada kullanılmıştır. Sistemin hiç görmediği kalan 2220 görüntü ise test olarak kullanılmıştır.

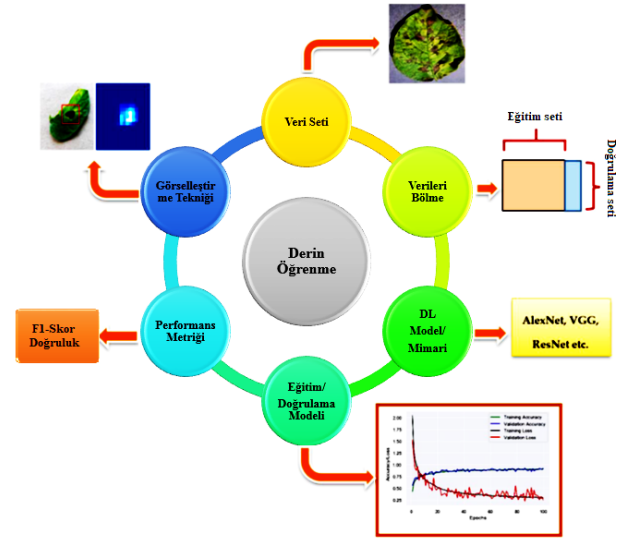
Faster R-CNN Modeli

Faster R-CNN, Girshick (2015), tarafından geliştirilen ve nesne tespiti için kullanılan bir derin öğrenme mimarisidir. Bu mimari, Şekil 3'de görüldüğü gibi üç bölümden oluşmaktadır.


Şekil 3'de görüldüğü gibi ilk kısımda evrişim katmanındaki filtreler ile görüntünün öznelikleri çıkarılmış ve böylece iki boyutlu matris yapısında bir öznelik haritası oluşturulmuştur. İkinci bölümde, sinir ağı olarak kullanılan Bölge Önerme Ağı (RPN), özellik haritalarında nesnelere varsa ilgili nesneye benzerlik (tahmin doğruluğu) olasılığı tahmin edilmektedir. Tahmin katmanı aşaması olan üçüncü bölümde, Faster R-CNN ağı kullanılarak bölgelerin sınıflandırma değeri ile tahmin doğruluk oranı birleştirilerek iki çıktı katmanı oluşturulmuştur. İlk çıktı katmanı softmax sınıflandırmasını gerçekleştirirken, diğer çıktı katmanı algılama doğruluğunu veren regresyon katmanıdır. Bu bölümde sınırlayıcı kutuların sınıfları belirlenerek puan tahminleri yapılmaktadır. Faster R-CNN modelinin getirdiği yenilik, RPN ağının doğrudan özellik haritasının bulunduğu katmana bağlanabilmesidir. Bu sayede tüm görüntülerde nesne tespiti için bir ortam sağlanmaktadır (Jiang ve Learned-Miller, 2017).



Şekil 1. On yıllık üzüm üretimi (ton) (FAO, 2022).
Figure 1. Ten-year grape production (tonnes) (FAO, 2022)



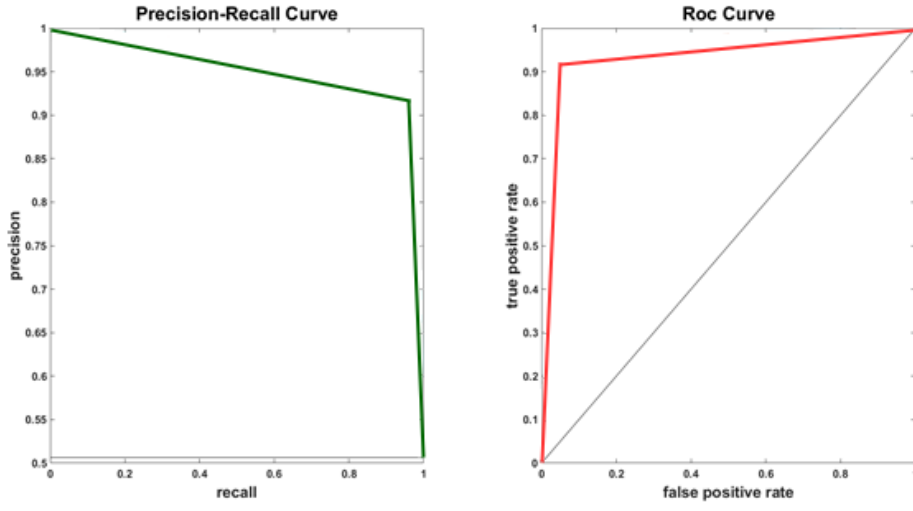
Şekil 2. Akış diyagramı (Saleem ve ark., 2019).
Figure 2. Flow chart (Saleem et al., 2019).



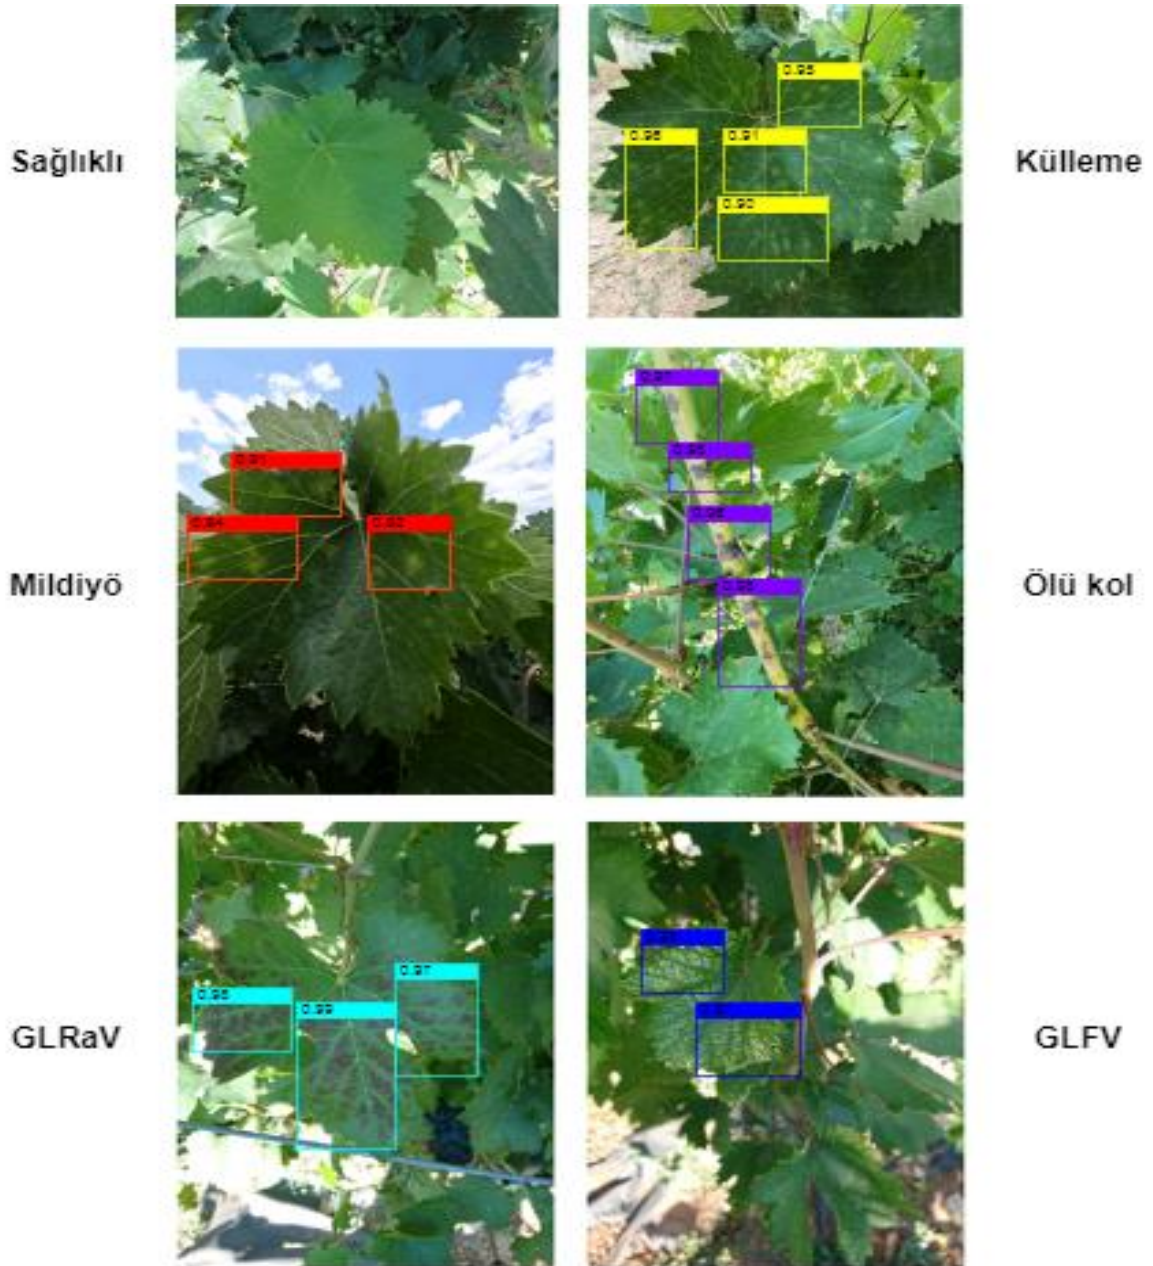
Şekil 3. Faster R-CNN mimarisi (Adem ve ark., 2022).
Figure 3. Faster R-CNN architecture (Adem et al., 2022).

Deneysel Sonuçlar ve Tartışma

Bağ hastalıklarına ait görüntülerde hastalıklı bölgelerin tanımlanması ve sınıflandırılması için önceden eğitilmiş Faster R-CNN derin öğrenme modelinin performansı değerlendirilmiştir. Ayrıca derin öğrenme modeli için eğitim süresi performansı hesaplanmıştır. Daha iyi bir değerlendirme için veri setinden rastgele örnekler seçilmiştir.



Şekil 4. Faster R-CNN modelinin PR Eğrisi ve Roc Eğrisi.
Figure 4. PR Curve and Roc Curve of the Faster R-CNN model.



Şekil 5. Derin öğrenme modelinin uygulanmasına örnek görüntüler.
Figure 5. Example images of the application of the deep learning model.

Çizelge 1. Faster RCNN modelinin karışıklık matrisi.

Table 1. Confusion matrix of the Faster RCNN model.

Sınıflar		Predict (Tahmin)					
		0 Sağlıklı	1 Külleme	2 Mildiyö	3 Ölü kol	4 GLRaV	5 GLFV
Actual (Gerçek)	0 Sağlıklı	470	8	6	0	0	0
	1 Külleme	18	590	11	11	3	10
	2 Mildiyö	3	11	240	7	5	9
	3 Ölü kol	0	6	5	319	5	11
	4 GLRaV	0	4	5	8	206	4
	5 GLFV	0	6	9	7	4	199

Çizelge 2. Faster R-CNN modelinin başarısının değerlendirilmesi.

Table 2. Evaluation of the success of the Faster R-CNN model.

Sınıf	Accuracy	Precision	Recall	F1 Score
0 (Sağlıklı)	98,30	97,10	95,72	96,40
1 (Külleme)	95,83	91,33	94,4	92,83
2 (Mildiyö)	96,61	87,27	86,95	87,10
3 (Ölükol)	97,12	92,19	90,62	91,39
4 (GLRaV)	98,15	90,74	92,37	91,54
5 (GLFV)	97,12	84,44	85,40	84,91
Overall Accuracy	92			

Çizelge 3. Derin öğrenme modelinin doğruluk değeri ve zaman performansı.

Table 3. Accuracy value and time performance of the deep learning model.

Method	Accuracy (%)	F1 Score (%)	Training Time (hours)
Faster R-CNN	92	0,9069	3

Çizelge 4. Bağ hastalıklarının tespitine yönelik çalışmaların karşılaştırılması.

Table 4. Comparison of studies on detection of vineyard diseases.

Yazar	Yıl	Görüntü Sayısı	Model	Nesne	Doğruluk
Ghoury ve ark.	2019	113	Faster R-CNN	GLRaV	93,30
				Mildiyö	95,57
Lauguico ve ark.	2020	900	AlexNet		95,65
			GoogLeNet	Siyah Kızamık	92,29
			ResNet-18		89,49
Xie ve ark.	2020	19362	Faster R-CNN'de INSE-ResNet	Siyah Kızamık	85,30
Liu ve ark.	2020	12740	DICNN	Mildiyö	96,00
Gutierrez ve ark.	2021	275	CNN	Mildiyö	91,00
Ji ve Wu	2022	500	DeepLabV3+	Siyah Kızamık	97,75
Chen ve Wu	2022	200	Faster R-CNN + DCGAN + ResNet	Siyah Kızamık	88,00
Guo ve ark.	2022	2300	Faster R-CNN	Mildiyö	86,91
				Külleme	85,39
Lu ve ark.	2022	12615	MobilenetV3_large	Mildiyö	96,44
				Külleme	99,31
				GLRaV	98,55
Kavala ve Pothuraju	2022	1383	VGG16-19	Siyah Kızamık	98,00
				Külleme	95,83
Önerilen Yöntem	2022	11000	Faster R-CNN	Mildiyö	96,61
				Ölü kol	97,12
				GLRaV	98,15
				GLFV	97,12

Çalışmada kullanılan derin öğrenme modeline ilişkin eğitim sırasında oluşturulan parametreler modelin hesaplama karmaşıklığını doğrudan etkilemektedir. Hesaplama karmaşıklığına ek olarak, modelin yüksek sınıflandırma doğruluğu da çok önemlidir. Faster R-CNN modelinde hastalıklı bölgelerin daha iyi ayırt edilebilmesi için input değeri $512 \times 512 \times 3$ olarak alınmıştır. Konvolüsyon katmanlarında 32 adet 4 adım, 2 dolgu'lu 3×3 'lük filtre uygulanmıştır. Modelde öğrenme oranı 0.001 olarak

belirlenmiştir. Değerin çok düşük seçilme amacı öğrenme hızını düşürmek ve öğrenme süresini artırmaktır. Bu değer yüksek seçilmesi durumunda çok hızlı öğrenmeye çalıştığı için yetersiz öğrenmeye neden olmaktadır. Ağırlık güncelleme aşamasında kullanılan 'MiniBatchSize' değeri 32 olarak belirlenmiştir. Eğitim algoritmasının veri seti üzerindeki uygulama sayısını gösteren 'MaxEpochs' değeri 100 olarak belirlenmiştir. Hastalıklı bölgeyi aynı verilerle öğrenerek 'Shuffle' değeri 'ever-epoch' olarak seçilmiştir.

Aşırı uymayı önlemek için 'Dropout' değeri 0,1 olarak ayarlanmıştır. Derin öğrenme modelinin uygulanması sonucunda elde edilen karışıklık matrisi Çizelge 1'de verilmiştir.

Precision-Recall (PR) eğrisi, dengesiz verilerle uğraşırken bir modelin performansının daha gerçekçi bir görünümünü sağlamaktadır. Şekil 4'de görüldüğü gibi çalışmada kullanılan veri setinde böyle bir sorun yaşanmamış ve tutarlı sonuçlar elde edilmiştir. Ayrıca Çizelge 3 çalışmanın genel doğruluk, F1 skoru ve eğitim süresi değerlerini göstermektedir.

Faster R-CNN derin öğrenme modelinin test görüntülerine uygulanması sonucunda, 484 sağlıklı görüntünün 470'i, 643 külleme hastalığının 590'u, 275 mildiyö hastalığının 240'u, 346 ölü kol hastalığının 319'u, 227 GLRaV hastalığının 206'sı ve 225 GLFV hastalığının 199'u doğru sınıflandırılmıştır. Toplamda 2220 test görüntüsünden 2024 görüntü doğru tahmin edilerek genel başarı oranı %92 olarak bulunmuştur. Faster R-CNN modelinin doğruluk açısından elde edilen sonuçların daha iyi değerlendirilebilmesi için Precision-Recall (PR) eğrisi ve Roc eğrisi Şekil 4'de gösterilmiştir.

Faster R-CNN modelinin uygulanması sonucunda elde edilen görüntülere örnekler Şekil 5'de gösterilmektedir. Bitkilerde bazı bağ hastalıklarının teşhisi konusunda son yıllarda yapılan akademik çalışmaların başarı oranlarının karşılaştırılması ve önerilen yöntem Çizelge 4'de verilmiştir.

Çizelge 4'de çalışmada önerilen modelin bazı bağ hastalıklarını sınıflandırma başarısı ile literatürdeki bazı çalışmalarda kullanılan derin öğrenme modellerinin sonuçları karşılaştırılmıştır. Önerilen yaklaşım, literatürdeki bazı benzer yöntemlerden daha iyi sonuçlar vermiştir. Literatürde son 5 yılda yapılan çalışmalar incelendiğinde bitki hastalıklarının teşhisinde derin öğrenme modellerinin yoğun olarak kullanıldığı görülmektedir. Çalışmalarda genellikle derin öğrenme modelleri olarak Faster RCNN, VGG16, VGG19 ve GoogLeNet, AlexNet, ResNet modellerinin tercih edildiği görülmektedir. Ayrıca literatürdeki tüm çalışmalarda derin öğrenme modellerinin doğrudan bitki hastalıklarının görüntülerine uygulandığı görülmüştür. Bu çalışmada, Faster R-CNN derin öğrenme modelinin veri setine uygulanması sonucunda hastalıkların doğruluk oranları; külleme %95,83, mildiyö %96,61, ölü kol %97,12, GLRaV %98,15, GFLV %97,12 olarak bulunmuştur. Hastalıkların tespiti ve sınıflandırılmasında %92 genel doğruluk elde edilmiştir. Bu sonuçlar neticesinde tarımsal problem için doğru derin öğrenme modelinin belirlenmesinin önemli olduğu sonucuna varılmıştır. Yanlış sınıflandırmalar incelendiğinde bitki yapraklarının görüntülerinde güneş kaynaklı parlak ve gölgelerin olduğu görülmektedir. Kılıçarslan (2022), hibrit yöntemlerin daha yüksek performans gösterdiğini bildirmiştir. Hastalık tespitinde de hibrit yöntemler uygulanarak başarı oranının artacağı düşünülmektedir.

Sonuç

Son yıllarda, bitki hastalıklarının otomatik teşhisi için yapılan çalışmalarda makine öğrenmesi yöntemlerinin geliştirilmesine odaklanılmıştır. Bu çalışmalarda hastalık semptomlarının daha hızlı saptanması ve hastalık

sınıflandırma sonuçlarının doğruluğunun artırılması üzerine çalışılmaktadır. Model performansı arttıkça bitki hastalıklarının tanımlanmasındaki başarı da artacaktır. Çalışmada, bazı bağ hastalıklarının tespiti ve sınıflandırılması için Faster R-CNN derin öğrenme modeli yöntem olarak önerilmiştir. Deneysel değerlendirmeler sonucunda hastalıkların doğruluk oranları; külleme %95,83, mildiyö %96,61, ölü kol %97,12, GLRaV %98,15, GFLV %97,12 olarak bulunmuştur. Hastalıkların tespiti ve sınıflandırılmasında %92 genel doğruluk elde edilmiştir. Önerilen yöntemin, bağ hastalıklarının tespiti ve sınıflandırılmasında güvenilir bir şekilde kullanılabilmesi sonucuna varılmıştır. Ayrıca geliştirilecek yeni model başarılarının daha da artırılması ile görüntüleme ve veri iletimi teknolojilerindeki gelişmeler ile bitki hastalık görüntülerinin gerçek zamanlı olarak değerlendirilmesini sağlayabilecektir. Gelecekteki çalışmada, bağ hastalıkları görüntüleri üzerinden, derin öğrenme yöntemleri kullanılarak hızlı karar verebilecek uzman sistemlerin geliştirilmesi amaçlanmaktadır.

Kaynaklar

- Adem K. 2018. Exudate detection for diabetic retinopathy with circular Hough transformation and convolutional neural networks. *Expert Systems with Applications*, (114):289-295. doi: 10.1016/j.eswa.2018.07.053
- Adem K, Közkurt C. 2019. Defect detection of seals in multilayer aseptic packages using deep learning. *Turk J Elec Eng & Comp Sci*, 27:4220-4230. doi:10.3906/elk-1903-112
- Adem K, Ozguven MM, Altas Z. 2022. A sugar beet leaf disease classification method based on image processing and deep learning. *Multimedia Tools and Applications*, <https://doi.org/10.1007/s11042-022-13925-6>
- Altas Z, Özgüven MM, Dilmaç M. 2021. Görüntü işleme teknikleri ile bağ yaprak uyuzu hasarının belirlenmesi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, Volume 10:3: 77-87
- Ampatzidis Y, De Bellis L, Luvisi A. 2017. iPathology: robotic applications and management of plants and plant diseases. *Sustainability*, 9(6):1010. <https://doi.org/10.3390/su9061010>
- Asraf A, Islam M, Haque M. 2020. Deep learning applications to combat novel coronavirus (COVID-19) pandemic. *SN Comput Sci*, 1(6):1-7
- Ayon SI, Islam MM. 2019. Diabetes prediction: a deep learning approach. *Int J Inform Eng Electron Bus*, 12(2):21
- Bock CH, Poole GH, Parker PE, Gottwald TR. 2010. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *CRC Crit Rev Plant Sci*, 29(2):59-107
- Chen Y, Wu Q. 2022. Grape leaf disease identification with sparse data via generative adversarial networks and convolutional neural networks. *Precision Agriculture*, (2022). <https://doi.org/10.1007/s11119-022-09941-z>
- Cruz AC, Luvisi A, De Bellis L, Ampatzidis Y. 2017. X-FIDO: an effective application for detecting olive quick decline syndrome with deep learning and data fusion. *Front Plant Sci*, 8:1741. <https://doi.org/10.3389/fpls.2017.01741>
- FAO, 2022. Food and Agriculture Organization of the United Nations. FAOSTAT, <https://www.fao.org/faostat/en/#data/QCL>. (Erişim Tarihi: 25.10.2022)
- Gavhale KR, Ujwalla G. 2014. An overview of the research on crop leaves disease detection using image processing techniques. *IOSR J Comput Eng*, 16(1):10-16
- Gayathri S, Wise DJW, Shamini PB, Muthu kumar N. 2020. Image analysis and detection of tea leaf disease using deep learning. In: 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC). IEEE, pp 398-403

- Ghoury S, Sungur C, Durdu A. 2019. Real-time diseases detection of grape and grape leaves using Faster R-CNN and SSD-MobileNet Architectures. International Conference on Advanced Technologies, Computer Engineering and Science (ICATCES 2019), Apr 26–28, 2019 Alanya, Türkiye
- Girshick R. 2015. Fast R-CNN. Proceedings of the IEEE international conference on computer vision, Santiago, Chile, pp 1440–1448
- Guo W, Feng Q, Li X, Yang S, Yang J. 2022. Grape leaf disease detection based on attention mechanisms. *Int J Agric and Biol Eng*, 15(5): 205-2012. Doi: 10.25165/j.ijabe.20221505.7548
- Gutiérrez S, Hernández I, Ceballos S, Barrio I, Navajas AMD, Tardaguila J. 2021. Deep learning for the differentiation of downy mildew and spider mite in grapevine under field conditions. *Computers and Electronics in Agriculture*, 182:105991. <https://doi.org/10.1016/j.compag.2021.105991>
- Islam M, Haque M, Iqbal H, Hasan M, Hasan M, Kabir MN. 2020. Breast cancer prediction: a comparative study using machine learning techniques. *SN Comput Sci*, 1(5):1-14
- Islam MM, Karray F, Alhadj R, Zeng J. 2021. A review on deep learning techniques for the diagnosis of novel coronavirus (COVID-19). *IEEE Access*, 9:30551–30572
- Ji M, Wu Z. 2022. Automatic detection and severity analysis of grape black measles disease based on deep learning and fuzzy logic. *Computers and Electronics in Agriculture*, 193:106718. <https://doi.org/10.1016/j.compag.2022.106718>
- Jiang H, Learned-Miller E. 2017. Face detection with the Faster R-CNN. In: 2017 12th IEEE international conference on automatic face & gesture recognition (FG 2017), pp 650–657
- Karabat S. 2014. Türkiye ve Dünya Bağcılığı. *Apelasyon*, ISSN:2149-4908. <http://apelasyon.com/Yazi/33-dunya-ve-turkiye-bagciligi> (Erişim Tarihi: 26.08.2019).
- Kavala SAPN, Pothuraju R. 2022. Detection of grape leaf disease using transfer learning methods: VGG16&VGG19. Proceedings of the Sixth International Conference on Computing Methodologies and Communication (ICCMC 2022), IEEE Xplore Part Number: CFP22K25-ART; ISBN: 978-1-6654-1028-1
- Kılıçarslan S. 2022. Kuru üzüm tanelerinin sınıflandırılması için hibrit bir yaklaşım. *Müh. Bil. ve Araş. Dergisi*, 4(1):62-71. <https://doi.org/10.46387/bjesr.1084590>
- Lauguico S, Concepcion IIR, Tobias RR, Bandala A, Vicerra RR, Dadios E. 2020. Grape leaf multi-disease detection with confidence value using transfer learning integrated to regions with convolutional neural networks. 2020 IEEE Region 10 Conference (Tencon), Osaka, Japan, November 16-19, 2020
- Liu B, Ding Z, Tian L, He D, Li S, Wang H. 2020. Grape leaf disease identification using improved deep convolutional neural networks. *Front Plant Sci*, 11:1082. <https://doi.org/10.3389/fpls.2020.01082>
- Lu X, Yang R, Zhou J, Jiao J, Liu F, Liu Y, Su B, Gu P. 2022. A hybrid model of ghost-convolution enlightened transformer for effective diagnosis of grape leaf disease and pest. *Journal of King Saud University – Computer and Information Sciences*, 34(2022): 1755-1767. <https://doi.org/10.1016/j.jksuci.2022.03.006>
- Ma J, Du K, Zheng F, Zhang L, Gong Z, Sun Z. 2018. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network. *Comput Electron Agric* 154:18–24. <https://doi.org/10.1016/j.compag.2018.08.048>
- Özgülven MM. 2018. Hassas tarım. Akfon Yayınları, Ankara (in Turkish). ISBN: 978-605-68762-4-0
- Özgülven MM. 2019. Technological concepts and their differences. International Erciyes Agriculture, Animal and Food Sciences Conference 24–27 April 2019- Erciyes University – Kayseri, Türkiye
- Ozguven MM. 2018. The newest agricultural technologies. *Curr Investigations Agric Curr Res*, 5(1):573–580. <https://doi.org/10.32474/CIACR.2018.05.000201>
- Ozguven MM, Adem K. 2019. Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A*, 535:122537
- Ozguven MM. 2020. Deep learning algorithms for automatic detection and classification of mildew disease in cucumber. *Fresenius Environ Bull*, 29:7081–7087
- Ozguven MM, Altay Z. 2022. A new approach to detect mildew disease on cucumber (*Pseudoperonospora cubensis*) leaves with image processing. *J Plant Pathol*. <https://doi.org/10.1007/s42161-022-01178-z>
- Rossi V. 1995. Effect of host resistance in decreasing infection rate of cercospora leaf spot epidemics on sugarbeet. *Phytopathol Mediterr*, 34:149–156
- Saleem MH, Potgieter J, Arif KM. 2019. Plant disease detection and classification by deep learning. *Plants*, 8, 468. doi:10.3390/plants8110468
- Song HA, Lee SY. 2013. Hierarchical representation using NMF. International conference on neural information processing, pp 466–473
- TÜİK, 2021. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Kategori/GetKategori?p=tarim-111&dil=1>. (Erişim Tarihi: 21.12.2021)
- Wang QQiF. 2019. Tomato diseases recognition based on Faster RCNN. IEEE, 10th International Conference on Information Technology in Medicine and Education (ITME), 78-1-7281–3918–0. <https://doi.org/10.1109/ITME.2019.00176>
- Xie X, Ma Y, Liu B, He J, Li S, Wang H. 2020. A deep-learning-based real-time detector for grape leaf diseases using improved convolutional neural networks. *Front. Plant Sci*, 11:751. doi: 10.3389/fpls.2020.00751
- Yadav S, Sengar N, Singh A, Singh A, Dutta MK. 2021. Identification of disease using deep learning and evaluation of bacteriosis in peach leaf. *Ecol Inf*, 61:101247. <https://doi.org/10.1016/j.ecoinf.2021.101247>