



Detection of Some Grape Varieties with Deep Learning Techniques

İsmail Terzi^{1,a,*}, Mehmet Metin Özgüven^{1,b}, Adem Yağcı^{2,c}

¹Department of Biosystems Engineering, Tokat Gaziosmanpaşa University, Türkiye

²Department of Horticulture, Tokat Gaziosmanpaşa University, Türkiye

*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 05/11/2022 Accepted : 20/11/2022</p> <p>Keywords: Deep learning CNN Classification Grape Ampelography</p>	<p>While determining grape varieties in viticulture, characterization features of shoots, leaves, clusters and fruits are used. These characterization features, in order to form an international method union, with a working team formed on behalf of the "International Board for Plant Genetic Resources" and the "Office International de la Vigne et du Vin-OIV" and "International Board for Plant Genetic Resources". It has been published in a norm called 'Grape Descriptors', developed in collaboration with the international union for the Protection of New Varieties of Plants-UPOV. The ampelographic characteristics of grape varieties are determined according to the characterization features in this norm. Each grape variety has ampelographic characteristics specific to its shoot, leaf, inflorescence and fruit. After these features are determined according to the grape descriptor norm, they are expressed numerically or verbally. In this study, using ampelographic features, Corint, Merlot, Tayfi, Michele palieri, Narince grape varieties were classified using deep learning techniques. The aim is to determine which grape variety it is by using the ampelographic characteristics of grape varieties with deep learning techniques. A new CNN model consisting of 15 layers was created for the study. A total of 1028 images of 227×227×3 dimensions of the clusters and fruits of five grape varieties were used in the data set with five classes. 80% of the images are reserved for training and 20% for validation. In the MATLAB program, 96.10% classification success rate was achieved with the new and originally developed CNN model. It was concluded that the CNN model created as a result of the analyzes was successful and could be used in the classification of grape varieties.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 11(1): 125-130, 2023

Derin Öğrenme Teknikleri ile Bazı Üzüm Çeşitlerinin Tespiti

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 05/11/2022 Kabul : 20/11/2022</p> <p>Anahtar Kelimeler: Derin öğrenme CNN Sınıflandırma Üzüm Ampelografi</p>	<p>Bağcılıkta üzüm çeşitleri belirlenirken, sürgün, yaprak, salkım ve meyveye ait karakterizasyon özellikler kullanılmaktadır. Bu karakterizasyon özellikler uluslararası yöntem birliğinin oluşması için "Uluslararası Bitki Gen Kaynakları Merkezi" (International Board for Plant Genetic Resources) adına oluşturulmuş bir çalışma ekibi ile "Bağcılık ve Şarapçılık Ofisi" (Office International de la Vigne et du Vin-OIV) ve "Uluslararası Yeni Bitki Çeşitlerinin Korunması Birliği" (International union for the Protection of New Varieties of Plants- UPOV) ile işbirliği içinde yapılan çalışmalarla geliştirilmiş 'Üzüm Tanımlayıcıları' (Grape Descriptors) adıyla bir normda yayınlanmıştır. Üzüm çeşitlerinin sahip olduğu ampelografik özellikler bu normdaki karakterizasyon özelliklere göre belirlenerek ortaya çıkarılmaktadır. Her üzüm çeşidinin sürgününe, yaprağına, salkımına ve meyvesine özgü ampelografik özellikleri bulunmaktadır. Bu özellikler 'Üzüm Tanımlayıcıları' normuna göre belirlendikten sonra sayısal veya sözel olarak ifade edilmektedir. Bu çalışmada ampelografik özellikler kullanılarak Corint, Merlot, Tayfi, Michele palieri, Narince üzüm çeşitlerinin derin öğrenme teknikleri ile sınıflandırılması yapılmıştır. Amaç üzüm çeşitlerinin ampelografik özelliklerini kullanarak derin öğrenme teknikleri ile hangi üzüm çeşidi olduğunu belirlemektir. Yapılan çalışma için 15 katmandan meydana gelen yeni bir CNN modeli oluşturulmuştur. Beş sınıflı bulunan veri setinde beş adet üzüm çeşidinin salkım ve meyvelerine ait 227x227x3 boyutunda toplam 1028 adet görüntü kullanılmıştır. Görüntülerin %80'i eğitim için %20'si ise doğrulama için ayrılmıştır. MATLAB programında, yeni ve özgün olarak geliştirilen CNN modeli ile %96,10 sınıflandırma başarı oranı elde edilmiştir. Yapılan analizler neticesinde geliştirilen CNN modelinin başarılı olduğu ve üzüm çeşitlerinin sınıflandırılmasında kullanılabileceği sonucuna varılmıştır.</p>

^a iso_di@hotmail.com
^c adem.yagci@gop.edu.tr

^b <https://orcid.org/0000-0003-2710-9172> | metin.ozguven@gop.edu.tr
^b <https://orcid.org/0000-0002-3650-4679>

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



Giriş

Üzüm, dünyada üreticiliği yapılan ve tarih öncesi dönemlerde kültüre alınan hem taze olarak hem de kurutulmuş geniş bir tüketim alanı bulunan, doğu ve batı medeniyetlerinin sosyal ve ekonomik yapılanmasında önemli yeri olan en eski bitki çeşitlerindedir (Çelik ve ark., 1998; Ağaoğlu, 1999). İçerisinde bulunan vitaminlerin, proteinlerin, karbonhidratların, mineral maddelerin ve antosiyaninlerin zenginliği nedeniyle üzüm, insanların beslenme ihtiyacını karşılama açısından önemli paya sahip bir üründür (Xia ve ark., 2010; Lim, 2013).

Dünyadaki üzüm üretimi yapılan alanların ve üzüm üretimi miktarının güncel olan durumuna bakıldığında, sekiz ülkenin üretimde öne çıktığı görülmektedir. Türkiye bu sıralamada üzüm üretimi yapılan alanda beşinci, toplam üzüm üretiminde ise altıncı sırada bulunmaktadır. Türkiye’de üretimi yapılan üzümler ticari olarak değerlendirildiğinde; sofrada, kurutmada, şıra ve şarap yapımında kullanılmak üzere pek çok üzüm çeşidi yetiştirilmektedir. Dünyadaki toplam üzüm üretiminin %5’i Türkiye’de yapılmaktadır. Buna rağmen ülkemizde üzüm üretiminde beklenen potansiyele tam olarak ulaşamamıştır. Ülkemiz birim alan başından elde edilen üzüm verimi açısından, İtalya’dan sonra altıncı sırada bulunmaktadır. Bağcılık yapılan alanlarda modern teknolojik uygulamaların kullanılmasıyla dünya sıralamasında üst sıralara çıkılması mümkün olabilecektir (FAO, 2021).

Dünyada yaklaşık 13.000 üzüm çeşidi bulunurken (Alleweldt, 1997) üzüm yetiştiriciliği açısından en uygun iklim kuşağına sahip (Karabat, 2014) ülkemizde ise bölgesel olarak 1400 çeşidin olduğu bilinmektedir (Sağlam ve Çalkan Sağlam, 2018). Üzüm çeşitlerini tespit etmek amacıyla kullanılan ampelografik özellikler; sürgün ucu, genç yaprak, olgun yaprak, odunsu sürgün, çiçek, salkım, meyve ve çekirdeklere ait karakterizasyon özelliklerden meydana gelmektedir. Bu karakterizasyon özellikler uluslararası yöntem birliğinin oluşması için “Uluslararası Bitki Gen Kaynakları Merkezi” (International Board for Plant Genetic Resources) adına oluşturulmuş bir çalışma ekibi ile “Bağcılık ve Şarapçılık Ofisi” (Office International de la Vigne et du Vin-OIV) ve “Uluslararası Yeni Bitki Çeşitlerinin Korunması Birliği” (International union for the Protection of New Varieties of Plants- UPOV) ile işbirliği içinde yapılan çalışmalarla geliştirilmiş ‘Üzüm Tanımlayıcıları’ (Grape Descriptors) adıyla bir normda yayınlanmıştır. Üzüm çeşitlerinin sahip olduğu ampelografik özellikler bu normdaki karakterizasyon özelliklere göre belirlenerek ortaya çıkarılmaktadır. Her üzüm çeşidinin sürgününe, yaprağına, salkımına, meyvesine ve çekirdeğine özgü ampelografik özellikleri bulunmaktadır. Bu özellikler ‘Üzüm Tanımlayıcıları’ (Grape Descriptors) normuna (Anonymous, 1997) göre belirlendikten sonra sayısal veya sözel olarak ifade edilmektedir.

Ülkemizin ekonomisine büyük katkı sağlayan ve tarımsal üretimin önemli bir dalı olan bağcılığın geliştirilmesi nedeniyle asma genetik kaynaklarının bir araya getirilmesi, muhafaza edilmesi, geliştirilmesi ve çeşitlerinin tespit edilmesi amacıyla yapılan çalışmalar ülkemiz bağcılığı açısından gerekli ve önemlidir (Ünal, 2020). Üzüm tür ve çeşitleri üzerinde hem fenolojik hem pomolojik hem de morfolojik tanımlamalar yapılmaktadır.

Bu tanımlamalar, çeşitlere ait özelliklerin hızlı ve doğru bir şekilde ortaya çıkarılması; çeşit tescili ve yetiştirme tekniği açısından yapılan çalışmalardır. Bu bakımdan ülkemizdeki bölgesel üzüm çeşitlerinin büyük bir bölümünün fenolojik, pomolojik ve ampelografik özellikleri ortaya çıkarılmıştır (Altuntaş ve ark., 2019).

Dünya ve ülkemiz ekonomisine büyük katkı sağlayan üzüm çeşitlerinin tespitinde ve sınıflandırılmasında oluşan karmaşanın ortadan kaldırılması, bağcılığın geliştirilmesi bakımından önem arz etmektedir (Pınar ve ark., 2018). Bu karmaşanın ortadan kaldırılması için özellikle büyük üretim yapılan alanlarda insan hatalarını en aza indirebilen daha hızlı ve pratik tekniklere ihtiyaç duyulmaktadır (Altas ve ark., 2018). Üzüm çeşitleri, sürgün, yaprak, salkım, meyve ve çekirdeklerinin karakterizasyon özelliklerine göre farklılıklar göstermektedirler. Görüntü işleme yöntemleri ile bu farklılıklar ayırt edilebilmektedir (Ozguven ve Altas, 2022). Son yıllarda ise özellikle makine öğreniminin alt dalı olan derin öğrenme teknikleri kullanılarak daha hızlı ve etkin bir şekilde (Adem ve Közkurt, 2019) üzüm çeşitlerinin karakterizasyon özellikleri kullanılarak çeşit tespiti ve sınıflandırılması yapılabilmektedir.

Makine öğrenmesi alt sınıfı olan derin öğrenme, özellik çıkarımı ve dönüştürme işlemi için birden fazla doğrusal olmayan işlem birim katmanını kullanmaktadır. Ardışık olan katmanlar bir önceki katmanlardaki çıktıyı girdi olarak kullanır (Deng ve Yu, 2014). Derin öğrenme tekniklerinde, verilerin birden çok özellik seviyelerinin ve temsilinin öğrenilmesine dayalı bir yapı bulunmaktadır. Üst düzey özelliklerden alt düzey özellikler oluşturularak hiyerarşik bir temsil meydana getirilir. Bu temsil ise soyutlama işleminin değişik seviyelerine karşı birden fazla temsil seviyesini öğrenmektedir (Bengio, 2013). Derin öğrenme tekniklerinde el ile ortaya çıkarılan özellikler yerine veriyi en iyi şekilde temsil eden ve hiyerarşik özelliklerin çıkarımında etkin algoritmalar kullanılmaktadır (Song ve Lee, 2013). Derin öğrenmede, ön işleme gerek duyulmadan evrimsel yapay sinir ağı (CNN) modeli oluşturulabilmekte ve sınıflandırma işlemleri diğer makine öğrenmesi yöntemlerine göre daha hızlı ve daha doğru yapılabilmektedir (Adem, 2018; Adem ve Közkurt, 2019).

Son yıllarda derin öğrenme teknikleri kullanılarak bitkisel üretim alanında hastalık ve zararlı tespiti, bitki çeşidi tespiti ve sınıflandırılması gibi birçok konuda çalışma yapılmıştır. Yapılan bazı çalışmalarda; 18149 görüntü ile %90 (Yamamoto ve ark., 2017), 1965 görüntü ile %95 (Türkoğlu ve Hanbay 2019), 54000 görüntü ile %91 (Mohameth ve ark., 2020), 175 görüntü ile %94 (Ozguven, 2020), 13200 görüntü ile %94 (Diaz ve ark., 2021), 18160 görüntü ile %95 (Atik, 2022) başarımlar elde edilmiştir.

Bu çalışmada, 5 adet (Corint, Merlot, Tayfi, Michele palieri, Narince) üzüm çeşidinin salkım ve meyve görüntüleri üzerinde, çeşit tespitinde kullanılan ampelografik özellikler kullanılarak geliştirilen CNN modeli ile çeşitlerin sınıflandırılması gerçekleştirilmiştir. Üzüm çeşitlerinin ampelografik özelliklerinin belirlenmesi, tanımlama ve sınıflandırma bakımından önem arz ettiği kadar, herhangi bir alana en iyi uyum sağlayan üzüm çeşitlerinin tespiti açısından da önem taşımaktadır (Çelik ve Karanis, 1998). Bu çalışmada, her

alandaki olduğu gibi teknolojideki son gelişmelerin tarımsal alanda da kullanılması amaçlanmaktadır. Bununla beraber çevreye duyarlı, ileri tarım teknolojilerini kullanarak daha az girdi ile daha fazla üretim, yüksek kalitede ürün ve daha çok gelir elde edilmesini imkân sağlayan çalışmalarla bilime katkı sağlanması hedeflenmektedir. Çalışmada performans metriği olarak doğruluk değerleri elde edilerek başarı değerlendirilmesi yapılmıştır.

Materyal ve Yöntem

Materyal

Çalışmada, Intel(R) Core(TM) i5-7200U, 2,50 GHz işlemci hızı 4 GB RAM, 2 GB AMD Radeon R5 M330 ekran kartı ve MATLAB 2021a platformuna sahip bilgisayar kullanılmıştır. Tespit edilmeye çalışılan üzüm çeşitleri, Tokat ilinde bulunan Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğüne ve Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi'ne ait bağ alanlarından seçilmiştir. Bu bağ alanlarından, derin öğrenme yöntemlerinde veri seti olarak kullanılan 5 sınıf (Corint, Merlot, Tayfi, Michele palieri, Narince) ve 2 özellikten (salkım-meyve) oluşan üzüm çeşitlerine ait görüntüler GoPro Hero 7 Black model kamera kullanılarak elde edilmiştir. Her bir üzüm çeşidine ait en az 200'er adet, toplamda ise 1028 adet görüntü bulunmaktadır. Michele palieri üzüm çeşidine ait görüntüler Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi'ne ait bağ alanından, Corint, Merlot, Tayfi ve Narince üzüm çeşitlerine ait görüntüler ise Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü'ne ait bağ alanından elde edilmiştir. Görüntüler bağ alanlarında bulunan üzüm çeşitlerinin olgunlaşma dönemlerine göre farklı tarihlerde alınmıştır. Görüntülerin elde edildiği tarihler ve bağ alanı bilgileri Çizelge 1'de gösterilmektedir.

Gerçek zamanlı bir çalışmada salkım ve meyve birbirinden ayrı tutulmadığı için etiketleme işlemlerinde aynı görüntü üzerinde ayrı ayrı hem salkım özelliklerine hem de meyve özelliklerine etiketleme işlemi yapılarak veri seti oluşturulmuştur. Derin öğrenme teknikleri ile çeşitlerin sisteme öğretilmesi MATLAB platformu ile yapılmıştır. MATLAB platformu üzerinde üzüm çeşitlerinin tespit edilmesinde geliştirilen 15 katmanlı ve eğitim seçenekleri; 'InitialLearnRate' 0.1, 'MaxEpoch' 42,

'ValidationFrequency' 23 olan yeni bir derin öğrenme modeli CNN (Convolutional Neural network) kullanılmıştır. Şekil 1'de veri setinde kullanılan beş adet üzüm çeşidine ait (salkım-meyve) görüntülerden örnekler gösterilmektedir.

Görüntüler elde edildikten sonra veri kümesinde temizleme, çoğaltma, boyutlandırma ve normalize işlemleri gerçekleştirilerek 5 sınıfta, meyve şekli ve salkım yoğunluğu ampelografik özellikleri üzerinde etiketleme işlemleri yapılmıştır. Yapılan etiketlerin bazı örnek görüntüleri Şekil 2'de gösterilmektedir.

Yöntem

Çalışmada, salkım ve meyve özellik görüntülerinin yer aldığı 5 sınıflık (Corint, Merlot, Tayfi, Michele palieri, Narince) bir veri seti oluşturulmuştur. Oluşturulan veri setindeki görüntüler, kullanılan derin öğrenme modeline giriş görüntüsü için 227×227×3 şeklinde yeniden boyutlandırılmıştır. 5 sınıfın her birinde görüntülerin %80'i eğitim işlemlerine %20'si ise doğrulama işlemlerine rastgele ayrılmıştır. Veri setinde bulunan toplam 1028 adet görüntünün 796 tanesi eğitimde, 232 tanesi ise doğrulamada kullanılmıştır.

Geliştirilen derin öğrenme modelinde ilk önce görüntü depolama aracılığıyla veri seti sisteme aktarılmıştır. Ardından eğitim için ayrılan görüntüler geliştirilen modelde belirlenen eğitim seçenekleri ile eğitilmiştir. Eğitilen ağ sistemin hiç görmediği doğrulama görüntülerinde test edilmiştir. Çeşitlerin tespiti ve sınıflandırılmasında derin öğrenme modelinin uygulanması sonucu doğruluk oranları elde edilmiştir.

Bulgular ve Tartışma

Corint, Merlot, Tayfi, Narince ve Michele palieri üzüm çeşitlerinin salkım ve meyve özellikleri ile sınıflandırılması için yeni ve özgün olarak geliştirilen derin öğrenme modelinin performansı analiz edilmiştir. 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. Şekil 3'te eğitim işlemlerine ait grafikte sınıflandırma doğruluk başarı oranı gösterilmektedir.

Çizelge 1. Görüntülerin elde edildiği tarihler ve bağ alanı bilgileri

Table 1. Dates of acquisition of images and vineyard area information

Çeşit adı	Özellik	Görüntü alınan tarih	Görüntü alınan bağ
Corint, Merlot, Tayfi, Narince, Michele palieri	Salkım	16-20-21-24.08.2020	Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi
	Meyve	23-24.09.2020	

Çizelge 2. Veri setinde bulunan üzüm çeşitlerinin özelliklerine ait görüntü sayıları

Table 2. Number of images of grape varieties in the data set

Genotip (Çeşitler)	Özelliklerin görüntü sayısı		Genel toplam
	Salkım	Meyve	
Corint	108	104	212
Merlot	102	103	205
Tayfi	102	104	206
Michele palieri	102	102	204
Narince	101	100	201
Genel toplam	515	513	1028

Çizelge 3. Sınıflandırma modelinin karışıklık matrisi.

Table 3. Confusion matrix of the classification model.

Sınıflar		Predict (Tahmin)				
		Corint	Merlot	M.palieri	Narince	Tayfi
Actual (Gerçek)	Corint	53	0	0	1	0
	Merlot	0	46	0	0	0
	M.palieri	0	0	44	0	0
	Narince	8	0	0	33	0
	Tayfi	0	0	0	0	46

Çizelge 4. CNN modelinin başarısının değerlendirilmesi.

Table 4. Evaluating the success of the CNN model.


Sınıf	Accuracy	Precision	Recall	F1 Score
Corint	86,90	98,10	86,80	92,10
Merlot	100	100	100	100
M.palieri	100	100	100	100
Narince	97,10	80,40	97,05	87,94
Tayfi	100	100	100	100
Overall Accuracy	96,10			

Çizelge 5. Bu çalışma ve tarımsal alanda yapılan diğer çalışmaların başarı oranı değerleri

Table 5. Success rate values of this study and other studies in the agricultural field

S. no	Kaynak	Veri seti kaynağı	Kullanılan veri	Model	Sınıf sayısı	Görüntü sayısı	Doğruluk (%)
1	Yamamoto ve ark. (2017)	PlantVillage	Domates yaprağı	SCRNN	14	18149	90
2	Türkoğlu ve Hanbay (2019)	Kendi veri seti	Hastalık/zararlı görüntüsü	VGG16	8	1965	95
3	Ozguven (2020)	Kendi veri seti	Salatalık yaprağı	Faster R-CNN	5	175	94,86
4	Mohameth ve ark. (2020)	PlantVillage	Bazı meyve-sebzeler	ResNet	14	54000	91
5	Diaz ve ark (2021)	Bejo (Tarımsal şirket)	Lahana Yapracağı	AlexNet	6	13200	94
6	Divakar ve ark. (2021)	Plant Pathology	Elma yaprağı	DenseNet	4	3640	92,28
7	Atik (2022)	PlantVillage	Domates yaprağı	GoogleNet	10	18160	95,18
8	Nasiri ve ark. (2022)	Kendi veri seti	Yabancı ot	ResNet50	9	1385	96
9	Raei ve ark. (2022)	Kendi veri seti	Arazi görüntüsü	ResNet34	4	3600	94
10	Yapılan çalışma (2022)	Kendi veri seti	Üzüm (salkım/meyve)	CNN	5	1028	96,10

Şekil 1. Üzüm çeşitlerine ait görüntüler (veri setinden örnekler)
Figure 1. Images of grape varieties (examples from the dataset)Şekil 2. Üzüm çeşitlerine ait etiketli görüntü örnekleri
Figure 2. Labeled image examples of grape varieties



Şekil 3. Sınıflandırma doğruluk oranı grafiği
Figure 3. Classification accuracy rate graph

Şekil 3'te 5 sınıf için oluşturulan eğitim işlemi grafiği incelendiğinde, 42 epoch sayısı, iterasyon başına 6 epoch olacak şekilde 252 iterasyon, 0.1 öğrenme oranı ile gerçekleştiği görülmektedir. Çalışma sonucunda %96,10 başarı oranı elde edilmiştir. Grafikte görüldüğü üzere eğitim doğruluğu iterasyonları ve eğitim kaybı iterasyonları arasındaki ilişki, modelin çeşitleri ezberlemek yerine kararlı bir şekilde öğrenmeyi sağlayarak eğitim kaybı fonksiyonunu en aza indirip en yüksek başarı oranını elde etmeye çalışmıştır. Çizelge 3'te ise oluşturulan sınıflandırma modelinin performansını gösteren ve çalışmada hedeflenen tahmin sınıflarının ve gerçek sınıfların değerlerinin karşılaştırılmasının yapıldığı karışıklık matrisi verilmiştir.

Çizelge 3'te karışıklık matrisi incelendiğinde oluşturulan model doğrulama veri setinde Corint üzüm çeşidi için 54 adet görüntüden 1 tanesini yanlış tahmin etmiş 53 adet görüntüyü doğru tahmin etmiştir. Merlot ve Tayfi üzüm çeşitlerinde 46 adet doğrulama görüntüsünün tamamını doğru tahmin etmiştir. Michele palieri üzüm çeşidinde 44 adet doğrulama görüntüsünün tamamını doğru tahmin etmiştir. Narince üzüm çeşidinde ise 41 adet görüntüden 8 tanesini yanlış tahmin ederken 33 tanesini doğru tahmin etmiştir. Genel toplamda ise 231 test görüntüsünden 222 görüntü doğru tahmin edilerek %96,10 sınıflandırma başarı oranı elde edilmiştir. Çizelge 4'te CNN modelinin başarısının değerlendirildiği Accuracy, Precision, Recall ve F1 Score değerleri gösterilmektedir.

Yapılan çalışmada, derin öğrenme teknikleri ile bazı üzüm çeşitlerinin sınıflandırılması için geliştirilen modelden elde edilen sonuçlar bu alanda yapılmış bazı çalışmalar ile karşılaştırıldığında geliştirilen modelin sınıflandırma performansının başarılı olduğu sonucuna varılmıştır. Çizelge 5'te gösterilen literatür çalışmalarının

bazılarında hazır veri setleri, bazılarında ise kendi veri setleri ile ön eğitilmiş modeller kullanılmıştır. Bu çalışmada ise belirtilen alanlardan deneysel olarak elde edilmiş veri setinden yeni oluşturulan derin öğrenme modeli ile başarılı sonuçlar alınmıştır. Çizelge 5'te yeni geliştirilen CNN modeli ve bu alanda yapılmış literatürdeki bulunan çalışmalarda yararlanılan, veri seti kaynağı, kullanılan veri, model, sınıf sayısı, görüntü sayısı ve doğruluk başarı oranları karşılaştırılarak gösterilmektedir.

Çizelge 5'te karşılaştırmalı olarak verilen başarı oranı değerleri derin öğrenme modelleri ile yapılmış olan bazı çalışmalardan oluşmaktadır. Çalışmalara baktığımızda derin öğrenme modellerinden SCRNN, VGG16, Faster R-CNN, ResNet, AlexNet, DenseNet, GoogleNet'in kullanıldığı ve oldukça başarılı sonuçlar verdiği görülmektedir. Çalışmalarda en düşük başarı oranı %90 ve en yüksek başarı oranı ise %96'dır. Bu durum, derin öğrenme tekniklerinin tarımda kullanımının başarılı olduğunu göstermektedir. 5 sınıf ve 1028 görüntünün kullanıldığı bu çalışma için geliştirilen yeni CNN modelinin başarı oranı ise %96,10 olarak bulunmuştur. Önerilen model, literatürdeki bazı benzer yöntemlerden daha iyi sonuçlar vermiştir. Diğer çalışmalarla karşılaştırıldığında, yeni modelin de oldukça başarılı olduğunu ve üzüm çeşitlerinin sınıflandırılmasında kullanılabilirliğini ortaya çıkarmıştır.

Sonuç

Gelişen teknolojiyle birlikte tarımsal alanda; bitki hastalıkları, zararlılarla mücadele, yabancı ot tespiti, bitki çeşitlerinin tespiti, sınıflandırma vs. gibi birçok işlemin hızlı ve otomatik olarak gerçekleştirilmesi için yapay zekâ tabanlı derin öğrenme teknikleri yoğun olarak

kullanılmaya başlanmıştır. Bu çalışmada, Corint, Merlot, Tayfi, Narince ve Michele palieri üzüm çeşitlerinin salkım ve meyve görüntüleri kullanılarak sınıflandırılması yapılmıştır. Çalışmada 5 sınıf oluşturulmuş ve 1028 adet görüntü veri seti olarak kullanılmıştır. Sınıflandırmanın yapılabilmesi için derin öğrenme tabanlı ve 15 katmandan oluşan bir CNN modeli kullanılmıştır. Kullanılan model ile sınıflandırma başarımları %96,10 olarak elde edilmiştir. Üzüm çeşitlerinin sınıflandırılması için geliştirilen bu modelin sonucuna bakıldığında ve literatürdeki diğer benzer çalışmalarla karşılaştırıldığında modelin başarılı sonuçlar verdiği görülmektedir. Modelin daha fazla geliştirilerek daha çok veri seti ile daha iyi sonuçlar vermesi için çalışmalar yapılması hedeflenmektedir. Böylece ilerleyen dönemlerde geliştirilecek sistemlerle gerçek zamanlı olarak çeşitlerin belirlenmesi sağlanabilecektir. Gelecekteki çalışmada, üzüm çeşit 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* 2018; (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. *Turkish Journal of Electrical Engineering and Computer Sciences*: Vol. 27: No. 6, Article 13. <https://doi.org/10.3906/elk-1903-112>
- Ağaoğlu YS. 1999. Bilimsel ve uygulamalı bağcılık. *Cilt-I Asma Biyolojisi*. Kavaklıdere Eğitim Yay. No.1, 205 s
- Alleweldt G. 1997. Genetics of grapevine breeding. *Progress in Botany*, 58:441-454
- Altas Z, Ozguven MM, Yanar Y. 2018. Determination of sugar beet leaf spot disease level (*Cercospora beticola* sacc.) with image processing technique by using drone. *Current Investigations in Agriculture and Current Research*, 5(3):621-631
- Altuntaş Y, Kocamaz AF, Yeroğlu C. 2019. Identification of apricot varieties using leaf characteristics and KNN classifier. In: 2019 International Artificial Intelligence and Data Processing Symposium (IDAP), pp 1-6
- Anonymous 1997. Descriptors for grapevine (*Vitis* spp.). International Plant Genetic Resources Institute, ISBN 92-9043-352-3
- Atik İ. 2022. Derin öğrenme yöntemlerini kullanarak bitki yaprağındaki hastalıkların sınıflandırılması. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 25(2):126-137
- Bengio Y, Courville A, Vincent P. 2013. Representation learning: a review and new perspectives, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35, no. 8, pp 1798-1828
- Çelik H, Ağaoğlu YS, Fidan Y, Maraslı B, Söylemezoğlu G. 1998. Genel bağcılık. *Sun Fidan Mesleki Kitaplar Serisi-1*, 253 s
- Çelik H, Karanis C. 1998. Amasya'da yetiştirilen bazı üzüm çeşitlerinin ampelografik özelliklerinin saptanması üzerine bir araştırma. 4. Bağcılık Sempozyumu, 357-361, Yalova.
- Deng L, Yu D. 2014. Deep learning: methods and applications. *Found. Trends Signal Process*, vol. 7, no.3-4, pp 197-387, 2014
- Diaz YP, Tomczak JM, Bhulai S. 2021. Deep learning for white cabbage seedling prediction. *Computers and Electronics in Agriculture*, Volume 184. doi.org/10.1016/j.compag.2021.106059
- Divakar S, Bhattacharjee A, Priyadarshini R. 2021. Smote-DL: a deep learning-based plant disease detection method. 2021 6th International Conference for Convergence in Technology (I2CT), IEEE. doi: 10.1109/I2CT51068.2021.9417920
- FAO, 2021. Food and Agriculture Organization of the United Nations. <http://www.fao.org/faostat/en/#home> (Erişim Tarihi: 29.10.2022)
- Karabat S. 2014. Dünya ve Türkiye bağcılığı. *Apelasyon e-Dergi*, Ocak 2014, Sayı: 2. <http://www.apelasyon.com/Yazi/33-dunya-ve-turkiye-bagciligi>. Erişim: 22.09.2022
- Lim TK. 2013. Edible medicinal and non-medicinal plants. *Springer Science and Business Media Dordrecht*, Volume 6, Fruits, Vitaceae: 450-482 pp
- Mohameth F, Bingcai C, Sada KA. 2020. Plant disease detection with deep learning and feature extraction using plant village. *Journal of Computer and Communications*, Vol.8:10-22. doi: 10.4236/jcc.2020.86002
- Nasiri A, Omid M, Garavand AT, Jafari A. 2022. Deep learning-based precision agriculture through weed recognition in sugar beet fields. *Sustainable Computing: Informatics and Systems*. doi.org/10.1016/j.suscom.2022.100759
- Ozguven MM. 2020. Deep learning algorithms for automatic detection and classification of mildew disease in cucumber. *Fresenius Environmental Bulletin*, 29(08/2020):7081-7087
- Ozguven MM, Altas 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>
- Pınar H, Çöçen E, Yaman M, Uzun A, Sarıtepe Y. 2018. Türk Çekirdekli beyaz dutlarının (*Morus alba* L.) fenolojik ve pomolojik özellikleri. *Bahçe* 47 (Özel Sayı 2: Uluslararası Tarım Kongresi (UTAK 2018)):6-12
- Raei E, Asanjan AA, Nikoo MR, Sadegh M, Pourshahabi S, Aamowski JF. 2022. A deep learning image segmentation model for agriculture irrigation system classification. *Computers and Electronics in Agriculture*, Volume 198. doi.org/10.1016/j.compag.2022.106977
- Sağlam H, Sağlam Çalkan Ö. 2018. Türkiye bağcılığına tarihsel bir bakış; asma genetik kaynaklarının önemi. *Selçuk Tarım ve Gıda Bilimleri Dergisi*, 32 (3):601-606
- Song HA, Lee SY. 2013. Hierarchical representation using NMF. In *International Conference on Neural Information Processing*, 2013, pp 466-473
- Türkoğlu M, Hanbay D. 2019. Plant disease and pest detection using deep learning-based features. *Turkish Journal of Electrical Engineering and Computer Sciences*, (2019) 27: 1636-1651. doi:10.3906/elk-1809-181
- Ünal MS. 2020. Şırnak yöresel üzüm çeşitlerinin bazı özelliklerinin belirlenmesi. *ÇOMÜ Zir. Fak. Derg. (COMU J. Agric. Fac.)*, 8(2):277-287. doi: 10.33202/comuagri.740162
- Yamamoto K, Togami T, Yamaguchi N. 2017. Super-resolution of plant disease images for the acceleration of image-based phenotyping and vigor diagnosis in agriculture. *Sensors*, 17 (11):2557. doi.org/10.3390/s17112557
- Xia EQ, Deng GF, Guo YJ, Li HB. 2010. Biological activities of polyphenols from grapes. *International Journal of Molecular Science*, pp 622-646