



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME TEKNİKLERİ İLE ÜZÜM ÇEŞİTLERİNİN
BELİRLENMESİ**

DOKTORA TEZİ

İsmail TERZİ

Birinci Danışman: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Doç. Dr. Adem YAĞCI

TOKAT- 2023

JÜRİ KABUL VE ONAY

İsmail TERZİ tarafından hazırlanan “**Derin Öğrenme Teknikleri ile Üzüm Çeşitlerinin Belirlenmesi**” adlı tez çalışmasının savunma sınavı **21/12/2022** tarihinde yapılmış olup aşağıda verilen Jüri tarafından **Oy Birliği** ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü **Biyosistem Mühendisliği Anabilim Dalı**’nda **Doktora Tezi** olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan)	Prof. Dr. Engin ÖZGÖZ	
Üye (Danışman)	Doç. Dr. Mehmet Metin ÖZGÜVEN	
Üye	Doç. Dr. Kemal ADEM	
Üye	Dr. Öğr. Üyesi Seda SUCU	
Üye	Dr. Öğr. Üyesi Serhat KILIÇARSLAN	

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

Prof. Dr. Mehmet GÜNEŞ

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Mehmet Metin ÖZGÜVEN danışmanlığında hazırlamış olduğum “Derin Öğrenme Teknikleri İle Üzüm Çeşitlerinin Belirlenmesi” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

21/12/2022

İsmail TERZİ

TEŞEKKÜR

Doktora çalışmam boyunca beni destekleyen ve önerilerde bulunan hem hayata dair hem de akademik bilgilerini benimle paylaşan, hiçbir konuda yardımlarını esirgemeyen, azmini, gayretini ve sabrını örnek aldığım, danışmanım değerli hocam Sayın Doç. Dr. Mehmet Metin ÖZGÜVEN'e, veri kümesini oluşturma dönemlerinde katkılarını esirgemeyen ikinci danışmanım Sayın Doç. Dr. Adem YAĞCI hocama, yapay zeka ve derin öğrenme uygulamaları alanında önemli bilgiler aldığım, tez izleme komitesi üyesi Sayın Doç. Dr. Kemal ADEM hocama, tez izleme komitesi üyesi Sayın Prof. Dr. Engin ÖZGÖZ hocama, tez sınav jürileri Sayın Dr. Öğr. Üyesi Seda SUCU ve Sayın Dr. Öğr. Üyesi Serhat KILIÇARSLAN hocalarıma, hayatımın her evresinde desteğini gördüğüm gerek saha çalışmalarında gerekse tez yazım kurallarının düzenlenmesinde bana yardım eden sevgili eşim Dilek TERZİ' ye, doktora eğitimine birlikte başladığımız ve zorlukların üstesinden birlikte geldiğimiz ve her durumda birbirimize destek olduğumuz, doktora sürecimin neredeyse her anını paylaştığım ve çok desteğini gördüğüm, müteşekkirdiğim, azimli, gayretli, bilgili, başarılı ve kalbi güzel insan değerli arkadaşım Ziya ALTAŞ'a, saha çalışmalarında desteğini gördüğüm Sayın Deniz TERZİ' ye, varlıklarıyla mutlu olduğum sevgili kızım Bilge'ye ve oğlum Onur'a yine hayatımın her alanında her türlü desteklerini gördüğüm anneme, babama, kayınvalideme ve kardeşlerime sonsuz sevgi ve teşekkürlerimi sunuyorum.

İsmail TERZİ

21/12/2022

ÖZET

DERİN ÖĞRENME TEKNİKLERİ İLE ÜZÜM ÇEŞİTLERİNİN BELİRLENMESİ

İsmail TERZİ

Tokat Gaziosmanpaşa Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyosistem Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Doç. Dr. Adem YAĞCI

Aralık 2022, xi + 82 sayfa

Bağcılıkta üzüm çeşitlerinin belirlenmesinde, çeşitlerin sürgününe, yaprağına, salkımına ve meyvesine ait ampelografik özellikler kullanılmaktadır. Ampelografik özellikler tespit edildikten sonra sayısal veya sözel olarak ifade edilmektedir. Bu çalışmada, elli adet üzüm çeşidinin yaprak, salkım ve meyvelerine ait ampelografik özellikleri kullanılarak derin öğrenme teknikleriyle sınıflandırılması yapılmıştır. Çalışmada, yeni ve özgün olarak geliştirilen CNN modeli önerilmiştir. Önerilen CNN modeli, 227x227x3 boyutunda, 9 854 yaprak, 8 745 salkım ve 8 721 meyve olmak üzere toplam 27 320 veri seti görüntüsü kullanılarak MATLAB 2021a platformu üzerinde geliştirilmiştir. Veri setinin %80'i eğitime %20'si ise doğrulamaya ayrılmıştır. Sınıflandırma, yaprak ve salkım/meyve görüntüleriyle iki aşamada gerçekleştirilmiştir. Üzüm çeşitlerinin özelliklerinin birbirlerine çok benzerlik göstermesinden dolayı, modelde ezberlemenin önüne geçilebilmesi için sınıflandırma da yaprak grubunda beş farklı, salkım/meyve grubunda ise dört farklı kategori olmak üzere toplam dokuz farklı kategori oluşturulmuştur. Yaprak görüntülerinin olduğu beş farklı kategorinin her birinde on sınıf bulunurken, salkım/meyve görüntülerinin olduğu dört farklı kategorinin her birinde on bir sınıf bulunmaktadır. Her bir kategorinin Doğruluk, Hassasiyet, Duyarlılık ve F1 Skoru değerleri ayrı ayrı hesaplanarak model performansı belirlenmiştir. Ayrıca önerilen model performansının karşılaştırılması için GoogleNet ve AlexNet modelleri de oluşturulan veri seti ile eğitilmiştir. Yeni model için yaprak grubunda doğruluk başarı oranları; kategori 1 için %82.50, kategori 2 için %90.03, kategori 3 için %87.44, kategori 4 için %94.10 ve kategori 5 için %92.40 olarak hesaplanmıştır. Salkım/meyve grubunda ise doğruluk başarı oranları; kategori 1 için %85.88, kategori 2 için %84.90, kategori 3 için %96.40 ve kategori 4 için %97.20 olarak hesaplanmıştır. GoogleNet modelinde başarı oranı %84.39, AlexNet modelinde ise %92.31 bulunmuştur. Çalışma sonucunda üç model arasında en yüksek başarı oranı, salkım/meyve grubundaki kategori 4'te %97.20, en düşük başarı oranı ise yaprak grubundaki kategori 1'de %82.50 doğrulukla yeni model ile hesaplanmıştır. Elde edilen bu sonuçlara bakıldığında, modellerin üzüm çeşitlerinin sınıflandırılmasında başarılı bir şekilde çalıştığı, üzüm çeşitlerinin ampelografik özelliklerini öğrenebildiği ve bu alanda yapılacak çalışmalarda kullanılabileceği ortaya çıkarılmıştır.

Anahtar Kelimeler: Derin öğrenme, CNN, GoogleNet, AlexNet, Üzüm, Ampelografi

ABSTRACT

DETERMINATION OF GRAPE VARIETIES WITH DEEP LEARNING TECHNIQUES

İsmail TERZİ

Tokat Gaziosmanpasa University

Graduate School of Education

Biosystems Engineering Department

Thesis Advisor: Assoc. Prof. Dr. Mehmet Metin ÖZGÜVEN

Second Advisor: Assoc. Prof. Dr. Adem YAĞCI

December 2022, xi + 82 pages

In viticulture, the ampelographic characteristics of the shoot, leaf, inflorescence and fruit of the varieties are used to determine the grape varieties. After the ampelographic features are determined, they are expressed numerically or verbally. In this study, classification of fifty grape cultivars with deep learning techniques was done by using ampelographic features of leaves, bunch and fruits. In the study, a new and originally developed CNN model is proposed. The proposed CNN model was developed on the MATLAB 2021a platform, using a total of 27 320 dataset images, 227x227x3 in size, 9 854 leaves, 8 745 bunch and 8 721 fruits. 80% of the data set is reserved for training and 20% for validation. Classification was carried out in two stages with leaf and bunch /fruit images. Since the characteristics of grape varieties are very similar to each other, in order to avoid memorization in the model, a total of nine different categories were created, five different categories in the leaf group and four different categories in the bunch /fruit group. There are ten classes in each of the five different categories with leaf images, and eleven classes in each of the four different categories with bunch /fruit images. Model performance was determined by calculating the Accuracy, Sensitivity, Sensitivity and F1 Score values of each category separately. In addition, GoogleNet and AlexNet models were also trained with the newly created dataset to compare the proposed model performance. Accuracy success rates in the leaf group for the new model; 82.50% for category 1, 90.03% for category 2, 87.44% for category 3, 94.10% for category 4 and 92.40% for category 5. Accuracy and success rates in the bunch /fruit group; 85.88% for category 1, 84.90% for category 2, 96.40% for category 3 and 97.20% for category 4. The success rate was 84.39% in the GoogleNet model and 92.31% in the AlexNet model. As a result of the study, the highest success rate among the three models was calculated with 97.20% in category 4 in the bunch/fruit group, and the lowest success rate in category 1 in the leaf group was calculated with the new model with an accuracy of 82.50%. When these results are examined, it has been revealed that the models work successfully in the classification of grape varieties, can learn the ampelographic properties of grape varieties and can be used in studies in this field.

Keywords: Deep learning, CNN, GoogleNet, AlexNet, Classification, Grape, Ampelography

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME.....	i
TEŞEKKÜR.....	ii
ÖZET	iii
ABSTRACT.....	iv
İÇİNDEKİLER	v
ŞEKİLLER LİSTESİ	vii
ÇİZELGELER LİSTESİ.....	ix
KISALTMALAR.....	x
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ	17
2.1. Derin Öğrenme Literatürleri	17
2.2. Ampelografik Özelliklerle İlgili Literatürler	22
3. MATERYAL ve YÖNTEM	27
3.1. Materyal	27
3.1.1. Çalışmaların yapıldığı bağ alanları	27
3.1.2. Çalışmada kullanılan teknik cihazlar	34
3.1.3. Çalışmada kullanılan yazılım programı	39
3.2. Yöntem	36
3.2.1. Veri toplama.....	43
3.2.2. Veri kümesi oluşturma	43
3.2.3. Veri seti oluşturma	45
3.2.4. Etiketleme işlemleri	48
3.2.5. Karar verme.....	50
4. BULGULAR ve TARTIŞMA	54
4.1. Bulgular.....	54
4.1.1. Yaprak görüntülerine ait bulgular	54
4.1.2. Salkım/Meyve görüntülerine ait bulgular	62
4.1.3. GoogleNet ve AlexNet modellerine ait bulgular	68
4.2. Tartışma.....	72

5. SONUÇ ve ÖNERİLER	74
5.1. Sonuç.....	74
5.2. Öneriler	75
5.3. Çalışmanın sınırlılıkları.....	76
6. KAYNAKLAR	77
7. ÖZGEÇMİŞ	82



ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki süreç	7
Şekil 2. Derin öğrenme sinir ağı	7
Şekil 3. CNN modeli genel yapısı	9
Şekil 4. 5x5x3 boyutlu giriş görüntüsü üzerinde 3x3 filtrenin uygulandığı konvolüsyon işlemi	11
Şekil 5. ReLu katmanının çıkış verisine etkisi	12
Şekil 6. 2x2 filtre ile havuzlama işleminin uygulanması.....	13
Şekil 7. Tam bağlantılı katman genel yapısı.....	13
Şekil 8. AlexNet ağ mimarisi.....	15
Şekil 9. GoogleNet ağ mimarisi.....	15
Şekil 10. Görüntülerin alındığı bağ alanlarına ait uydu fotoğrafları.....	29
Şekil 11. Görüntülerin alındığı bağ alanlarına ait arazi görüntüleri	30
Şekil 12. Üzüm çeşitlerinin sırasıyla; çiçek, sürgün, genç yaprak, olgun yaprak, salkım meyve ve odunsu sürgün özelliklerine ait birer adet görüntüleri	31
Şekil 13. Üzüm çeşitlerine ait yaprak görüntüleri (Yaprak veri seti materyali)	32
Şekil 14. Üzüm çeşitlerine ait salkım-meyve görüntüleri (Salkım-meyve veri seti materyali)	33
Şekil 15. Görüntülerin alındığı GoPro Hero 7 Black Model kamera	34
Şekil 16. Ampelografik özelliklerin bazı görselleri.....	42
Şekil 17. Crimson seedlees ve Royal çeşitlerinin yaprak ve salkım/meyve etiketli görüntüleri	49
Şekil 18. Yeni ve özgün olarak geliştirilen CNN modelinin genel mimari yapısı	50
Şekil 19. Yaprak kategori 1 eğitim akış diyagramı	55
Şekil 20. Yaprak kategori 2 eğitim akış diyagramı	56
Şekil 21. Yaprak kategori 3 eğitim akış diyagramı	58
Şekil 22. Yaprak kategori 4 eğitim akış diyagramı	59
Şekil 23. Yaprak kategori 5 eğitim akış diyagramı	61
Şekil 24. Salkım/meyve kategori 1 eğitim akış diyagramı	62
Şekil 25. Salkım/meyve kategori 2 eğitim akış diyagramı	64

Şekil 26. Salkım/meyve kategori 3 eğitim akış diyagramı	65
Şekil 27. Salkım/meyve kategori 4 eğitim akış diyagramı	67
Şekil 28. GoogleNet modeline ait eğitim akış diyagramı	68
Şekil 29. AlexNet modeline ait eğitim akış diyagramı	70



ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1. Görüntülerin alındığı tarihler ve bağ alanları	28
Çizelge 2. Ampelografik özellikler	38
Çizelge 3. Üzüm çeşitlerinden alınan görüntü sayısı (Veri kümesi)	43
Çizelge 4. Üzüm çeşitlerinin yaprak ve salkım/meyve ampelografik özellikleri	46
Çizelge 5. Etiketleme yöntemi	48
Çizelge 6. Yaprak kategori 1 karışıklık matrisi ve performans değerleri	55
Çizelge 7. Yaprak kategori 2 karışıklık matrisi ve performans değerleri	57
Çizelge 8. Yaprak kategori 3 karışıklık matrisi ve performans değerleri	58
Çizelge 9. Yaprak kategori 4 karışıklık matrisi ve performans değerleri	60
Çizelge 10. Yaprak kategori 5 karışıklık matrisi ve performans değerleri	61
Çizelge 11. Salkım/meyve kategori 1 karışıklık matrisi ve performans değerleri	63
Çizelge 12. Salkım/meyve kategori 2 karışıklık matrisi ve performans değerleri	64
Çizelge 13. Salkım/meyve kategori 3 karışıklık matrisi ve performans değerleri	66
Çizelge 14. Salkım/meyve kategori 4 karışıklık matrisi ve performans değerleri	67
Çizelge 15. GoogleNet karışıklık matrisi ve performans değerleri	69
Çizelge 16. AlexNet karışıklık matrisi ve performans değerleri	70
Çizelge 17. Yeni model, GoogleNet ve AlexNet modellerinin performans değerleri	71
Çizelge 18. Yeni modelin diğer modellerle karşılaştırılması	73

KISALTMALAR

<u>Kısaltma</u>	<u>Açıklama</u>
mp	: Mega Piksel
ResNet	: Residual Network
VGG	: Görsel Geometri Grup (Visual Geometry Group)
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Network)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
DN	: Doğru Negatif
DP	: Doğru Pozitif
DŞ	: Diş Şekli
ESA	: Evrişimli Sinir Ağları
FAO	: Gıda ve Tarım Örgütü (Food and Agriculture Organization)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
IPGRI	: Uluslararası Bitki Gen Kaynakları Enstitüsü (The International Plant Genetic Resources Institute)
KNN	: K- en Yakın Komşu (K-Nearest Neighbors)
LVQ	: Vektör Nicelemesini Öğrenme (Learnind Vector Quantization)
MLR	: Makine Öğrenimi Havuzu (Machine Learning Repository)
MŞ	: Meyve Şekli
OIV	: Uluslararası Bağcılık ve Şarapçılık Ofisi (Office International de la Vigne et du Vin)
R-CNN	: Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağları (Region Based Convolutional Neural Networks)
SSD	: Tek çekim çoklu kutu dedektörü (Single shot multi box detector)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
SY	: Salkım Yoğunluğu
TARBİL	: Tarımsal İzleme ve Bilgi Sistemi
UCI	: Makine Öğrenimi Deposu
UPOV	: Uluslararası Yeni Bitki Çeşitlerinin Korunması Birliği (International Union for the Protection of New Varieties of Plants)
YN	: Yanlış Negatif

YP	: Yanlıř Pozitif
YSA	: Yapay Sinir Ađları
HD	: High Definition (Yüksek Çözünürlük)
PPI	: Pixels Per Inch (Piksel hassasiyeti)
FPS	: Frame Per Seconds (Saniyelik kare sayısı)
GHz	: GigaHertz



1. GİRİŞ

İnsanlığın yaşamını devam ettirebilmesi açısından gerekli, zorunlu ve temel gıda ihtiyaçlarının elde edildiği en önemli üretim sektörü tarımdır. Bitkisel ve hayvansal faaliyetlerden meydana gelen tarımsal üretim; sağlıklı ve dengeli beslenmek, ülke gelirini artırmak ve iş ortamı sağlamak, tarımsal üretime dayalı sanayiye hammadde sağlamak, ülke kalkınmasına katkıda bulunmak ve ihracat yoluyla döviz gelirlerini artırmak açısından sosyal ve ekonomik etkiye sahiptir. Tarım sektörü, küresel piyasalardaki dalgalanmalardan, ekonomik krizlerden, iklim değişikliğine ve kuraklığa sebep olan küresel ısınmadan, hayvansal hastalıklardan, tarımsal ürünlerin biyoyakıt üretimi gibi gıda üretimi dışında kullanımından, tarım arazilerinin çok parçalı olmasından ve eğitimsizlik gibi olumsuz durumlardan etkilenmektedir. Bunların dışında dünyadaki nüfusun hızlı ve sürekli artmasıyla birlikte kentleşmenin çoğalması sebebiyle tarımsal üretim alanları ve su gibi önemli yaşamsal etkiye sahip olan doğal kaynaklarda azalma görülmektedir (Özgüven, 2018).

Bu azalmanın yanı sıra ülkemizde tarımsal alanların büyük bir kısmını oluşturan tarımsal faaliyetlerin yürütüldüğü küçük işletmelerde, teknoloji ve bilgi-bilişim kullanımının da kısıtlı olduğu görülmektedir. Türkiye’de tarımsal faaliyetlerin çoğunluğu, iktisat teorilerini umursamayan bir düşünceyle yoluna devam etmektedir. Tarım sektörünün en önemli sorunlarından biri olarak görülen yeterli olmayan bilgi ve teknoloji kullanımı, sektörün ekonomiye katma değerinin de düşük olmasının nedenidir. Tarım sektörünü geri plana atarak kalkınmanın sağlanması mümkün olamamaktadır. Tarımı bir endüstri dalı gibi düşünen ve buna bağlı iktisadi fenomenleri bünyesinde taşıyan bir görüşün hakim olması zorunluluk haline gelmiştir. Tarımdaki nüfusun sosyal imkanlarının çoğaltılması ve bilgi-bilişim kullanımının yaygınlaştırılması tarımsal üretimin geliştirilmesi ve geleceği açısından öncelikli konular olarak ele alınmalıdır (Karkacier ve Karabaş, 2016).

Türkiye’de sermaye birikiminin ve teknoloji kullanımının yetersiz olması pek çok olumsuzluğa neden olmaktadır. Bütün sektörler içinde, özellikle de tarım sektöründe teknoloji kullanımı ve eğitim düzeyinin istenilen seviyede olmaması, bazı olumsuzlukların temel nedenidir. Tarım sektörü, başka sektörlerle de girdi veren, sanayiye destekleyen önemli bir sektördür. Tarım sektörünün acil müdahale planı olarak, yeni tarım teknolojileriyle birleştirilmesi önemli görülmektedir. Tarımsal üretimi gelenekselci

bir üretim görüşünden, modern anlayışa doğru kaydırmak, ilk olarak sektördeki aktörlerin bu konudaki bakış açısını değişime yönlendirmekle olacaktır. Diğer taraftan, üretimin önemli fonksiyonundan birisi olan “planlama” konusunda hem politika yapıcılarının hem de tarımsal üretim bölümlerinin üretim planlarını etkinleştirmesi sağlanmalıdır. Bunu yapmak, tarımsal üretimin yapısı açısından zor da olsa çiftçilerin az maliyetli bilgi sistemlerine adapte edilmesiyle, tedarikten lojistiğe kadar tüm süreçlerde rekabet edilebilen duruma dönüşmeleri sağlanabilmektedir (Karabaş ve Tekmen, 2019).

Tarımsal üretimin gelişme dönemi boyunca mekanizasyon, otomasyon, kontrol ve bilişimden sonra bilgi teknolojilerinde görülen hızlı gelişim sonucu günümüzde akıllı makineler ve makineleri kontrol eden üretim sistemlerinin geleneksel üretim yöntemlerinin yerini almaya başlaması önem arz etmektedir. Tarımda mevcut bilgi ve tecrübelerin, bilgi teknolojilerinin sunduğu makine öğrenmesi, derin öğrenme, yapay zeka, modelleme ve simülasyon uygulamaları ile birlikte değerlendirilmesi sonucu gerçek zamanlı ve otomatik çalışan uzman sistemler, otonom traktör veya tarım makinaları ve tarımsal robotik uygulamaların geliştirilmesini sağlamıştır (Ozguven, 2018).

Bilgi teknolojileri; bilginin üretilmesi/edinilmesi, işlenmesi/değerlendirilmesi, depolanması, aktarılması ve kullanılmasını kapsayan geniş bir konu dağılımına sahiptir. Bilgi işleme ve kullanma süreçlerine ilişkin birçok araç ve gereç halihazırda geliştirilmiş olup piyasada mevcuttur. Bu araçların en önemlilerinden bazıları sensörler, mikroişlemciler, bilgisayarlar, uydular ve yazılımlardır (Tarhan ve Özgüven, 2015).

Tarımsal üretimdeki ekonomikliğin, sürdürülebilirliğin ve işletmelerdeki üretkenliğin sağlanması, tarımsal üretimdeki ilk hedeflerdendir. Bu sebeple; verim ve kalitenin artırılması, maliyetin düşürülmesi, güvenli gıda arzı, doğal kaynaklara zarar verilmemesi ve çevre kirliliğinin azaltılması gibi durumlarda bilgi teknolojilerinin kullanılması ile tarım sektöründeki işlerin daha kolay yapılması için alternatif çözümler ortaya konulmaktadır. Yakın gelecekte 5G teknolojisinin uygulamaya girmesiyle tüm kırsal alanlarda dahil her yerde internete ulaşım imkanı ortaya çıkacaktır. Bu sayede bilgi teknolojileri ve tarımsal üretimdeki hızlı gelişimle birlikte geleneksel üretimin yerine, robotlar, otonom ve akıllı drone’lar, kontrol edilebilen sistemler kullanılmaya başlanacaktır (Ozguven, 2018; Özgüven ve ark., 2022).

Tarımsal üretim alanında büyük yer kaplayan ve ülkeler ekonomisine çok katkısı olan önemli bir tarımsal faaliyet ise bağcılıktır. Bağcılıkta yetiştirilen asma (*Vitis vinifera* L.) *Vitaceae* ailesi üyelerinden olup, yürütülen arkeolojik çalışmalarla elde edilen bulgulara göre geçmişi 150 milyon yıl öncesine kadar uzandığı kabul edilen, iklim şartları ve toprak özellikleri bakımından uyum yeteneği yüksek olması sebebiyle dünyanın farklı bölgelerinde yetiştirilebilen, dünyada yaklaşık 13 000 kadar çeşidi bulunan, insanlık tarihinin en eski bitkilerindendir (Alleweldt, 1997; Türkben, 2010; Semerci ve ark., 2015). Üzüm, doğu ve batı medeniyetlerinin sosyal ve ekonomik oluşumunda önemli yeri olan, dünyada yetiştiriciliği yapılan ve çok eski dönemlerde kültüre alınan gerek taze gerekse kurutulularak geniş bir tüketim alanı bulunan, içerisindeki vitamin, protein, mineral madde ve antosiyaninlerin bol olması ve yaprağının da gıda olarak kullanılması sebebiyle insanların beslenme ihtiyacını karşılamada da önemli bir paya sahip olan bitki çeşitlerindendir (Çelik ve ark., 1998; Ağaoğlu 1999; Xia ve ark., 2010; Lim, 2013; Yağcı ve ark., 2018).

Bağcılık, uygun iklim şartları olarak Türkiye'nin de içinde yer aldığı dünyanın 34°- 49° kuzey ve güney enlemleri arasında yapılan tarımsal bir faaliyettir. Asmanın meyvesi olan üzüm ise kurutulularak ya da yaş meyve olarak dünya genelinde tüketimi fazla olan bir gıdadır. Üzüm, taze olarak sofralık, kurutulmuş üzüm ve şaraplık üzüm olarak değerlendirilse de üzüm suyu, sirke, reçel, pekmez gibi gıda ürünlerine de dönüştürülebilmektedir. Sahip olduğu bu değerlendirme olanakları sayesinde bağcılık, tarım sektörünün ticari açıdan önemi yüksek olan faaliyetlerinden birisidir (Cangi ve ark., 2011).

Bağcılığın geliştirilmesi ve daha yüksek seviyeye çıkarılması, öncelikle sahip olunan asma gen potansiyelinin belirlenmesi, korunması ve değerlendirilmesine yönelik yapılan araştırmalara gerekli önemin verilmesiyle mümkün olacaktır. Bağcılıkta üretimdeki yoğunluktan dolayı üzümde çeşit çoğalması ortaya çıkmıştır. Çeşit çoğalması ise bu çeşitlerin özelliklerinin bilinmesini, tiplerin ayrı ayrı bir çeşit olarak değerlendirilmesini, çeşitler arasındaki farklılıkların saptanarak tescil koşullarına uygunluğunun ortaya çıkarılmasını gerektirmiştir. Bu bağlamda bu çeşitlerin belirlenmesinde ampelografik özellikler ile moleküler karakterizasyonlar kullanılmaktadır. Üzüm çeşitleri üzerinde çeşitlerin özelliklerinin daha hızlı ve doğru şekilde ortaya çıkarılması, çeşit tescili ve yetiştirme tekniğinin geliştirilmesi amacıyla, fenolojik, pomolojik ve morfolojik

tanımlamalar yapılmaktadır. Hem dünyada hem de Türkiye’de yetiştiriciliği yapılan üzümlerin büyük bir bölümünün ampelografik özellikleri ortaya çıkarılmıştır (Söylemezoğlu, 1996; Yağcı ve İlter, 2018; Altuntaş ve ark., 2019).

Asma tür ve çeşitlerinin ampelografik özelliklerinin belirlenmesi, tanımlama ve sınıflandırma bakımından önem arz ettiği kadar, herhangi bir alana en iyi uyum sağlayan üzüm çeşitlerinin belirlenmesi açısından da önem taşımaktadır. Ülkemizde bağcılığın geliştirilmesi, randıman, kalite ve çeşitlerin belirlenmesi konusunda ampelografi üzerine birçok çalışma yapılmış ve karşılaşılan problemlerin çözümüne yönelik önemli adımlar atılmıştır (Çelik ve Karanis, 1998; Sucu ve Yağcı, 2020; Ünal, 2020).

Ampelografi ismi Yunanca ampelos (asma) ve graphe (açıklama) kelimelerinin birleşiminden türemiştir. Ampelografi asma türleri ve ekili çeşitlerin tanımıyla ilgili bir bilim dalıdır. Ampelografi çalışması şarap yetiştiriciliğinde kullanılan üzümlerle birlikte kök seçme, klonal seleksiyon, sofralık üzüm yetiştirme ile diğer endüstriyel ve tarımsal uygulamalardaki kullanımları da kapsamaktadır (Dexheimer, 2011).

Üzüm çeşitlerinin ampelografik özelliklerinin belirlenmesi oldukça zahmetli ve uzun süreli olan dikkatli araştırma ve çalışmalar gerektiren bir iştir. Aynı özelliklere sahip çeşide, farklı bölgelerde farklı isimler verilebilmektedir. Bu farklılıklar, uluslararası yöntem birliği çalışmaları kullanılarak ortadan kaldırılabilir. Bunun için bir çeşidin ampelografik özelliklerinin belirlenmesi genç sürgünlerin ortaya çıkmasıyla başlayarak, çiçeklenme, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün dönemlerini kapsayacak şekilde devam etmektedir. Bu karakterlere ait bütün özellikler her bir karakterin kendi döneminde belirlenebilmektedir. Bu işlem ise ampelografik özelliklerin belirlenmesinde kapsamlı çalışmaları gerektirmektedir. Bu bakımdan bir çeşide ait ampelografik özelliklerin belirlenmesi ve elde edilmesi bağcılığın geleceği ve üzüm yetiştiriciliğinin geliştirilmesi bakımından önem arz etmektedir.

Üzümlerin ampelografik özelliklerinin belirlenmesinde uluslararası yöntem birliğini sağlamak için Uluslararası Bitki Gen Kaynakları Enstitüsü (The International Plant Genetic Resources Institute- IPGRI) 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 iş birliği içinde yapılan çalışmalarla geliştirilmiş normlar

Üzüm Tanımlayıcıları (Grape Descriptors) adıyla yayınlanmıştır. Bu normlar daha sonra yeniden ele alınıp üzerlerinde bazı değişiklikler yapılarak ve üzüm genotipleri karakterizasyonu ile akrabalık ilişkilerinin tespitinde yürütülecek çalışmalar için yüksek oranda ayırıcı özellik taşıyan unsurlar olarak belirlenmiştir. Bu yöntemle günümüzde genotip tanımlama çalışmaları için kullanılan Descriptors for Grapevine (Vitis spp.) listeleri oluşturulmuştur (Anonymous, 1997).

Üzüm Tanımlayıcıları kavramı iki tanımlama sisteminden oluşmaktadır. Bunlardan birincisi olan Tanımlama ve Ön Değerlendirme Verileri vegetatif özellikler ve bitkisel özellikler olup bunlar meyve ve çiçek özellikleri ile çekirdeklere has özelliklerin incelenmesini esas almaktadır. İkinci tanımlama sistemi İleri Tanımlama ve Değerlendirme ise bu özellikleri daha ayrıntılı incelemekte; bununla beraber yüksek ve düşük sıcaklıklara, kurağa, neme, demir klorozuna ve toprak tuzluluğuna duyarlılık, hastalık ile zararlılara dayanıklılık ve bazı sitolojik karakterleri de incelemektedir (Eren, 2012).

Ampelografik özellikler (Çizelge 2), üzüm çeşitleri arasında kolay ve hızlı bir tespit yapılmasını sağlayan tanımlayıcılardır. Ampelografik özellik olarak belirtilen tanımlayıcılar, üzüm çeşitlerinde genelde yüksek oranda kalıtsal olarak var olan ve gözle bakıldığında kolayca görülebilen ve tüm ortamlarda eşit olarak ifade edilen, çeşitlere ait karakterlerdir. Ampelografik özellikler listeleri Uluslararası Bitki Gen Kaynakları Enstitüsü tarafından oluşturulmuştur. IPGRI Uluslararası Tarımsal Araştırma ve Danışma Grubu'nun himayesi altında faaliyet gösteren ve özerk bir uluslararası bilimsel kuruluştur. IPGRI'nın uluslararası statüsü 1997'de Türkiye'nin de içinde bulunduğu kırk dokuz ülke tarafından kabul edilmiştir. IPGRI araştırma, eğitim, bilimsel, teknik tavsiye ve bilgi sağlanması gibi birçok konuda diğer kuruluşlarla ortak olarak çalışır ve Birleşmiş Milletler Gıda ve Tarım Örgütü ile güçlü bir program bağlantısı bulunmaktadır (Anonymous, 1997).

Üzüm, dünya genelinde çeşit bakımından çok zengin olan bir bitki türü olduğundan dolayı üzüm yetiştiriciliği alanında çeşitlerin hızlı ve kolay tespit edilmesi hem tarım sektörüne hem de bağcılığa büyük katkılar sağlamaktadır. Çeşit bakımından oldukça zengin olan üzüm çeşitlerinin tespitinde ve sınıflandırılmasında meydana gelen karışıklığın ortadan kaldırılması, bağcılıkta üretim ve kalitenin geliştirilmesi açısından

önemli bir durumdur (Pınar ve ark., 2018). Bu tür karışıklıkların ortadan kaldırılması amacıyla özellikle tarımsal üretiminin yapıldığı büyük alanlarda insan kaynaklı hataları minimuma indiregeyebilen daha hızlı ve pratik çalışabilen teknolojik sistemlere ihtiyaç duyulmaktadır (Altas ve ark., 2018).

Çağımızın en hızlı ve pratik teknolojilerinden olan derin öğrenme teknolojileri, tarımsal üretim işlemlerinin kolaylaştırılmasında, çözüm ve iyileştirme bekleyen problemlere alternatif çözümler getirme potansiyelinden dolayı bulunduğumuz çağda ve yakın gelecekte en önemli tarımsal araştırma alanlarında yer alması beklenmektedir. Tarımsal alanda derin öğrenme teknolojileri ve kavramları kullanılarak üretim planlamaları, otomatik tespit ve bitkisel sınıflandırma, ürün kaybı tespiti, verim tahmini, bitki hastalıkları ve hastalıkların erken teşhisi, zararlılar ve yabancı ot tespiti, işletme kararlarının hatasız alınması gibi tarımda birçok alanda araştırmacılar tarafından çalışmalar yapılmaktadır (Ozguven ve Adem, 2019; Özgüven, 2019; Terzi ve ark., 2019; Adem ve ark., 2022; Kılıçarslan, 2022; Ozguven ve Yanar, 2022).


Derin öğrenme uygulamalarında bilgiyi iç içe geçmiş bir kavramlar hiyerarşisi olarak temsil etmeyi öğrenen, geleneksel yöntemlerle ortaya çıkarılan özelliklerin yerine veriyi en üst düzeyde temsil eden ve özelliklerin ortaya çıkarılmasında etkin olan algoritmalar kullanılmaktadır. Geri yayılım algoritmaları ile çok boyutlu veri setlerinin karmaşık yapılarını çözen derin öğrenme; bu işlemi, katmanlarda hesaplanan parametrelerin değerlerinin bir önceki katman değerleri ile karşılaştırıp değişikliğin nasıl yapılması gerektiğine karar vererek gerçekleştirmektedir. Derin öğrenme yapay sinir ağı algoritmalarını kullanarak çok katmanlı olan mimarilerde çok boyutlu verilerle çalışma olanağı sunan makine öğrenmesi alt dalıdır. Derin öğrenme yöntemleri ile doğal dil işleme, görüntü işleme, görsel nesne tespitinde, ilaç keşfi vb. uygulamalarda yapılan çalışmalarla çok yüksek seviyelerde başarılar elde edilmiştir (Deng ve Yu, 2014; LeCun ve ark., 2015; Lee ve ark., 2015; Aktaş, 2020).

Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki süreç Şekil 1’de gösterilmektedir.



Şekil 1. Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki süreç (Kayaalp ve Süzen, 2018)

Makine öğrenmesinde hedef, daha önce hiç görünmeyen bir girdi için doğru tahminler yapılması veya karar verilmesi ve bu tahmin ve karar verme süreçlerini otomatikleştiren verimli algoritmaların geliştirilmesidir. Algoritmalar geliştirilirken kuralların oluşturulması sırasında, bir uzmanın bir kararı alırken nelere dikkat etmesi gerektiğine dair kriterler dikkate alınmalıdır. Makine öğrenmesi yöntemlerinin uygulanmasında hesaplama karmaşıklığı, eğitim karmaşıklığı ve eğitilmiş algoritma uygulaması karmaşıklığı gibi karmaşıklıklar bulunabilmektedir. Bir algoritmanın performansı test hatasına göre değerlendirilmektedir. Ayrıca bir algoritma çalışırken çok sayıda test noktası bulunabilmekte ve bu noktalarda hızlı karar alınması istenmektedir. Bu nedenle test işleminin düşük hesaplama yüküne sahip olması gerekir (Ozguven, 2023). Giriş verisi olarak bir önceki katmanın çıktı verisi kullanılan derin öğrenmede; verilerin birden fazla özellik katmanlarının ve temsiline öğrenilmesine dayanan bir yapı ile üst düzey özelliklerden alt düzey özellikler oluşturularak hiyerarşik bir temsil öğrenimi ortaya çıkmaktadır (Bengio ve ark., 2013). Şekil 2’de derin öğrenme sinir ağının genel yapısı gösterilmektedir.




Şekil 2. Derin öğrenme sinir ağı (Çarkacı, 2018)

Derin öğrenme modelleri, mimari yapıların oluşturulmasına büyük katkı sağlayan; veri setinin büyüklüğüne, türüne, boyutuna, hacmine, yapısına ve kullanılan parametrelere bağlı olarak değişebilen; genel olarak görüntülere ses ve metinsel gibi karmaşık dizelere uygulanan; gizli katmanların eğitim aşamasında modelleri hem toplamsal hem de çarpımsal olarak parametrelere ayıran; optimizasyonu iyileştiren ve modellerde çıkarım işlemleri yaparak problemlerin çözümünü kolaylaştıran ve özellik çıkarma ve dönüştürme işlemleri için birden çok doğrusal olmayan işlem birim katmanını kullanan sistemlerdir (Song ve Lee, 2013; Goodfellow ve ark., 2016; Zheng ve ark., 2019). Derin öğrenme modellerinin en iyi avantajlarından biri yapılandırılmamış verileri (görüntüler vb.) özellik çıkarma tekniklerine gerek duymadan üzerinde işlem yapabilmesidir. En çok kullanılan derin öğrenme modelleri; Evrimsel Sinir Ağları (Convolutional Neural Network- CNN), Tekrarlayan Sinir Ağları (Recurrent Neural Networks- RNN), Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines- RBM), Uzun Kısa Dönemli Bellek (Long/Short Term Memory- LSTM), Derin İnanç Ağları (Deep Belief Networks- DBN) ve Derin Oto-Kodlayıcılar (Auto Encoder)'dır. Bu çalışmada yaygın kullanılan modellerden olan CNN'e dayalı AlexNet ve GoogleNet modeli ile özgün olarak yeni geliştirilen CNN modeli kullanılmıştır.

Sınıflandırma ve segmentasyon özellikleriyle öne çıkan (Diaz ve ark., 2021) CNN'ler başarılı uygulamaları sayesinde derin öğrenme çalışmalarında çok tercih edilen popüler ve güçlü modellerdendir. Derin öğrenmede sınıflandırma işlemleri, ön işlem yapılmaksızın CNN modeli ile diğer makine öğrenmesi tekniklerine kıyasla daha hızlı ve

doğru bir şekilde yapılabilmektedir (Adem, 2018; Adem ve Közkurt, 2019). CNN bir girdinin görüntüsünü alabilen, görüntüdeki çeşitli özelliklere önem (weight ve bias) atayan ve görüntülerin birbirlerinden ayırt edilebilmesine imkan sağlayan ve aynı zamanda görüntülerin birbirleriyle olan ilişkilerini ortaya çıkarabilen ve bilgisayarlı görü işlevlerinde uzmanlaşmış derin öğrenme algoritmasıdır (Couliably ve ark., 2022).

Görüntü verileri ile doğru özelliklerin ortaya çıkarılması oldukça karmaşık ve zor bir işlemdir. CNN modellerinde, evrişimli katmanlar özellik tespitini otomatik olarak gerçekleştirmektedir. Bu yüzden yapay sinir ağına evrişimli katmanlar eklenmesiyle CNN'lere dönüştürülerek bir görüntüden özellik çıkarımı ve sınıflandırma işlemleri daha kolay hale getirilmektedir. Şekil 3'te üzüm çeşitlerini salkım özellikleri ile sınıflandıran CNN modelinin genel yapısı gösterilmektedir.



Şekil 3. CNN modeli genel yapısı (Anonim, 2022a)

Derin öğrenmede modeller oluşturulurken, modelde kullanılacak olan hiper-parametreler, uygulamalardaki önemli problemlerden birisini oluşturmaktadır. Hiper-parametreler ve bunların değerlerinin seçimine karar verme, veri setinin türüne kullanıcının algı ve tecrübesine, çalışmaların yeniliğine, başka uygulamalardaki elde edilen sonuçlara vb. birçok duruma göre değişmektedir. Model oluşturulurken kullanılan parametrelerden başlıca olanları şunlardır;

- Ağda kullanılacak çekirdeğin boyutu
- Parti büyüklüğünün sayısı (Batch-size)
- Çevrim ve katman sayısı
- Kullanılan aktivasyon fonksiyonu
- Optimizasyon algoritmaları

- Öğrenme hızı (Learning rate)
- Seyreltme değeri (Drop out)
- Seyreltmenin kullanılacağı yerler
- Veri setinin büyüklüğü

Bu hiper-parametreler çalışmaların çoğunda test edilerek sonuç yorumlama yöntemiyle defalarca tekrar edilen çalışmalar sonucu belirlenmektedir. Kullanılacak modele en uygun olan ve en iyi sonuç veren parametre/parametreler programı yapan tarafından belirlenerek, modelin son hali oluşturulmaktadır (Çarkacı, 2018; Savaş, 2020a).

Derin öğrenmede CNN modelleri oluşturulduktan sonra elde bulunan veriler, sonuç alınabilmesi için CNN modelinde eğitim ve test sürecine tabii tutulmaktadır.

Eğitim boyunca CNN modeline görüntülerden oluşan binlerce veri yüklenerek, görüntünün ne olduğu öğretilmektedir. Test işleminde ise test verileri ile CNN modelinin hangi oranda başarılı olduğu test edilerek istenilen sonuca ulaşmak hedeflenmektedir.

CNN modelini oluşturan katmanlar


Giriş katmanı

İsminden de anlaşıldığı gibi CNN'nin ilk katmanıdır. Veri ham olarak ağı bu katmanda verilmektedir. Bu katmanda verinin boyutu tasarlanan oluşturulan ya da eğitilen modelin başarı oranı için önemlidir. Giriş görüntü boyutlarının yüksek olması ağı başarısını artırabilir fakat fazla bellek ihtiyacını, eğitimin süresini ve her bir görüntü başına düşen test süresini uzatabilmektedir. Görüntü boyutunun düşük olması ise kurulan ağı derinliğini azaltır ve performansı düşürebilir. Fakat bellek ihtiyacını azaltırken eğitim süresini de kısaltabilmektedir. Her bir modelin görüntü giriş boyutu farklı olabilmektedir. Bu yüzden giriş görüntü boyutları; görüntü analizlerinde, ağı derinliği, donanımsal hesap maliyetleri ve ağı başarısı için en uygun şekilde seçilmelidir.

Konvolüsyon katmanı

Dönüşüm katmanı olarak bilinen konvolüsyon katmanı CNN modelinin temelini oluşturmaktadır. Burada dönüşüm işlemi belli bir filtrenin bütün görüntüler üzerinde gezdirilmesi işlemine dayanmaktadır. Bundan dolayı filtreler katmanlı mimarilerin ayrılmayan bileşenleridir. Filtrelerin 2x2, 3x3, 5x5 şeklinde farklı boyutları

bulunmaktadır. Bir önceki çıkış katmanından alınan görüntülere konvolüsyon işlemini uygulayarak çıkış verisini filtreler oluşturmaktadır. Her bir filtreye ait özelliklerin oluşturulduğu bölgeler aktivasyon haritası olarak bilinmektedir. Eğitimdeki öğrenme tekrarlarıyla filtrelerin katsayıları değişmektedir. Bu şekilde ağ, verinin hangi bölgesinin önemli olduğunu özelliklerin çıkarılması için belirler. Şekil 4'te görüntüler üzerinde bir filtrenin dolaştırılması işlemi gösterilmektedir.



Şekil 4. 5x5x3 boyutlu giriş görüntüsü üzerinde 3x3 filtrenin uygulandığı konvolüsyon işlemi (İnik ve Ülker, 2017)


Şekilde giriş görüntüleri renkli ve 5x5 matrisli olduğu düşünüldüğünde giriş veri boyutları 5x5x3 şeklinde olmaktadır. Bu durumda konvolüsyon işlemi için 3x3 filtre ile görüntü üzerinde sağa veya sola belirli Adım (Stride) ile kaydırılarak dolaşım işlemi gerçekleştirilmektedir. Bu dolaşma işlemi matris sınırına geldiğinde bir basamak aşağı doğru kaydırılarak işleme tekrar devam edilmektedir. Görüntü matrisinin tamamında bu dolaşma işlemi yapılmaktadır. Her bir renk kanalındaki değerler ile filtre katsayıları çarpılıp bunların toplamı elde edilir. Üç kanal üzerinde de bu işlem yapıldıktan sonra üçünün toplam değeri aktivasyon haritasını meydana getirir. Giriş ve çıkış boyutu arasındaki aynı yoğunluğu sağlayabilmek için aktivasyon haritası üzerindeki değerler normalize edilmektedir. Normalize işlemi için renk kanalları için hesaplanan değerler filtrelerin katsayılarının toplamına bölünmektedir (İnik ve Ülker, 2017).

Toplu normalleştirme katmanı (Batch normalization layer)

Bu katman giriş için kullanılan her kanalın aktivasyonlarını normalize etme işleminde kullanılır. Konvolüsyon ve aktivasyon katmanları arasında kullanılması tavsiye edilmektedir. Standart sapma parametreleri katman içerisinde varsayılan olarak ayarlanmaktadır.

Düzleştirilmiş doğrusal birim katmanı (ReLU)


Girdi için eşik değeri uygulamasını oluşturan bir aktivasyon fonksiyonu katmanıdır. Aktivasyon katmanındaki gibi eşik değeri sıfırdır ve değiştirilemez. CNN için en çok devreye sokulan doğrultucu birim ya da aktifleştirme katmanı olarak da bilinmektedir. Şekil 5'te ReLu katmanının genel yapısı gösterilmektedir.



Şekil 5. ReLu katmanının çıkış verisine etkisi

Havuzlama katmanı (Pooling layer)

Girdi görüntüsünün özelliklerini çıkaran ve bunların analizini yapan ilk katmandır. Genellikle ReLu katmanından sonra yerleştirilir. Temel görevi sonraki gelecek konvolüsyon katmanının giriş boyutunu azaltmaktır. Önceki katmandan aldığı girdiyi bölümlere ayırıp her bir bölümün maksimumunu hesaplayarak ve maksimumlardan oluşan katman çıktıları yeni katmanın girişi olarak ayarlamaktadır. Katmanın uygulanabilmesi için katmana özel bazı parametrelerin tanımlanması gerekmektedir. Bu tanımlamaları PoolSize parametresi, Stride parametresi ve Padding parametresi gerçekleştirmektedir. Şekil 6'da 2x2 filtre ile havuzlama işleminin uygulanması gösterilmektedir.




Şekil 6. 2x2 filtre ile havuzlama işleminin uygulanması

Tam bağlantılı katman (Fully connected layer)

Düzleştirilmiş doğrusal birim katmanı ve havuzlama katmanından sonra tam bağlantılı katman gelmektedir. Evrişimsel sinir ağının (CNN) son aşamasına gelindiğinde devreye girer ve evrişim/havuz oluşturma çıktısını alarak, görüntüyü tanımlayabilmek için en iyi etiketi tahmin işlemini yapmaktadır. Kendinden önce gelen katmanın bütün alanlarına bağlıdır. Mimari yapıya göre tam bağlantılı katman sayısı değişiklik gösterebilmektedir. Modele verilen girdilerin tek boyutlu doğrusal vektör olması gerekmektedir. Ortaklama (Pooling) katmanından elde edilen çıktı, girdinin sinir ağına eklenmesi için tam bağlantılı katmanda tek boyutlu vektöre dönüştürülür. Bundan dolayı CNN modellerinde düzleştirici (flatten) ve tam bağlantılı katmanlara ihtiyaç duyulmaktadır. Model eğitiminde hata ile karşılaşmamak için katmanın çıktı boyutu kullanılan girdi boyutu ile aynı olmalıdır (Anonim, 2022b).

Şekil 7’de tam bağlantılı katmanın genel yapısı gösterilmektedir.



Şekil 7. Tam bağlantılı katman genel yapısı (Anonim, 2022c)

Softmax katmanı (Softmaxlayer)


Çoklu sınıflandırma problemlerinde kullanılan softmax katmanı verilen her girdinin bir sınıfa ait olma durumunu gösteren ve 0-1 arası çıktılar üreten bir yapıdır. Bu katmanda sinir ağına kayıp fonksiyonu uygulanmaktadır.

Sınıflandırma katmanı (Classification layer)

Softmax katmanından sonra gelen sınıflandırma katmanı derin öğrenme mimarilerinde sınıflandırma işlemini gerçekleştirmektedir. Bir önceki katmanın çıktı boyutları sınıflandırma katmanının çıktı boyutunu belirlemektedir. Çıkış değeri, sınıflandırması yapılacak olan nesne sayısına eşit olmaktadır. Örneğin 11 farklı nesne sınıflandırılacaksa, sınıflandırma katmanı çıkış değeri 11 olmalıdır. Sınıflandırma katmanında farklı sınıflandırıcılar kullanılabilir. Genellikle softmax sınıflandırıcısı başarısından dolayı çok tercih edilmektedir. Derin öğrenme algoritmalarının çalıştırılması ve çalışmaların aktif hale getirilmesi ile problemlerin çözümü için kullanılan birçok derin öğrenme kütüphanesi bulunmaktadır. Günümüzde var olan kütüphaneler devamlı güncellenmekte ve yeni geliştirilen kütüphaneler de kullanıma açılmaktadır. Derin öğrenmede hazır veri setlerinin kullanıldığı kütüphanelerden bazıları Tensorflow, Theano, Caffe, Keras, PyTorch, DIGITS'dir (Savaş, 2020b).

AlexNet


Giriş, normalizasyon, havuzlama, dropout, tam bağlı, yumuşak bağlı ve çıkış katmanlarından oluşmaktadır. AlexNet mimarisinde örüntü tanıma oranının %26'dan %15'lere indirgenmektedir. Bu başarısı AlexNet'i en çok bilinen mimarilerden biri haline getirmiştir. Mimari yapıda doğrusal olmayan fonksiyonlar için klasik fonksiyonlardan daha hızlıdır. Eğitim süresini kısalttığından dolayı, aktivasyon (ReLU) fonksiyonu, eğitimde aşırı öğrenmenin önüne geçilebilmek için Bırakma (Dropout) katmanı, momentum değerleri ve ağırlık gecikmeleri için ise gradyan inişli model kullanılmaktadır. AlexNet mimari yapısının içinde beş ana konvolüsyonel katman bulunmaktadır (You ve ark., 2018). Şekil'8 de AlexNet ağ mimarisi gösterilmektedir.



Şekil 8. AlexNet ağ mimarisi (You ve ark., 2018)

GoogleNet

GoogleNet yapısındaki Inception modülünden dolayı kompleks bir mimari yapıya sahiptir. Yirmi iki katman derinliğe sahip olup değişik boyutlarda filtreleme işlemi yaparak, diğer derin öğrenme mimarilerinden farklı bir yaklaşım ortaya çıkarmaktadır. Sıralı bir yapıda konvolüsyon ve havuzlama katmanlarını üst üste gelmeyecek şekilde ayarlayan ilk CNN mimarilerindendir. Katmanların üst üste gelmesi ve çok sayıda filtrenin olması, bir hesaplama ve hafıza maliyeti ortaya çıkarmaktadır. GoogleNet bu durumu ortadan kaldırmak için paralel şekilde bağlantılı olan modüller kullanmaktadır. (Szegedy ve ark., 2014). Şekil’9 da GoogleNet ağ mimarisi gösterilmektedir.



Şekil 9. GoogleNet ağ mimarisi (Szegedy ve ark., 2014)

Görüntüleme teknikleri ile bitkilerdeki var olan farklılıkların ayırt edilebilmesi mümkündür (Ozguven ve Altas, 2022). Üzüm bitkisi; sürgün, yaprak, salkım, meyve ve çekirdeklerinin karakterizasyon özelliklerine göre çok farklılıklar gösterebilen bir meyve olduğundan, ekonomik ve ticari boyutu büyük olan üzüm üretimi yapılan alanlarda teknolojik alt yapıya sahip uygulamaların kullanılması bağcılığın geleceği için önemlidir. Günümüz teknolojisi olan derin öğrenme teknikleri ile üzüm çeşitlerinin karakterizasyon özellikleri kullanılarak çeşitlerin tespiti ve sınıflandırılması işlemlerinin yapılması bağcılık alanına önemli katkılar sağlamaktadır (Terzi ve ark., 2022).

Yapılan bu çalışma ile bilgi teknolojilerinin tarıma adapte edilmesi; bu alandaki bilime, üzüm yetiştiriciliği alanında bulunan bölgenin sanayisine, pazarına ve ekonomisine, katkı sağlayacaktır. Tarımsal üretim yapan çiftçilerin yetiştirdikleri ürün hakkındaki bilgiye hızlı ve kolay bir şekilde ulaşabilmeleri yetiştiricilik bakımından büyük önem arz etmektedir. Bu da ancak teknolojiye ki son gelişmelerin tarıma uyarlanmasıyla mümkün olmaktadır. Üzüm yetiştiriciliği alanında üzüm çeşitlerinin belirlenmesi aşamasında derin öğrenme tekniklerinin kullanılmasının uzun vadede tarımsal kalkınma ve toplumsal gelişme alanında etkili olacağı düşünülmektedir. Bu çalışmada, elli adet üzüm çeşidinin (bunlardan üç tanesi 5BB, 110R ve 41B Amerikan Asma Anacı'dır) yaprak, salkım ve meyve görüntüleri üzerinde, çeşit tespitinde kullanılan ampelografik özellikler (Çizelge 4) kullanılarak, yeni geliştirilen CNN modeli, GoogleNet ve AlexNet modelleri ile çeşitlerin sınıflandırılması yapılmıştır. Bununla birlikte teknolojiye ki son gelişmelerin tarımsal alanda da kullanılması amaçlanmaktadır.

2. LİTERATÜR ÖZETLERİ

2.1. Derin Öğrenme Literatürleri

Fuentes ve ark. (2017) çalışmalarında, değişik çözünürlükteki kameralarla dokuz hastalık ve zararlı sınıfından oluşan 5 000 adet görüntü elde ederek, domates bitki hastalık ve zararlılarının derin öğrenme yöntemi ile tanımlaması ve tespiti için yeni bir model önermişlerdir. Veri setlerini %80 eğitim, %10 doğrulama ve %10 test seti olarak bölmüşlerdir. Çalışmada üç farklı derin öğrenme mimarisi kullanmışlardır. Bunlar; Faster R-CNN, R-FCN ve SSD mimarileridir. Çalışmada modellerin başarı oranlarını Faster R-CNN için %83, R-FCN için %85.98 ve SSD için %82.53 olarak ortaya çıkarmışlardır. En başarılı modelin R-FCN modeli ile %85.98 olduğunu açıklayarak, bu modellerle farklı hastalık ve zararlıları başarılı bir şekilde tespit ettiklerini ifade etmişlerdir.

Durmuş ve ark. (2017) çalışmalarında, AlexNet ve SqueezeNet derin öğrenme modellerini kullanarak domateste Bakteri Lekesi, Erken Yanıklık, Geç Yanıklık, Yaprak Küf, Yaprak Lekesi, İki Noktalı Kırmızı Örümcek Hasarı, Siyah Leke, Mozaik Virüsü, Sarı Yaprak Kıvrılması Virüs hastalıklarını tespit etmişlerdir. PlantVillage veri kümesinden elde ettikleri veri kümesinde 14 farklı ürün için 54 309 etiketli görüntü kullanmışlardır. Veri setlerini sağlıklı görüntüler dahil olmak üzere, 10 farklı sınıf oluşturmuşlardır. Görüntülerin %80'ini eğitim, %20'sini test için değerlendirmişlerdir. AlexNet ve SqueezeNet arasında karşılaştırma yapmışlar; doğruluk oranını AlexNet için %95.65 ve SqueezeNet için ise %94.30 olarak bildirmişlerdir.

Mureşan ve Oltean (2018) çalışmalarında, derin öğrenme yöntemlerini kullanarak görüntülerden meyve tanıma işlemi yapmışlardır. Meyvelerin bulunduğu görüntülerden yeni ve yüksek kalitede 60 sınıflı, 38 409 meyve görüntüsü bulunan veri kümesi oluşturmuşlardır. Veri kümesini Fruits-360 olarak adlandırmışlardır. Görüntülerin 28 736 tanesini eğitimde ve 9 673 tanesini test işleminde kullanmışlardır. Görüntülerden meyveleri algılayabilmek için, eğitim setinden rastgele seçilen 50 görüntüden oluşan gruplarla 40 000 iterasyonla eğitilmiş olan CNN modelini kullanmışlardır. Her 50 adımda bir çapraz doğrulamayı kullanarak doğruluğu hesaplamaya çalışmışlar ve %96.3 doğruluk oranı elde ederek görsellerden meyveleri tanıyabilen bir yazılım geliştirdiklerinin bildirmişlerdir.

Türkoğlu ve Hanbay (2018) çalışmalarında, derin öğrenme algoritmalarından elde edilen öz niteliklere dayalı kayısı hastalık tespiti yapmışlardır. Veri setleri sağlıklı kayısı (308) ile çil hastalığı (652) olmak üzere toplam 960 yaprak görüntüsünden oluşmaktadır. Kayısı hastalık tespiti için önceden eğitilmiş CNN'e dayalı AlexNet, VGG16 ve VGG19 gibi derin öğrenme modellerini kullanmışlardır. Sistemin performansını hesaplamak için 10'lu çapraz geçerlilik testi uygulamışlardır. Önerilen yöntemle 864 sağlıklı ve hastalıklı görüntü eğitim kısmında ve 96 görüntü ise test kısmında kullanılmıştır. Önerdikleri sistemin çil hastalığı ile sağlıklı kayısı görüntülerini tanıma başarımı AlexNet için %89.7, VGG19 için %92.9 ve en yüksek VGG16 modeli için %94.8 olarak hesaplamışlardır. Bitki hastalık tespiti için önerdikleri sistemin başarılı olduğunu ve gelecekte farklı modellerle farklı bitki hastalılarının sınıflandırılmasını yapacaklarını raporlamışlardır.

Doğan ve Türkoğlu (2018), derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılmasını konu edindikleri çalışmalarında, yaprak sınıflandırması için AlexNet, VGG16, VGG19, ResNet50 ve GoogleNet derin öğrenme algoritmalarını uygulamışlardır. 32 sınıftan oluşan toplam 7 628 yaprak görüntüsünü veri seti olarak kullanmışlardır. Bu görüntülerin %80'ini eğitim için %20'sini ise test için ayırmışlardır. Uygulama için MATLAB derin öğrenme algoritmalarından faydalanmışlardır. Beş farklı derin öğrenme algoritmaları ile gerçekleştirilen yaprak sınıflandırma çalışmalarına ait başarımlar oranları AlexNet için %99.72, GoogleNet için %97.77, VGG16 için %99.12, VGG19 için %98.36 ve ResNet50 için %99.15 olarak hesaplamışlardır. Bu sonuçlara göre ise en yüksek başarımlar oranının AlexNet modelinde %99.72 olduğunu bildirmişlerdir.

Heinrich ve ark. (2019) çalışmalarında, nesne sayımı için derin öğrenme yöntemlerini kullanarak üzüm bağlarının tarımsal yönetimi için ürün verim tahmini yapmışlardır. Bunun için iki aşamalı bir yaklaşım kullanmışlardır. Önce nesne algılama yoluyla (ör; CNN gibi bir algılama modeli kullanımı) yer belirleme işlemi yapmışlar, daha sonra algılanan nesneleri sayma işlemi yapmışlardır. Veri bilimi çalışmalarında, yapısal olarak altı aşamadan oluşan (etki alanı anlama, veri anlama, veri hazırlama, modelleme, değerlendirme ve dağıtım) Bilgi Keşfi ve Veri Madenciliği (Knowledge Discovery & Data Mining- KDDM) yaklaşımını önermişlerdir. Kullandıkları sistemin modelleme aşamasında nesne algılamada yapay sinir ağları için kullanımı yaygın olan, derin öğrenme modellerinden SSD, Faster R-CNN ve R-FCN modellerini kullanmışlardır. Kullandıkları modellerin eğitim işlemlerinde ise daha önceden eğitilmiş olan COCO (durumdaki ortak

nesneler), KITTI (trafikteki durumların yakalandığı görüntüler) ve OID (9 milyon görüntü ile açık bir görüntü veri kümesi) kullanmışlardır. Modellerin eğitimindeki başarı oranlarını SSD için %98.47, Faster R-CNN için %99.62 ve R-FCN modeli için ise %99.10 olarak hesaplamışlardır. Bu sonuçlara göre FR-CNN modelinin verim tahmini yapmada en iyi performansı gösterdiği raporlanmıştır.

Doğan (2019) çalışmasında, domates ve elma yaprakları üzerinde görülen hastalıkların derin öğrenme yöntemleriyle tespitini ve sınıflandırılmasını ele almıştır. Program olarak MATLAB programından faydalanmıştır. Hastalık tespiti için derin öğrenme yöntemlerinden olan CNN modeli kullanılmıştır. Veri setinde domates yapraklarında 1 sağlıklı yaprak ve 4 farklı hastalıklı yaprak olmak üzere 5 farklı sınıf, elma yapraklarında ise 1 sağlıklı 1 hastalıklı olmak üzere 2 sınıf için deneysel çalışmalar yapılmıştır. Çalışmada bitki hastalık tespiti yapabilmek için 500 tane sağlıklı ve hastalıklı yapraklardan oluşan görüntülerin 400 tanesini eğitim verisinde, 100 tanesini ise test verisinde kullanılmıştır. Ortalama doğruluk oranı ise domates yapraklarında %86 ve elma yapraklarında ise %98.5 olarak bulunmuştur.

Turkoglu ve Hanbay (2019) çalışmalarında, bitki türlerinin tespiti için CNN ve Renkli-Yerel İkili Örüntü (YİÖ) yönteminin kombinasyonuna dayalı bir yaklaşım önermişlerdir. Önceden eğitilmiş bir CNN mimarisi olan AlexNet modelinin fc6 katmanından derin özellikler elde edildiği, renkli görüntülerin her bir kanalı (R,G,B) için YİÖ yöntemi uygulandığı ve YİÖ yönteminden elde edilen özellikler birleştirilerek Destek Vektör Makinesi (DVM) ile sınıflandırma yapıldığı bildirilmiştir. Araştırmacılar, doğruluk testinde 40 farklı bitkiye ait toplam 443 yaprak görüntüsü içeren ICL ve her bir türden 20 adet olmak üzere 32 farklı bitkiye ait toplam 640 yaprak görüntüsü içeren Folio yaprak veri setlerini kullanmışlardır. Ayrıca deneysel çalışmalarında iki veri tabanından da rastgele bir şekilde verilen %70'i eğitim kümesi için, %30'u ise test kümesi için ayrılmıştır. ICL ve Folio veri setleri için sırasıyla %98.50 ve % 99.48 doğruluk oranları bulunduğu raporlanmıştır. Önerilen modelin yapılan son çalışmalarla karşılaştırdığında daha iyi performans elde edildiğini bildirmişlerdir

Özgür ve Nar (2019) çalışmalarında, dört derin öğrenme modeli olan, LeNet5, AlexNet, VGG16 ve MobilNet modellerini kullanarak ekin ile yabancı otların birbirinden ayırt edilmesini ele almışlardır. Araştırmacılar kullandıkları derin öğrenme modellerini eğitim

süresi, parametre sayısı ve doğruluk oranı ölçümleri bazında karşılaştırmış ve veri seti olarak 12 sınıftan oluşan Plant Seedlings veri setini kullanmışlardır. Modellerden elde edilen doğruluk oranları LeNet5 için %69.37, AlexNet için %85.72, VGG16 için %31.68 ve MobilNet modeli için %85.29 olarak bulunduğu bildirilmiştir. Bu sonuçlara göre kullanılan veri setine en uygun modelin AlexNet olduğu ve VGG16 modelinin kullanılan veri setinde en kötü sonucu verdiğini bildirmişlerdir.

Kairoldayeva (2019) çalışmasında, tarla görüntülerinden bitki türü ve fenolojik evresinin derin öğrenme yöntemi ile otomatik saptanmasını önermiştir. Araştırmasında arpa, buğday, ayçiçeği, mısır, pamuk ve nohut olmak üzere altı tür bitki ve bitkilerin farklı fenolojik aşamalarını sınıflandırmak için CNN temelli 5 farklı model kullanmıştır. Veri setinde 9 000 görüntü elde etmişler ve bunların 6 000 tanesini eğitim için 3 000 tanesini ise test için kullanmıştır. Model doğruluk oranlarını CNN için %82.19, MobilNet-Feature Extraction için %80.3, MobilNet V2 - Feature Extraction için %83.27, MobilNet V2 – Fine Tuning için %97.72 ve VGG16 - Fine Tuning için ise %93.08 olarak bulmuştur. Bu oranlara göre ve en yüksek doğruluk oranını %97.72 olarak MobilNet V2-Fine Tuning modeli ile hesaplandığını bildirmiştir.

Franczyk ve ark. (2020) çalışmalarında, üzümde Chardonnay (CDY), Cabernet Franc (CFR), Cabernet Sauvignon (CSV), Sauvignon Blanc (SVB), Syrah (SYH) çeşitlerini ResNet modeli kullanılarak belirlemişlerdir. Modelin eğitim ve test işlemleri için beş üzüm çeşidine ait 3 957 salkım görüntüsü kullanmışlardır. Veri setlerini %90 eğitim, %10 test görüntüleri olacak şekilde rastgele bölmüşlerdir. Çalışma sonucunda CDY %95.38, CFR %89.23, CSV %85.96, SVB %83.07, SYH %95.83 doğruluk oranı elde edildiğini bildirmişlerdir. Araştırmacılar ayrıca ResNet modeli ile üzüm çeşitlerinin belirlenmesinde %89.89 genel doğruluk elde edildiğini raporlamışlardır.

Grace ve ark. (2021) çalışmalarında, derin öğrenme tabanlı bir CNN modelinin, yabancı otları ve ürünleri tanımlamak için kullanılmasını önermişlerdir. Önerilen modelin değerlendirilebilmesi için Kaggle’ın halka açık Bitki Fide Sınıflandırması veri setinden 5 545 görüntü kullanıldığı ve deneylerin Google Colaboratory kullanılarak gerçekleştirildiği ve sınıflandırma veri seti için eğitim ve test işlemlerinin hesaplandığını bildirmişlerdir. Görüntülerin %80’ini eğitimde %20’sini teste kullanarak, sınıflandırma doğruluk oranının %89 olarak bulunduğu rapor edilmiştir.

Liu ve ark. (2021) çalışmalarında, derin öğrenme teknikleriyle yirmi bir çeşitten oluşan 33 600 görüntü bulunan bir veri seti kullanarak asma çeşitlerinin tanımlanabilmesi için bir mobil uygulama geliştirmeyi önermişlerdir. Veri setlerinin %70'ini eğitim için %30'unu test için ayırmışlardır. Çalışmada AlexNet, VGG-16, ResNet101, ResNet18, DenseNet ve GoogleNet olmak üzere altı farklı derin öğrenme modeli kullanmışlardır. Modellerin başarı oranlarını AlexNet için %94.70, VGG-16 için %96.85, ResNet101 için %97.24, ResNet18 için %95.68, DenseNet için %94.70 ve GoogleNet için %99.66 olarak hesaplamışlardır. Bu oranlara göre GoogleNet modelinin %99.66 başarı oranı ile en iyi performansı gösterdiğini bildirmişlerdir. Çalışmanın sonucunda Android işlemcisinde çalışan VitisView isimli bir uygulama geliştirmişlerdir.

Peng ve ark. (2021) çalışmalarında, üzümde Chardonnay, Cabernet Franc, Cabernet Sauvignon, Sauvignon Blanc ve Syrah çeşitlerini AlexNet, GoogLeNet, ResNet-18, ResNet-50, ResNet-101 derin öğrenme modelleri kullanılarak belirlemişlerdir. Modelin eğitim ve test işlemleri için beş üzüm çeşidine ait 300 salkım görüntüsü kullanmışlardır. Veri setlerini %70 eğitim, %30 test görüntüleri olarak rastgele bölmüşlerdir. Çalışma sonucunda beş üzüm çeşidinin belirlenmesinde AlexNet %85.7, GoogLeNet %93.8, ResNet-18 %89.8, ResNet-50 %87.7, ResNet-101 %81.6 doğruluk oranı elde edildiğini bildirmişlerdir.

Adige ve ark. (2022) çalışmalarında, elma çeşitlerinin türlerine göre sınıflandırılmasını görüntü işleme tekniklerinden faydalanarak yapmışlardır. Çalışmada, 20 Golden, 20 Arjantin, 20 Buckeye Gala, 20 Galaval, 20 Süperchif ve 20 Joremin elma türlerinden toplamda 120 fotoğraf görüntünün, %70'ini eğitime %30'unu ise test işlemlerinde kullanılmıştır. Görüntüleri işlemek için MATLAB programını kullanılarak, sınıflandırma işlemlerinde derin öğrenme algoritmalarından yararlanıldığı ve Mimari yapı olarak ise AlexNet ve GoogleNet derin öğrenme algoritmalarını kullanıldığı rapor edilmiştir. AlexNet mimarisi için %83.33 başarı oranı elde edilirken GoogleNet mimarisinde ise %91.67 sınıflandırma başarısı elde edildiği bildirilmiştir. Bu sonuçlara göre, GoogleNet modelinin eğitim ve test süresi, AlexNet modeline kıyasla daha uzun olmasına rağmen, daha iyi sonuçlar verdiğini raporlamışlardır.

Atik (2022) çalışmasında, derin öğrenme tekniklerini kullanarak domates bitkisi yapraklarındaki hastalıkların sınıflandırılmasını ele almıştır. Veri seti olarak 9 hastalıklı

ve 1 sağlıklı sınıftan meydana gelen toplam 18 160 domates yaprağı görüntüsü kullanılmış ve hastalıkların sınıflandırılmasında CNN modellerinden ön eğitilmiş ağlardan olan AlexNet, GoogleNet, ShuffleNet, SqueezeNet, ve ResNet-18 modellerini kullanıldığı ve analizlerde görüntülerin %70'ini eğitime, %15'ini doğrulamaya ve %15'ini ise teste işlemlerine veri seti olarak ayrıldığı belirtilmiştir. Modellerin doğruluk oranları AlexNet, GoogleNet, ShuffleNet, SqueezeNet, ve ResNet-18 için sırasıyla %93,93, %95,18, %94,82, %94,29 ve %81,79 olarak hesaplandığı bildirilmiştir. Yapılan test analiz sonuçlarına göre, ön eğitilmiş CNN modelleri içinde en yüksek performans değerinin GoogleNet olduğu ve en düşük performansı gösteren modelin ise ResNet- 18 modeli olduğu rapor edilmiştir.

2.2. Ampelografik Özelliklerle İlgili Literatürler

Doğan ve ark. (2017) çalışmalarında, 2014-2015 yılları arasında Adıyaman merkez ilçesinde yetiştirilen yerel üzüm çeşitlerine ait ampelografik özellikleri ele almışlardır. Araştırmacılar ampelografik özellikleri “Uluslararası Bitki Gen Kaynakları Enstitüsü” (The International Plant Genetic Resources Institute- IPGRI) tarafından oluşturulmuş olan “Üzüm Tanımlayıcıları” metoduna göre belirlemişlerdir. Çalışmada, 19 üzüm çeşidinin (Dökülgen, Havik, Kabarcık, Can, Mezrone, Besni, Sorik, Sergi karası, Serpene kıran, Deli, Hıdır, Kırmızı sofralık, Zerik, Dımışkı, Boğazkere, Bozgolik, Hönüsü, Siyah üzüm, Boz üzüm) *Vitis vinifera* L. türüne ait olduğu belirlenmiştir. Ampelografik özellikleri belirlemede toplam 92 OIV kodlarını kullanıldığı, tane kabuk renginin çeşitlerde benzerlik gösterdiğinin tespit edildiği ve on iki çeşitte “yeşil sarı” 5 çeşitte “koyu kırmızı siyah” 2 çeşitte ise “kırmızı” olduğu bildirilmiştir. Ortalama salkım büyüklükleri 118.6- 291.78 cm², ortalama salkım ağırlığı 123.09-710.91 g, ortalama tane ağırlığı 2.05-6.21 g, omca başına ortalama verim 4.10-7.84, kg suda çözünür kuru madde (SÇKM) %10.5-26 ve titre edilebilir asit 3.29-4.46 g/l arasında olduğunu tespit edildiği rapor edilmiştir. Ayrıca çiçek yapısının on altı çeşitte aynı (erdişi), üç çeşitte ise (Zerik, Hönüsü, Bozgolik) morfolojik erdişi fizyolojik dişi olarak belirlendiği bildirilmiştir.

İlim Serhat ve ark. (2017) çalışmalarında, 2013-2014 yıllarında Iğdır ili yöresinde yetiştirilen 11 yerel üzüm çeşidinin (Askeri, Beyaz kişmişi, Erkek miskali, El-hakkı, Haçabaş, İnek emceği, Kerim gandı, Kırmızı kişmişi, Kuzu kuyruğu, Miskali ve Yezandayi) uluslararası normlar çerçevesinde ampelografik özelliklerinin belirlenmesi

için yapılmış ve 11 üzüm çeşidinin *Vitis vinifera* L. türüne ait olduğu belirlenmiştir. Araştırmacılar ampelografik özelliklerin belirlenmesinde IBPGR, OIV ve UPOV ortaklaşa kabul edilen “Descriptors for Grapevine” listelerinden yararlanmışlar, “Üzüm Tanımlayıcıları”na ait kod numaraları, bunların karşılığı olan ampelografik özellikler ve bu özelliklerin açıklamaları ile skala değerlerini baz almışlar ve özelliklerin sıralanmasında ise konuların birbirinin takip etmesi açısından OIV kod numaralarını kullanmışlardır. Çalışmada, 11 Üzüm çeşidine ait ampelografik özellikleri belirlendiği ve her bir çeşide ait özelliği çizelgeler halinde ayrı ayrı sunulduğu rapor edilmiştir.

Arslan ve ark. (2018) yaptıkları çalışmada, 2011 ve 2012 yıllarında Yüksekova (Hakkari) ve köylerinde yetiştirilen bazı üzüm çeşitlerinin ampelografik özelliklerini belirlemişlerdir. Araştırmacılar ampelografik özellikleri ‘International Board for Plant Genetic Resources’ (IBPGR) tarafından geliştirilen ‘Descriptors for Grape’ metoduna göre belirlemişler, bölgedeki 12 üzüm çeşidinin (Besirane, Daufi, Ğatunok, Mercani, Merceğöl, Mirani, Öküzgözü, Reşmiv, Sevdani, Tırşık, Tritelk, Zerik) *Vitis vinifera* L. türünden olduğunu saptamışlar, tane kabuk renginin 6 çeşitte “yeşil sarı” diğer 6 çeşitte ise “koyu kırmızı” olarak tespit etmişler ve ortalama salkım ağırlıklarını bazı çeşitlerde “küçük” bazılarında “büyük” bazılarında ise “orta” olarak belirlemişlerdir. En düşük salkım ağırlığının (193.50 ± 17.78 g), en yüksek salkım ağırlığının ise (576.30 ± 48.22 g) olarak tespit edildiği, çiçek yapısının tüm çeşitlerde “hermofrodit” olarak belirlendiği ve incelenen çeşitlerin ampelografik olarak tanımlanmasının OIV verilerine dayanarak çizelge halinde sunulduğu bildirilmiştir.

Okşit (2018) çalışmasında, genetik olarak önem taşıyan 14 adet üzüm çeşidinin ampelografik özelliklerini belirlemiştir. Yöntem olarak “Üzüm tanımlayıcıları”nın kod numaraları, bunlara karşılık gelen ampelografik özellikler ve bu özelliklerin açıklamaları ile skala değerlerini esas alındığı, özelliklerin sıralanmasında konuların birbirini takip etmesi bakımından OIV kod numaralarını tercih edildiği ve ampelografik özelliklerden; sürgün, genç yaprak, olgun yaprak, çiçek, salkım, tane, verim, kalite, fenolojik ve çubuk özelliklerini “Descriptors for Grape”e göre belirlemiş ve incelenen özellikleri ayrıntılı bir şekilde belirlendiği bildirilmiştir.

Ünal ve Yıldırım (2019) çalışmalarında, Şırnak ili İdil ilçesinde yetiştirildiği tespit edilen Mazrone, Mısabık, Bahdo, Bakari, Şikari, Kerküş, Raş kewnar (Gewdone), Raş gurnik,

Zeynebi, Zeyti, Hasani, Beytilhamam, Zerine, Bılbızeki, Gewre, Payizi, Tayifi (Beleki), Nasiri, Sinceri ve Goglani olmak üzere 20 üzüm çeşidini 2 yıl boyunca (2017-18) ayrıntılı bir şekilde incelenmiş ve bu çeşitlere ait toplam 40 karakter belirlenmiştir. Yöntem olarak OIV, UPOV, IBPGR Üzüm Tanımlayıcıları' nın kod numaraları, bunların karşılığı olan ampelografik özellikler ve bu özelliklerin açıklamaları ile birlikte skala numaralarının kullanıldığı ve incelenen üzüm çeşitlerinin organlarına ait ampelografik bulguların ayrıntılı bir şekilde açıklandığı rapor edilmiştir.

Maras (2019) çalışmasında, Karadağ asma çeşitlerinin ampelografik ve genetik karakterizasyonu ele alınmış ve Karadağ'da yetiştirilen 50 ile 300 yaşları arasında 188 üzüm çeşidini temsil eden örnekler sunulmuştur. Çalışmada, aynı zamanda 17 Kratosija çeşidinin biyotiplerini de içerdiği, ampelografik analizleri Uluslararası Asma ve Şarap Ofisi (OIV-Office International de la Vigne et du Vin) tarafından yayınlanan, tanımlayıcı kodlarla yapıldığı, çeşitlerin, genç sürgünleri, genç yaprakları, çiçekleri, sürgünleri, demetleri, meyveleri ve kaliteleri üzerinde gözlemler yapıldığı ve OIV kodları ile bunların gösterildiği bildirilmiştir.

Bahar ve ark. (2019) çalışmalarında, Ganos dağları doğal florasında bulunan kültür asmalarının (*Vitis vinifera* L.) moleküler ve ampelografik karakterizasyonunu ele almışlardır. Araştırmacılar, 2014 yılında yapılmış olan çalışmalarında elde edilen 103 örnekten salkım gösteren 34 tanesinden 2016 yılında materyaller almış ve 6 SSR belirteçlerini (VVMD5, VVMD6, VVMD7, VVMD8, VrZAG64, VrZAG79) kullanarak moleküler karakterizasyonlarını yapmışlardır. Çalışmadaki genotiplerin, ampelografik ve moleküler incelemeler neticesinde, çoğunlukla birbirlerinden farklı olduğunun saptandığı, ampelografik çalışmalar sonucunda ise birbirleriyle benzer olan herhangi bir genotipe rastlanılmadığı, moleküler karakterizasyon da ele alınan lokuslar bakımından bazı genotiplerin birbirleriyle tamamen benzer olduğunun tespit edildiği ve aynı alandan alınan genotiplerin ampelografik ve genetik olarak farklı karakter gösterebildiğini ve farklı alanlardan alınan bazı genotiplerinde birbirleriyle benzer özellikler gösterdiği bildirilmiştir..

Bounab ve Laiadi (2019) çalışmalarında, bazı asma genotiplerinin (*Vitis vinifera* L.) ampelografik özelliklerini belirleme işlemi yapmışlardır. Çalışma, Doğu Cezayir tohum plazması koleksiyonunda yetiştirilen 36 asma çeşidi üzerinde, OIV tanımlayıcılarını

kullanarak toplam 108 ampelografik kriterle ampelografik özellikleri belirlemek amacıyla 2015-2016 ve 2017 yıllarında yapıldığı belirtilmiştir. Araştırmacılar, çalışma sürecince bitkilerin farklı organlarında nicel ve nitel ölçümler gerçekleştirildiğini, 108 parametreden 44 tanesinin nicel olduğunu, 64 tanesinin nitel özellikte olduğunu, her parametrenin analiz grafiğini ayrıntılı bir şekilde gösterildiği, incelenen üzüm çeşitlerinin yarısı arasında ampelografik özellik bakımından farklılık kaydedildiğini ve diğer yarısı arasında ise benzerlikler olduğunu ifade etmişlerdir.

Çelik ve ark. (2019) çalışmalarında, Aydın Adnan Menderes Üniversitesi, Ziraat Fakültesi Bahçe Bitkileri uygulama bağında bulunan “Gelin Öldüren” (GÖ), “Gelin Üzümlü” (GÜ), “Osmanca” (O) ve “Red Globe” (RG) üzüm çeşitlerinin bir yıllık dal, genç sürgün, genç yaprak morfolojik özellikleri ile uyanma ve çiçeklenme fenolojik özelliklerini, Uluslararası Bağcılık ve Şarapçılık Organizasyonu (OIV) tarafından yayımlanan Ampelografik tanımlayıcılarını kullanarak belirlemişlerdir. Araştırmacılar çalışmalarında üzüm çeşitlerine ait elde ettikleri ampelografik özellikleri çizelgeler şeklinde verdiklerini bildirmişlerdir.

Tarımda derin öğrenme çalışmaları ve üzüm çeşitlerinin ampelografik özelliklerinin belirlenmesine yönelik çalışmalar incelenmiş ve çalışmalardan elde edilen değerlendirmeler maddeler halinde aşağıda verilmiştir.

- Derin öğrenme ile ilgili literatür taramasında, daha çok derin öğrenme modeli olarak CNN mimarilerinin ağırlıklı olduğu çalışmalara yer verilmiştir. Çalışmalarda genellikle CNN mimarilerinden AlexNet, VGG16, VGG19, GoogleNet, ResNet gibi mimariler kullanılmıştır.
- Çalışmalarda üzüm çeşitlerinin derin öğrenme yöntemleriyle belirlenmesi, bitki hastalık ve zararlıları, bitki tanıma sistemleri, bitkilerde sınıflandırma, bitkilerde nesne tespiti ve verim tahmini, elma yapraklarında gerçek zamanlı hastalık tespiti, hayvancılıkta vücut kondisyonu ve sınıflandırma işlemi, yabancı ot tespiti, cevizlerdeki yabancı cisimlerin tespiti, kullanım dışı alanlardaki tarım alanlarının tespiti, tarla görüntülerinden bitki türü ve fenolojik evresinin tespiti ve akıllı ilaçlama robotları gibi çalışmalar derin öğrenme yöntemleri kullanılarak ele alınmıştır.
- Çalışmalarda veri seti olarak genellikle hazır veri setleri kullanılmıştır. Bazı çalışmalarda ise oluşturulan yeni veri setleri kullanılmıştır.

- Model kullanımlarında genellikle ön eğitilmiş derin öğrenme modellerine ağırlık verilmiş, bazı çalışmalarda ise yeni modeller oluşturulmuştur.
- Ampelografik özelliklerin belirlenmesine yönelik çalışmalara; üzüm çeşitlerinin ampelografik özelliklerinin belirlenmesi üzerine durulan çalışmalara yer verilmiştir.
- Çalışmalar daha çok bölgesel olarak yetiştirilen üzüm çeşitleri üzerinde yapılmıştır.
- Aynı alandan alınan genotiplerin ampelografik ve genetik olarak farklı karakter gösterebildiğini ve farklı alanlardan alınan bazı genotiplerinde birbirleriyle benzer özellikler gösterdiği çalışmalarda ortaya çıkarılmıştır.

Bu çalışmada, ampelografik özellikleri derin öğrenme teknikleri kullanılarak belirlendiği, özgün olarak yeni bir derin öğrenme modelinin geliştirildiği bir çalışma yapılmıştır. Veri seti olarak özgün yeni bir veri seti oluşturulmuştur. Veri setinde sadece çalışmada kullanılan yaprak, salkım ve meyve özelliklerine ait görüntüleri değil, çiçek sürgün, genç yaprak ve odunsu sürgün görüntüleri de bulunmaktadır. Derin öğrenme modellerine elli adet üzüm öğretilmiş ve literatüre bu kapsamda katkı sağlanmıştır.

Çalışmada özgün olarak oluşturulan CNN modeli ile birlikte, ön eğitilmiş modellerden GoogleNet ve AlexNet modelleri de kullanılarak modeller arası performans değerlendirilmesi yapılmıştır. Çalışmanın en önemli özgünlüğü ise hem yeni oluşturulan veri seti ve CNN modeli hem de bu veri setinin ön eğitilmiş modellerde yüksek başarı elde etmesi olmuştur. Bu bakımdan bu çalışmayla literatüre yeni bir veri seti kazandırılmıştır. Bağcılıkta üzüm çeşitlerinin bilinmesi hem yetiştiricilik hem tüketim hem pazar hem de ekonomik açıdan önemli bir durumdur. Bu çalışma ile üzüm çeşitlerinin tespitinin teknolojik yöntemlerle de yapılabileceği ortaya konularak bağcılık alanına yeni bir yöntem kazandırılmıştır. Bağcılıkta büyük problem olan üzüm çeşitlerinin tespitinin kolaylaştırılmasına yönelik bir çalışma ortaya çıkarılmıştır.

3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Çalışmaların yapıldığı bağ alanları

Elli adet üzüm çeşidine ait bazı karakterizasyon özellikler ve bu özelliklere ait görüntülerin alınacağı bağ alanları tespit edilmiştir. Bu kapsamda görüntüler öncelikli olarak, Tokat ilinde bulunan Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğüne ait bağ alanından ve Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi'ne ait bağ alanından alınmıştır.

Bu alanların dışında; Ankara Üniversitesi Ziraat Fakültesi Kalecik Bağcılık Araştırma ve Uygulama istasyonundan, Kalecik İlçe Tarımın katkılarıyla ilçede tesis edilmiş olan üzüm bağlarından, Tekirdağ Bağcılık Araştırma Enstitüsü Müdürlüğünden, Manisa Bağcılık Araştırma Enstitüsü Müdürlüğünden, Ondokuz Mayıs Üniversitesi Ziraat Fakültesi Bahçe Bitkileri Bölümüne ait bağ alanlarından görüntüler elde edilmiştir. Kavaklıdere Ankara Akyurt Üzüm Bağları, Antepfıstığı Araştırma Enstitüsü, Bozok Üniversitesi Ziraat fakültesi Bahçe Bitkileri Bölümü, Erzincan Bahçe Kùltürleri Araştırma Enstitüsü Müdürlüğü ve Tokat Kazova bağ alanlarında da bazı çeşitlere ait görüntüler elde edilmiştir.

Elli adet üzüm çeşidinden, yirmi adet üzüm çeşidine ait görüntüler Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğüne ait bağ alanından, geri kalan 30 adet üzüm çeşidine ait görüntüler ise Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi'ne ait bağ alanından alınmıştır. Öncelikli görüntü alma alanımız olan bu iki bağdan, yukarıda ismi verilen çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün görüntüleri alınmıştır.

Bu bağlarda bulunamayan çeşitlere ait salkım ve meyve görüntüleri ise aşağıda ismi verilen bağ alanlarından elde edilmiştir.

Ankara Üniversitesi Ziraat Fakültesi Kalecik Bağcılık Araştırma ve Uygulama istasyonundan; Yalova incisi ve Kyoho üzüm çeşitlerine ait salkım ve meyve görüntüleri. Tekirdağ Bağcılık Araştırma Enstitüsü Müdürlüğünden; Erçiş, Muhammediye, Vakkas ve Tayfi üzüm çeşitlerine ait salkım görüntüleri. Ondokuz Mayıs Üniversitesi Ziraat

Fakültesi Bahçe Bitkileri Bölümüne ait bağ alanlarından; Rizessi ve Rizpem üzüm çeşitlerine ait salkım ve meyve görüntüleri elde edilmiştir.

Bunların dışında 5BB, 110R ile Cabernet france ve Helvani üzüm çeşitlerinin sadece salkım ve buna bağlı olarak da meyve görüntüleri çalışma takvimi dönemlerinde (2020-2021), belirtilen bağlarda ve araştırma yapılan diğer bağ alanlarında da bulunamamıştır. 1103 Paulsen ve Rup. Du. Lot. üzüm çeşitleri ise erkek anaç olduklarından dolayı sadece salkım ve buna bağlı olarak da meyve görüntüleri elde edilememiştir. Belirtilen bu altı üzüm çeşidi derin öğrenme yöntemiyle sisteme yaprak özellikleri kullanılarak öğretilmiştir. Kalan diğer çeşitler hem yaprak hem de salkım-meyve özellikleriyle öğretilmiştir.

Ankara Üniversitesi Ziraat Fakültesi Kalecik Bağcılık Araştırma ve Uygulama istasyonundan, 5BB ve 1103 Paulsen anaçlarına aşılantmış Lival üzüm çeşidine ait salkım görüntüleri de elde edilmiştir.

Üzüm çeşitlerine ait özelliklerin görüntülerinin alınması, sırasıyla çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün olacak şekilde planlanmıştır. Özelliklerin görüntülerinin alındığı tarihler ve bağ alanları Çizelge 1’de verilmiştir.

Çizelge 1. Görüntülerin alındığı tarihler ve bağ alanları

Görüntüsü alınan özellikler	Görüntülerin alındığı tarihler	Görüntülerin alındığı bağ alanları
Çiçek	27.05.2021	Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğü bağ alanı, Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanı
Sürgün	22.06.2020	
Genç yaprak	23.06.2020	
Olgun yaprak	16-17.07.2020	
Odunsu sürgün	25-26.11.2020	
Salkım	16-20-21-24.08.2020 23-24.09.2020	Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğü bağ alanı, Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanı, Ankara Üniversitesi Ziraat Fakültesi Kalecik Bağcılık Araştırma ve Uygulama istasyonu, Tekirdağ Bağcılık Araştırma Enstitüsü Müdürlüğü, Ondokuz Mayıs Üniversitesi Ziraat Fakültesi Bahçe Bitkileri Bölümü bağ alanı
Meyve		

Çizelge 1’de gösterilen çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün (Kyoho, Yalova incisi, Rizessi, Rizpem, Erçiş, Muhammediye, Tayfı, Vakkas üzüm çeşitlerinin sadece salkım ve meyve görüntüleri hariç) görüntülerinin hepsi Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğü bağ alanı ve Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanından alınmıştır. Şekil 10’da görüntülerin alındığı bağ alanlarına ait uydu görüntüleri gösterilmektedir. Şekilde sırasıyla; Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanı uydu görüntüsü, Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğü bağ alanı uydu görüntüsü, Ankara Üniversitesi Ziraat Fakültesi Kalecik Bağcılık Araştırma ve Uygulama istasyonu uydu görüntüsü, Ankara Tarım İl Müdürlüğü Örnek Bağ Tesisi uydu görüntüleri gösterilmektedir.



Şekil 10. Görüntülerin alındığı bağ alanlarına ait uydu fotoğrafları

Şekil 11’de görüntülerin alındığı bağ alanlarına ait arazi görselleri verilmektedir.



Şekil 11. Görüntülerin alındığı bağ alanlarına ait arazi görselleri

Tespiti yapılmaya çalışılan elli adet üzüm Tokat ilinde de yetiştiriciliği yapılan çeşitlerden seçilmiştir. Bu üzüm çeşitlerine ait özelliklerin görüntüleri tespit edilen üzüm yetiştirme alanlarından alınmıştır. Görüntüleri alınan bu özellikler; derin öğrenme sınıflandırma modelinde kullandığımız ve üzümlerin ampelografik özelliklerinin belirlenmesinde kullanılan çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgünden oluşmaktadır.

Belirlenen bağ alanlarından (Çizelge 1) üzüm çeşitlerinin tespitinde kullanılan Bitki Tanımlayıcıları Karakterizasyon özelliklerini temsil eden her bir özellik için elli adet üzüm çeşidine ait, çiçek, sürgün, genç yaprak, odunsu sürgün için en az yüzer adet görüntü, olgun yaprak, salkım ve meyvelerden ise ortalama en az yüz doksanar adet görüntü (Çizelge 3) olmak üzere toplam 48 946 adet görüntü elde edilmiştir.

Şekil 12’de üzüm çeşitlerinin sırasıyla; çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün özelliklerine ait birer adet görüntüleri gösterilmektedir.




Şekil 12. Üzüm çeşitlerinin sırasıyla; çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün özelliklerine ait birer adet görüntüleri

Derin öğrenme modellerinde veri seti olarak kullanılan ve etiketleme işlemlerinin yapıldığı, çalışmanın ana materyalini oluşturan elli adet üzüm çeşidine ait örnek birer adet yaprak (Şekil 13) ve salkım-meyve (Şekil 14) görüntüleri yer almaktadır. Aşağıdaki şekilde birer adet örnek görüntüleri gösterilen çeşitlerin veri setinde her birinin ortalama en az yüz doksana adet görüntüsü bulunmaktadır. Bunların dışında, derin öğrenme modellerinde kullanılamayan diğer özelliklerin (çiçek, sürgün, genç yaprak, odunsu sürgün) görüntüleri ise veri kümesinde bulunmaktadır.



Şekil 13. Üzüm çeşitlerine ait yaprak görüntüleri (Yaprak veri seti materyali)



Şekil 14. Üzüm çeşitlerine ait salkım-meyve görüntüleri (Salkım-meyve veri seti materyali)

Şekil 14’de 5BB, 110R ile Cabarnet france ve Helvani üzüm çeşitlerinin sadece salkım ve buna bağlı olarak da meyve görüntüleri, belirtilen bağlarda ve araştırılan başka bağ alanlarında da bulunamadığından, 1103 Paulsen ve Rup. Du. Lot. üzüm çeşitleri ise erkek anaç olduklarından dolayı sadece salkım ve buna bağlı olarak da meyve görüntüleri şekilde gösterilmemiştir. Belirtilen bu altı üzüm çeşidi derin öğrenme yöntemiyle sisteme yaprak özellikleri kullanılarak öğretilmiştir.

3.1.2. Çalışmada kullanılan teknik cihazlar

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. Üzüm çeşitlerinin belirlenmesinde gerekli olan görüntüleri elde edebilmek için ise GoPro marka Hero 7 Black Model kamera (Şekil 15) ve kamera çözünürlüğü iyi olan akıllı telefonlar kullanılmıştır.



Şekil 15. Görüntülerin alındığı GoPro Hero 7 Black Model kamera

Kullanılan kameranın özellikleri aşağıda belirtilmiştir.

- ❖ Görüntü İşlemcisi: GoPro GP1
- ❖ Sensör Tipi: CMOS
- ❖ Etkin Piksel: 12 MP
- ❖ Azami Çözünürlük: 4000x3000
- ❖ Görüntü Oranı: 4:3

- ❖ Sensör Formatı: 1/2.3 inch
- ❖ Sensör Boyutu (Gen): 6.17 mm
- ❖ Sensör Boyutu (uzun.): 4.62 mm
- ❖ En Düşük ISO: 100
- ❖ En Yüksek ISO: 6400
- ❖ Optik İmaj Sabitleme
- ❖ Wi-Fi Özelliği bulunmaktadır.

Kullanılan akıllı telefon özellikleri aşağıda belirtilmiştir.

- ❖ İşletim Sistemi: Android
- ❖ İşlemci Türü: Exynos 7080
- ❖ İşlemci Hızı: 1.90 GHz
- ❖ İşlemci Sayısı: 8 Çekirdek
- ❖ Etkin Piksel: 16 MP
- ❖ Ekran Çözünürlüğü: 1920*1080
- ❖ Piksel Yoğunluğu: 424 PPI
- ❖ Çözünürlük: Full HD
- ❖ Video FPS Değeri: 30 fps
- ❖ Ekran Boyutu: 5.2 inch
- ❖ Ekran Renk: 16 Milyon

3.1.3. Çalışmada kullanılan yazılım programı

MATLAB yazılım programı MATrix LABoratory' nin ilk üç harfleri alınarak adlandırılan bir programdır. Mühendislik çalışmalarının, hesaplama işlemlerinin ve simülasyon uygulamalarının çoğunun gerçekleştirildiği matris ve matematik tabanlı karmaşık bir yapıya sahiptir. Her türlü grafiksel işlemlerin sonuçları istenildiği şekilde alınabildiğinden dolayı çok geniş kullanım alanı bulunmaktadır (Ensari ve Özpolat, 2002). MATLAB programı bilgisayarlarda bulunan ekran kartlarının gücünden daha iyi yararlanmak için CUDA (Compute Unified Device Architecture) teknolojisini kullanmaktadır. CUDA bilgisayarların işlem platformuna büyük oranda katkısı olan bir

NVIDIA ekran kartı teknolojisidir. Birçok programlama dili ile geliştirilen algoritmaların grafik işlem birimlerinde çalışmasına yardımcı olmaktadır. MATLAB gibi yazılım programları CUDA teknolojisi sayesinde GPU üzerinde çalışarak CPU'nun daha az yıpranmasını sağlamaktadır. CUDA teknolojisiyle uyumlu olarak geliştirilen yazılım programları GPU'nun gücünden faydalanarak çalıştırılabilmektedir. CUDA yüksek performans gerektiren uygulamalarda kullanıcılara büyük faydalar sağlamaktadır (Anonim, 2022d).

Matematiksel hesaplama işlemleri, algoritma geliştirme ve kod yazma, lineer, cebir, istatistik, fourier analiz, filtreleme, optimizasyon, sayısal integrasyon vb. alanlarda matematik fonksiyonlar oluşturma gibi temel kullanım alanları bulunmaktadır (Anonim, 2022e). MATLAB programı aynı zamanda derin öğrenme sınıflandırması için bir CNN modelinin nasıl oluşturulacağını ve eğitileceğini de göstermektedir.

Sınıflandırma doğruluk oranlarının elde edilmesinde MATLAB programlama dili kullanılmıştır. Derin öğrenme ağı modelinin oluşturulmasında MATLAB programlama dilinin, sınıflandırma için örnek model olarak sunduğu şablon, veri setimize uygun model duruma getirilerek bir CNN modeli oluşturulmuştur. Daha sonra bu modele görüntüler yüklenerek tanıtılmıştır. Ağ mimarisi tanımlandıktan sonra eğitim seçenekleri belirtilerek ağ eğitilmiştir. Etiketli görüntülerin tahminleri yapılarak sınıflandırma doğruluk oranları sonuçları MATLAB programında elde edilmiştir.

3.2. Yöntem

Yöntem; veri toplama, veri kümesi oluşturma, veri seti oluşturma, etiketleme işlemleri ve karar verme aşaması olmak üzere beş başlıkta gerçekleştirilmiştir. Üzüm çeşitlerinin ampelografik özelliklerinin belirlenmesinde kullanılan yöntem, ampelografik araştırmalarda uluslararası yöntem birliği sağlamak için Uluslararası Bitki Gen Kaynakları Enstitüsü (The International Plant Genetic Resources Institute- IPGRI) adına oluşturulmuş bir araştırma ekibi tarafından Bağcılık ve Şarapçılık Ofisi (Office International de la Vigne Vigne et du Vin-OIV) ve Uluslararası Yeni Bitki Çeşitlerinin Korunması Birliği (International union for the Protection of New Varieties of Plants-UPOV) ile birlikte oluşturulan araştırmalarla geliştirilen normlar Üzüm Tanımlayıcıları (Grape Descriptors) adı şeklinde yayınlanmıştır. Üzüm tanımlayıcıları birbirini tamamlayan iki karakterdeki tanımlama sisteminden oluşmaktadır. Bu sistemlerden ilki

Tanımlama ve Ön Değerlendirme Verileri (Characterisation and Preliminary Evaluation Date)' vegetatif ve bitkisel özelliklerdir. Bu sistem çiçek ve meyve özellikleri ile birlikte çekirdeklere ait özelliklerin araştırılmasını konu edinmektedir.

İkinci sistem ise İleri Tanımlama ve Değerlendirme (Further Characterisation and Evaluation)'dir. Özelliklerin daha ayrıntılı biçimde ele alındığı bu sistemde, asmanın sıcaklık değişimlerine, kurağa, neme, toprak tuzluluğuna ve demir klorozuna duyarlılığı, hastalıklara ve zararlılara dayanma gücü ile bazı stolojik karakterler incelenmektedir. Üzüm çeşitlerinin ampelografik özelliklerinin belirlenmesi amacıyla yapılan çalışmalarda, bu iki sistemdeki kriterler kullanılmaktadır.

Çalışmada yukarıda adı geçen sistemlerden birincisi olan Tanımlama ve Ön Değerlendirme Verilerine (Characterisation and Preliminary Evaluation Data) ait kriterler kullanılarak ampelografik özellikleri belirlenen elli adet üzüm çeşidi ve ampelografik özellikler belirlenirken Descriptors for Grapevine (Vitis spp.) listesinin 6. bölümündeki bitki tanımlayıcılarından olan bitkisel özellikler kullanılmıştır.

Çizelge 2'de IPGRI tarafından oluşturulan Descriptors for Grapevine (Vitis spp.) listesinin 6. bölümündeki bitki tanımlayıcılarından olan ampelografik özellikler gösterilmektedir. Çizelgede; genç sürgün, sürgün, genç yaprak, olgun yaprak, odunsu sürgün, çiçek, salkım, meyve ve çekirdek özelliklerine ait toplam elli sekiz karakterizasyon özellik bulunmaktadır. Bunlardan kırk iki tanesi bitkisel (vegetatif) döneme, on altı tanesi ise çiçeklenme ve meyve dönemine ait karakterizasyon özelliklerdir. Bu özellikler çizelgede sayısal ve sözel olarak gösterilmektedir. Her bir özelliğe karşılık gelen ve sözel olarak ifade edilen karakterizasyon özelliğin 0 ile 9 arasında karşılık geldiği sayısal bir tanımı bulunmaktadır.

Çizelge 2. Ampelografik özellikler

Bitki Tanımlayıcıları Karakterizasyon özellikleri (Descriptors for Grapevine listesi 6. Bölüm)										
Karakterizasyon özellikler	Özellik no:									
	0	1	2	3	4	5	6	7	8	9
6.1.1. Genç sürgün: uç şekli		Kapalı	Biraz açık	Yarı açık	Geniş açık	Tam açık				
6.1.2. Genç sürgün: Uçtaki antosiyanin renklendirmesi	Yok	Çok zayıf		Zayıf		Orta		Güçlü		Çok güçlü
6.1.3. Genç sürgün: sivri uçtaki yatık tüylerinin yoğunluğu	Yok	Seyrek		Çok seyrek		Orta		Yoğun		Çok yoğun
6.1.4. Genç sürgün: uçtaki dik tüylerin yoğunluğu	Yok	Çok seyrek		Seyrek		Orta		Yoğun		Çok yoğun
6.1.5. Sürgün: Duruş şekli		Dik		Yarı dik		Yatay		Yarı sarkık		Sarkık
6.1.6. Sürgün: Boğumlar arası sırt tarafının rengi		Yeşil	Kırmızı ve Yeşil çizgili	Kırmızı						
6.1.7. Sürgün: Boğumlar arası karın tarafının rengi		Yeşil	Kırmızı ve Yeşil çizgili	Kırmızı						
6.1.8. Sürgün: Boğum sırt tarafının rengi		Yeşil	Kırmızı ve Yeşil çizgili	Kırmızı						
6.1.9. Sürgün: Karın tarafının rengi		Yeşil	Kırmızı ve Yeşil çizgili	Kırmızı						
6.1.10. Sürgün: Boğumdaki dik tüylerin yoğunluğu	Yok	Çok seyrek		Seyrek		Orta		Yoğun		Çok yoğun

Çizelge 2. (Devam) Ampelografik Özellikler

6.1.11. Sürgün: Boğum arası dik tüy varlığı	Yok	Mevcut								
6.1.12. Sürgün: Boğumdaki yatık tüylerin yoğunluğu	Yok	Çok seyrek				Orta				Çok yoğun
6.1.13. Sürgün: Boğum arası yatık tüylerin yoğunluğu	Yok	Çok seyrek				Orta				Çok yoğun
6.1.14. Sürgün: Filiz dizilişi		İkiye kadar	Üç ve üzeri							
6.1.15. Sürgün: Filiz uzunluğu		Çok kısa (<11 cm)		Kısa (14-16 cm)		Orta Boy (19-21 cm)		Uzun (24-26 cm)		Çok uzun (>30 cm)
6.1.16. Genç yaprak: üst yüzey rengi		Yeşil	Bronz benekli yeşil	Sarı	Sarı bronz	Bakır sarı	Bakır	Kırmızımsı		
6.1.17. Genç yaprak: Yatık tüylerin damarlar arasındaki yoğunluğu	Yok	Çok seyrek		Seyrek		Orta		Yoğun		Çok yoğun
6.1.18. Genç yaprak: Dik tüylerin damarlar arasındaki yoğunluğu	Yok	Çok seyrek		Seyrek		Orta		Yoğun		Çok yoğun
6.1.19. Genç yaprak: Ana damarlardaki yatık tüylerin yoğunluğu	Yok	Çok seyrek		Seyrek		Orta		Yoğun		Çok yoğun
6.1.20. Genç yaprak: Ana damarlardaki dik tüylerin yoğunluğu	Yok	Çok seyrek		Seyrek		Orta		Yoğun		Çok yoğun
6.1.21. Olgun yaprak: Boyutu		Çok küçük		Küçük		Orta		Büyük		Çok büyük
6.1.22. Olgun yaprak: Şekli		Kalp şekilli	Kama şekilli	Beşgen	Dairesel	Böbrek şekilli				
6.1.23. Olgun yaprak: Dilim sayısı		Tüm yaprakta	Üç tane	Beş tane	Yedi tane	Yediden fazla				
6.1.24. Olgun yaprak: Ana damarların antosiyanin renklenmesi	Yok	Çok zayıf		Zayıf		Orta		Güçlü		Çok güçlü

Çizelge 2. (Devam) Ampelografik Özellikler

6.1.25. Olgun yaprak: profil		Dairesel	V şekinde	Yukarı kvrık	Aşağı kvrık	Dalgalı				
6.1.26. Olgun yaprak: Yaprak üst yüzeyinin kabarması	Yok	Çok zayıf		Zayıf		Orta		Güçlü		Çok güçlü
6.1.27. Olgun yaprak: dişlerin şekli		İki tarafta içbükey	İki tarafta düz	İki tarafta dışbükey	Bir tarafta içbükey, bir	Her iki tarafın düz karışımı				
6.1.28. Olgun yaprak: dişlerin uzunluğu		Çok kisa		Kısa		Orta		Uzun		Çok uzun
6.1.29. Olgun yaprak: dişlerin boy/en oranı		Çok küçük		Küçük		Orta		Büyük		Çok büyük
6.1.30. Olgun yaprak: yaprak sapı oyuğunun genel şekli		Çok geniş açık	Geniş açık	Yarı açık	Biraz açık	Kapalı	Hafif dilimler	Zayıf dilimler	Kuvvetli dil.	Çok kuvvetli d
6.1.31. Olgun yaprak: yaprak sapı oyuğundaki dişler	Yok	Mevcut								
6.1.32. Olgun yaprak: Damarlarla sınırlı yaprak sapı oyuğu	Yok	Mevcut								
6.1.33. Olgun yaprak: üst yanal boşluk şekli		Açık	Kapalı	Hafif dilimler	Kuvvetli dilimler					
6.1.34. Olgun yaprak: üst yanal boşluğun derinliği		Çok sığ		Sığ		Orta		Derin		Çok derin
6.1.35. Olgun yaprak: yatık tüylerin yoğunluğu	Yok	Seyrek		Çok seyrek		Orta		Yoğun		Çok yoğun
6.1.36. Olgun yaprak: Ana damarlar arasındaki dik tüylerin yoğunluğu	Yok	Seyrek		Çok seyrek		Orta		Yoğun		Çok yoğun
6.1.37. Olgun yaprak: Ana damarlar arasındaki yatık tüylerin yoğunluğu	Yok	Seyrek		Çok seyrek		Orta		Yoğun		Çok yoğun
6.1.38. Olgun yaprak: Ana damarlar üstündeki dik tüylerin yoğunluğu	Yok	Seyrek		Çok seyrek		Orta		Yoğun		Çok yoğun


Çizelge 2. (Devam) Ampelografik Özellikler

6.1.39. Olgun yaprak: Ana damarlar üstündeki yatık tüylerin yoğunluğu	Yok	Mevcut								
6.1.40. Olgun yaprak: Yaprak sapının orta damara oranı		Çok daha	Biraz daha kısa	Eşit	Biraz daha	Çok daha uzun				
6.1.41. Odunsu sürgün: yüzey		Pürüzsüz	Kenarlı (açısal)	Çizgili	Kirışlı					
6.1.42. Odunsu sürgün: ana renk		Sarı	Sarımsı kahverengi	Koyu kahverengi	Kırmızımsı kahverengi	Menekşe				
6.2.1. Çiçeklenme: çiçeğin cinsiyeti		Sadece erkek	Ağırlıklı erkek	Tamamen gelişmiş erkek	Düz organlarındaki	Reflekslenmiş organlarındaki dışı				
6.2.2. Salkım: boyut		Çok küçük		Küçük		Orta		Büyük		Çok büyük
6.2.3. Salkım: yoğunluk		Çok gevşek		Gevşek		Orta		Yoğun		Çok yoğun
6.2.4. Salkım: sap uzunluğu		Çok kısa		Kısa		Orta		Uzun		Çok uzun
6.2.5. Meyve: boyut		Çok küçük		Küçük		Orta		Büyük		Çok büyük
6.2.6. Meyve: şekli		Dikdörtgen	Dar eliptik	Eliptik	Yuvarlak	Kutupları yassılaşmış	Yumurtamsı	Kalın kafalı-oval	Obovat	Kavisli
6.2.7. Meyve: çekirdek varlığı		Çekirdeksiz	Tam gelişmemiş	İyi gelişmiş						
6.2.8. Meyve: ten rengi		Yeşil-sarı	Gül pembesi	Kırmızı	Kırmızı- gri	Koyu kırmızı- mor	Mavi- siyah			
6.2.9. Meyve: etinin rengi		Çok hafif renkli		Biraz renkli		Renkli		Şiddetle renkli		Çok güçlü
6.2.10. Meyve: etin sulu olması		Çok hafif	Biraz sulu	Çok sulu						

Çizelge 2. (Devam) Ampelografik Özellikler

6.2.11. Meyve: etin sertliği		Yumuşak	Orta	Sert						
6.2.12. Meyve: Tat özelliği	Yok	Muscat	Ekşi							
6.2.13. Meyve: saptan ayrılma kolaylığı		Zor	Biraz kolay	Çok kolay						
6.2.14. Meyve: Çekirdek uzunluğu				Kısa		Orta		Uzun		
6.2.15. Çekirdek: 100 tane ağırlığı		Çok düşük		Düşük		Orta		Yüksek		Çok yüksek
6.2.16. Çekirdek: yandan enine oluklar	Yok	Mevcut								

Şekil 16'da belirtilen ampelografik özelliklerin görselleri ve çalışmaya konu olan yaprak profili, yaprak dış şekli, salkım ve meyve görselleri bulunmaktadır.



Şekil 16. Ampelografik özelliklerin bazı görselleri

Şekil 16’da yer alan sayısal değerlerin karşılığı, ayrıca Çizelge 2’de açıklanmaktadır. Örneğin; Yaprak şekli için 1 değeri kalp şekilli olarak ifade edilmektedir.

3.2.1. Veri toplama

Verilerin toplanmasında görüntüleme işlemleri doğal aydınlanma ortamında gerçek zamanlı olarak yapılmıştır. Her bir çeşit için görüntü alma işleminde en az üç omca kullanılmıştır. Görüntülerin yetersiz olduğu durumlarda ise aynı sıra üzerinde aynı çeşidin tekrerrür eden diğer üç omcasından görüntüler alınmıştır. Görüntüler alınırken bitkinin sınırlı bir alanına bağlı kalınmamış, omcanın her tarafı kullanılmaya çalışılmıştır.

3.2.2. Veri kümesi oluşturma

Çizelge 3’te görüntüsü alınan üzüm çeşitleri ve sayısı, bu çeşitlere ait özellikler ve bu özelliklerden elde edilen görüntü sayıları gösterilmektedir. Hücrelerde, bir çeşidin bir özelliğine ait görüntü sayısı verilmektedir (Ör; Narince üzüm çeşidinin, salkım görüntüsü). Satır sonu toplamalarda, bir çeşide ait bütün özelliklerin (çiçek, sürgün, genç yaprak, olgun yaprak, salkım, meyve ve odunsu sürgün) toplam görüntü sayısı gösterilmektedir. Sütun sonu toplamalarda ise, bütün çeşitlerden alınan bir özelliğe ait toplam görüntü sayısı gösterilmektedir. Genel toplamda ise; elde edilen toplam görüntü sayısı yani tüm özelliklerin görüntü sayısı ve tüm çeşitlerin görüntü sayısı gösterilmektedir. Tüm çeşitlerin özelliklerinden toplamda 48 946 görüntü elde edilmiştir.

Çizelge 3. Üzüm çeşitlerinden alınan görüntü sayısı (Veri kümesi)

Genotipler (Üzüm çeşitleri)		Görüntü sayısı (Özellikler)							Genel Toplam
		Çiçek	Sürgün	Genç yaprak	Olgun yaprak	Salkım	Meyve	Odunsu sürgün	
1	Crimson seedlees	110	102	115	186	197	197	185	1 092
2	Bilecik karası	107	103	112	185	201	200	103	1 011
3	Michele palieri	105	105	113	191	204	205	213	1 136
4	Tekirdağ çekirdeksizi	102	108	115	197	203	202	128	1 055
5	Lival	111	112	105	197	197	197	115	1 034
6	Trakya ilkeren	106	110	102	197	199	200	110	1 024
7	Karaerik	112	104	104	186	199	199	115	1 019
8	Flame seedlees	101	113	108	188	203	200	110	1 023
9	Horoz karası	103	108	110	189	202	201	112	1 025
10	Royal	105	106	107	199	196	195	110	1 018
11	Alphonse L.	107	103	109	194	206	205	105	1 029

Çizelge 3. (Devam) Üzüm çeşitlerinden alınan görüntü sayısı (Veri kümesi)

12	Prima	109	101	110	194	197	197	110	1 018
13	Cardinal	110	111	111	196	197	197	105	1 027
14	Superior seedlees	113	105	112	192	196	195	105	1 018
15	Victoria	104	114	116	200	197	196	105	1 032
16	Red globe	102	112	105	190	194	195	101	999
17	Sultani çekirdeksiz	101	116	104	190	199	198	112	1 020
18	Mevlana	100	111	108	190	199	200	105	1 013
19	İtalia	105	110	106	188	198	197	100	1 004
20	İzabel	104	107	112	187	199	198	105	1 012
21	Vakkas	110	105	110	196	195	195	100	1 011
22	Erçiş	106	105	110	189	197	197	100	1 004
23	Pinot noir	102	103	109	203	199	199	100	1 015
24	Abalıhoca	104	100	104	204	194	195	100	1 001
25	Hasandede	113	109	102	197	199	198	105	1 023
26	Cabarnet france	109	113	103	197	-	-	100	622
27	Syrah	107	117	108	217	196	195	110	1 050
28	Cabarnet sauvignon	106	111	110	198	197	197	105	1 024
29	Kyoho	103	110	111	205	199	198	107	1 033
30	Corinth	102	108	113	191	214	210	108	1 046
31	Merlot	111	107	116	205	206	205	110	1 060
32	Rup. Du. Lot.	107	102	103	202	-	-	105	619
33	Narince	105	106	104	184	207	205	107	1 018
34	1103 Paulsen	102	109	107	201	-	-	108	627
35	Muhammediye	109	110	102	197	199	200	105	1 022
36	Helvani	106	113	108	201	-	-	107	635
37	Çavuş	104	101	112	200	201	200	106	1 024
38	110R	108	112	106	197	-	-	105	628
39	Tayfi	105	112	102	197	200	200	102	1 018
40	Black magic	105	114	104	203	198	198	120	1 042
41	Bronx seedlees	102	103	105	201	196	195	100	1 002
42	Autumn royal	104	102	106	205	200	200	105	1 022
43	Yalova incisi	109	103	112	207	195	194	105	1 025
44	41B	110	101	108	207	199	199	100	1 024
45	5BB	113	104	105	205	-	-	110	637
46	Regent	112	106	109	200	192	192	118	1 029
47	Rizessi	109	104	113	204	191	190	100	1 011
48	Kısmış vatkana	111	105	111	203	193	190	117	1 030
49	Rizellim	105	108	109	205	200	200	101	1 028
50	Rizpem	104	106	110	197	195	195	100	1 007
Genel Toplam		5 320	5 370	5 416	9 854	8 745	8 721	5 520	48 946

Çizelge 3’te gösterilen 5BB, 110R ile Cabernet france ve Helvani üzüm çeşitlerinin salkım görüntüleri araştırma yapılan alanlarda bulunamadığı için ve 1103 Paulsen ile Rup. Du.Lot. çeşitleri de erkek anaç oldukları için salkım görüntüleri elde edilememiştir. Bu çeşitlerin diğer bütün özelliklerinin görüntüleri elde edilmiştir.

3.2.3. Veri seti oluşturma

Büyük veriler arasından istenilen veriyi zamanı ve yeri geldiğinde, hızlı ve etkin bir şekilde kullanabilmek problemlerin çözümü için önem arz etmektedir. Veri seti oluşturma aşamasında öncelikle elde edilen görüntülerden üzüm çeşitlerine ait karakterizasyon özellik işlemi yapılmıştır. Görüntüleri alınan özelliklerden çiçek, sürgün ve odunsu sürgün, uzman görüşü doğrultusunda veri kümesine konulmuş fakat derin öğrenme teknikleri açısından ayırt edici özellikte olmadıkları için veri seti hazırlamada kullanılmamıştır. Diğer özellikler ise; yaprak, salkım ve meyve olmak üzere gruplara ayrılmıştır.

Genç yaprak görüntülerinde, uzman görüşü doğrultusunda, görüntü işlemeye uygun olan sadece bir ampelografik özellik tespit edilmiş (ÜYR: Üst yüzey renklenmesi, elli çeşidin hepsinde de tespit edilerek ortaya çıkarılmıştır), tespit edilen bu ampelografik özellik ise çeşitlerde çok benzerlik gösterdiğinden ve modellerde ezberleme durumunun ortaya çıkmasından ve buna bağlı olarak başarı oranının düşmesinden dolayı, veri seti içerisine alınmış fakat etiketleme işleminde ayrı tutulmuştur. Bundan dolayı yaprak çeşitlerinde olgun yaprak ile çeşitlerin yaprak özelliklerinden tespiti yapılmıştır.

Salkım ve meyve birbirinden ayrı tutulamayacağı için salkım ve meyvede ayrı etiketleme işlemi yapılmış fakat eğitim modeline etiketli görüntüler aynı anda verilerek sonuçlar alınmıştır. Her bir veri sınıfı için elde edilen görüntüleri daha hızlı ve sisteme uygun bir şekilde kullanabilmek amacıyla veri çoğaltma, veri temizleme, yeniden boyutlandırma ve Çizelge 4’de gösterilen değerlere göre veri setlerinin etiketleme işlemleri yapıldıktan sonra elde edilen etiketli görüntüler kategorilere ayrılarak, yeni oluşturulan CNN modeline uygun veri seti oluşturulmuştur.

Descriptors for Grapevine (*Vitis spp.*) listesinde, yaprak karakterine ait toplamda yirmi beş tane ampelografik özellik bulunmaktadır. Çalışmada bu özellikler içerisinden dokuz tanesinin sınıflandırma işlemine uygun olduğu uzman görüşü doğrultusunda tespit edilerek seçilmiştir. Seçilen bu dokuz özellik içerisinden ise, modellemelerde

ezberlemenin önüne geçilebilmesi ve başarı oranının artırılması için, benzerlik oranı yüksek olan özellikler ayrı tutularak, etiketlemede yaprak dış şekli (DŞ) ve yaprak profili (P) olmak üzere iki tane özellik kullanılmıştır. Bu durum meyve ve salkım özelliklerinde de uygulanmıştır.

Descriptors for Grapevine (*Vitis spp.*) listesinde, meyve ve salkım karakterlerine ait toplam on üç tane ampelografik özellik bulunmaktadır. Bu özelliklerden yukarıda belirtildiği gibi sınıflandırma işlemine uygun olan salkım yoğunluğu (SY) ve meyve şekli (MŞ) seçilip etiketleme işlemlerinde kullanılarak veri setleri oluşturulmuştur. Veri setinde bulunan ve çalışmaya konu olan elli adet üzüm çeşidi özelliklerinin (yaprak, meyve ve salkım) Descriptors for Grapevine (*Vitis spp.*) listesinin 6. bölümündeki bitki tanımlayıcılarından olan, bitkisel özelliklere göre belirlenen ve etiketleme işleminde etiket kodu olarak kullandığımız ampelografik özellikler Çizelge 4’de sayısal olarak gösterilmektedir.

Çizelge 4. Üzüm çeşitlerinin yaprak ve salkım/meyve ampelografik özellikleri

Üzüm çeşitleri		Kod (ID) / Karakterizasyon özellik			
		Yaprak		Salkım/Meyve	
		P	DŞ	SY	MŞ
1	Crimson seedlees	3	1	5	5
2	Bilecik karası	5	2	7	6
3	Michele palieri	3	2	5	5
4	Tekirdağ çekirdeksizi	5	5	5	8
5	Lival	2	3	7	5
6	Trakya ilkeren	1	3	5	4
7	Karaerik	1	2	7	7
8	Flame seedlees	5	4	5	4
9	Horoz karası	5	3	5	7
10	Royal	5	3	5	8
11	Alphonse L.	5	3	7	8
12	Prima	1	2	5	6
13	Cardinal	5	5	3	4
14	Süperior seedlees	1	3	5	5
15	Victoria	1	3	3	7
16	Red globe	1	5	5	4
17	Sultani çekirdeksiz	1	1	3	5
18	Mevlana	1	3	5	7
19	İtalia	5	5	5	2
20	İzabel	2	3	7	4
21	Narince	2	3	7	4
22	Vakkas	5	1	7	6

Çizelge 4. (Devam) Üzüm çeşitlerinin yaprak ve salkım/meyve ampelografik özellikleri

23	Erciş	3	4	9	6
24	Pinot noir	5	2	7	8
25	Abalıhoca	3	4	9	6
26	Hasandede	5	1	7	8
27	Cabernet france	5	3	-	-
28	Syrah	5	3	9	8
29	Cabernet sauvignon	5	3	5	8
30	Kyoho	2	2	3	4
31	Corinth	1	3	5	4
32	Merlot	5	2	5	8
33	Rub. Du. Lot.	2	2	-	-
34	1103 Paulsen	1	3	-	-
35	Muhammediye	2	3	5	1
36	Helvani	2	2	-	-
37	Çavuş	2	4	7	1
38	110R	2	3	-	-
39	Tayfi	5	4	5	7
40	Black magic	1	3	7	7
41	Bronx seedlees	5	3	7	1
42	Autumn royal	5	5	5	6
43	Yalova incisi	1	5	7	2
44	41B	1	3	5	4
45	5BB	1	3	-	-
46	Regent	1	3	5	8
47	Rizessi	1	3	7	8
48	Kısmışh vatkana	5	5	5	8
49	Rizellim	3	5	7	5
50	Rizpem	5	2	7	8

Çizelgede: *P* (Profil), *DŞ* (Dişlerin şekli), *SY* (Salkım yoğunluğu), *MŞ* (Meyve şekli)

Çalışmada üzüm çeşitleri yaprak ve salkım/meyve özellikleri ile iki ayrı şekilde sisteme öğretildiği için; veri seti, yaprak veri seti ve salkım/meyve veri seti olmak üzere iki gruba ayrılmıştır. Üzüm çeşitlerinin yapraklarında ve salkım-meyvelerinde özellikler birbirine çok yakın benzerlik gösterdiğinden dolayı, ezberlemenin önüne geçilebilmesi için sınıflandırma yapılırken tek grupta elli adet sınıf kullanmak yerine, çeşitler arasından rastgele seçim yapılarak, yaprak grubunda beş farklı kategori ve salkım-meyve grubunda ise dört farklı kategori olmak üzere toplamda dokuz farklı kategori kullanılmıştır.

Yaprak görüntülerinin bulunduğu beş farklı kategorinin her biri on sınıftan oluşurken, salkım/meyve görüntülerinin bulunduğu dört farklı kategorinin her biri on bir sınıftan oluşmaktadır. Bu şekilde üzüm çeşitlerinin sisteme öğretilmesinde toplam doksan dört

sınıfın kullanıldığı bir veri seti oluşturulmuştur. Her bir veri sınıfı için elde edilen görüntüleri daha hızlı ve sisteme uygun bir şekilde kullanabilmek amacıyla veri çoğaltma, veri temizleme, yeniden boyutlandırma ve normalize edilme gibi işlemler yapıldıktan sonra veri setlerinde etiketleme işlemleri yapılmıştır.

3.2.4. Etiketleme işlemleri

Oluşturulan veri setleri, yeni geliştirilen CNN modelinde eğitilebilmesi için veriler üzerinde etiketleme işlemleri yapılması gerekmektedir. Çizelge 5’te çalışmada kullanılan etiketleme yöntemi, Crimson seedlees ve Royal üzüm çeşitleri üzerinde örnek olarak gösterilmektedir. Etiketleme işlemlerinde yaprak profili (P), yaprak dış şekli (DŞ), meyve şekli (MŞ) ve salkım yoğunluğu (SY) karakterizasyon özellikleri kullanılmıştır.

Etiket kodları oluşturulurken;

İki isimden oluşan çeşitlerin etiketlenmesinde, isimlerinin baş harfleri, kullanılan karakterizasyon özellik ve bu özelliğe ait ampelografik özellikler (Çizelge 4) kullanılmıştır. Örneğin; Crimson seedlees profil kodu için CSP3.

Tek isimden oluşan çeşitlerin etiketlenmesinde ise isimlerinin sessiz harfleri, kullanılan karakterizasyon özellik ve bu özelliğe ait ampelografik özellikler kullanılmıştır. Örneğin; Royal profil kodu için RYLP5.


Çizelge 5. Etiketleme yöntemi

		Karakterizasyon Özellik			
		Yaprak		Salkım/meyve	
		P	DŞ	MS	SY
Sınıf adı	Crimson seedlees	CSP3	CSDS1	CSMS5	CSSY5
	Royal	RYLP5	RYLDS3	RYLMS5	RYLSY8
Etiket Kodu (ID)					

Etiketleme yöntemi belirlendikten sonra MATLAB 2021a platformuna sahip bilgisayarda, görüntüler yaprak profili, yaprak dış şekli, meyve şekli ve salkım yoğunluğu karakterleri ile etiketlenmiş ve CNN modelinde eğitim ve test için uygun veri setine

dönüştürülmüştür. Etiketleme işlemlerinde kullanılan ve derin öğrenme modellerine uygun olan yaprak, salkım ve meyve özelliklerine ait toplamda 27 320 görüntü bulunmaktadır. Bu görüntüler üzerinde yaklaşık olarak 70 000 adet etiketleme işlemleri yapılmıştır. Oluşturulan etiketler, yapılan yazılımla ortaya çıkarılan derin öğrenme modellerine öğretilerek sonuçlar elde edilmiştir.

Yukarıdaki etiketleme yöntemine göre Crimson seedlees ve Royal üzüm çeşitlerinin etiketlenmiş görüntüleri Şekil 17’de gösterilmektedir. Bu yöntem çalışmamıza konu olan bütün üzüm çeşitlerinin etiketleme işlemlerine uygulanmıştır.




Şekil 17. Crimson seedlees ve Royal çeşitlerinin yaprak ve salkım/meyve etiketli görüntüleri

Şekil 17’de sırasıyla: CSP3: *Crimson seedlees* yaprak profili, CSDS1: *Crimson seedlees* yaprak dış şekli, CSMS5: *Crimson seedlees* meyve şekli, CSSY5: *Crimson seedlees* salkım yoğunluğu, RYLP5: *Royal* yaprak profili, RYLD3: *Royal* yaprak dış şekli, RYLS8: *Royal* meyve şekli, RYLSY5: *Royal* salkım yoğunluğu bulunmaktadır.

3.2.5. Karar verme

Karar verme aşamasında derin öğrenme modellerinden yeni ve özgün olarak geliştirilen CNN modeli ile ön eğitilmiş GoogleNet ve AlexNet modelleri kullanılmıştır. AlexNet ve GoogleNet ön eğitilmiş modeller olduğundan dolayı bu modellerin çıkış katmanları değiştirilerek veri setlerine uygun olan kişiselleştirilmiş modeller meydana getirilebilmektedir. Çalışmada yeni oluşturulan modelin yanı sıra transfer öğrenme yöntemi kullanılarak AlexNet ve GoogleNet modellerinin çıkış katmanları veri setimize uygun olacak şekilde değiştirilerek eğitilmiştir.

Şekil 18’de çalışmada kullanılan yeni ve özgün olarak geliştirilen 15 katmanlı CNN modelinin genel mimari yapısı gösterilmektedir.



Şekil 18. Yeni ve özgün olarak geliştirilen CNN modelinin genel mimari yapısı

Çalışmada üzüm çeşitlerinin sınıflandırılması için yeni ve özgün olarak geliştirilen ve bir giriş katmanı, üç konvolüsyon katmanı, üç toplu normalleştirme katmanı, üç ReLU katmanı, iki havuzlama katmanı, bir tam bağlantılı katman, bir softmax katmanı ve bir sınıflandırma katmanı olmak üzere toplam 15 katmandan oluşan bir CNN modeli kullanılmıştır.

CNN modelinde sınıflandırma için yapılan işlemler

Görüntü verilerinin sisteme yüklenmesi ve gösterilmesi

İlk olarak çeşitlerin örnek verileri bir görüntü veri deposu olarak yüklenmektedir. Bu işlemin amacı, belleğe sığmayan veriler de dahil olmak üzere büyük görüntü verilerinin depolanmasına ve CNN modelinin eğitimi sırasında görüntü yığınlarının verimli bir şekilde okunmasına kolaylık sağlamaktır. Veri deposu yüklendikten sonra rastgele bazı görüntülerin sistem tarafından gösterilmesi sağlanmaktadır. Veri deposunda bulunan her bir dosyada ne kadar görüntü olduğu hesaplatılarak, etiketleri ve etiketlere ait görüntü sayılarını içeren tablo komutu oluşturulmaktadır.

Çalışmadaki veri setinde toplam 27 320 adet etiketli görüntü bulunmaktadır. Oluşturulan komutla, kaç sınıf ve her sınıfta ne kadar görüntü olduğu hesaplatılarak sistemde gösterilmektedir. Bununla birlikte ağın son tam bağlı katmanındaki sınıfların sayısı da belirtilebilmektedir. Verilerin yüklenmesi sırasında görüntülerin boyutları da sistemin kabul ettiği eşit boyutta olacak şekilde boyutlandırılmaktadır.

Çalışmada görüntüler 227x227x3 şeklinde boyutlandırılmıştır. Veriler eğitim ve doğrulama seti olarak sistem tarafından ikiye ayrılmaktadır. Bir komutla eğitim ve doğrulamada ne kadar görüntünün kullanılacağı sisteme öğretilmektedir. Görüntülerin %80'i eğitim için %20'si ise doğrulama için ayrılmıştır. Örneğin bin adet görüntüden sekiz yüzü eğitim iki yüzü doğrulama verisi şeklinde ayarlanmaktadır.

Ağ mimarisinin tanımlanması

Sistemde hangi mimari kullanılacaksa o mimari tanımlanmaktadır. Çalışmada CNN mimarisi kullanılmaktadır. CNN'nin katmanları oluşturulan modele göre adım adım ayarlanarak ağ mimari yapısının tanımlanması gerçekleştirilmiştir. Katmanlar; *Görüntü Giriş Katmanı*, *Toplu Normalleştirme Katmanı*, *ReLU Katmanı*, *Maksimum Havuzlama Katmanı*, *Tam Bağlantılı Katman*, *Softmax Katmanı* ve *Sınıflandırma Katmanı* şeklinde tanımlanmıştır.

Eğitim seçeneklerinin belirtilmesi

Ağ yapısının tanımlanmasından sonra eğitim seçenekleri belirtilmiştir. Model eğitiminde öğrenme oranı deneme yoluyla belirlenmiştir. Öğrenme oranları 0.1 ve 0.0001 aralığında veri setine uygulanmış ve en iyi model başarısının 0.1 öğrenme oranı ile elde edildiği tespit edilerek öğrenme oranı 0.1 olarak ağ eğitilmiştir. Doğrulama veri seti kullanılarak devir (epoch) sayısı da deneme yoluyla belirlenmiştir. Doğrulama veri setine model eğitiminde kullanılan 42 devir sayısının altında ve üstünde birçok değer uygulanarak model eğitilmiş en iyi başarı oranı 42 devir sayısında elde edildiği için devir sayısı her sınıf için 42 olarak ayarlanmıştır.

Doğrulama frekans sayısı ise aynı şekilde deneme yoluyla tespit edilerek 23 olarak ayarlanmıştır. Bütün eğitim setinde bir devir, tam bir eğitim döngüsüne karşılık gelmektedir. Her devirde veriler karıştırılmaktadır. Yazılım programı eğitim verileri ile ağı eğiterek eğitim sırasında düzenli aralıklarla doğrulama verilerinin doğruluğunu hesaplamaktadır. Bu sırada eğitim ilerleme grafiği açılarak ekranda eğitimin ilerlemesi her devirde izlenebilmektedir.

Ağın eğitilmesi

Oluşturulan katmanlarda, eğitim verileri ve seçenekleri ile tanımlanan mimariyi kullanarak ağ eğitilir. Ağ eğitimi sırasında bir GPU ya da CPU kullanılmaktadır. Çalışmada kullanılan ağ CPU'lu bir bilgisayar ortamında eğitilmiştir.

Doğrulama görüntülerinin sınıflandırılması ve doğruluğunun hesaplanması

Eğitilmiş olan ağ kullanılarak doğrulama verilerinin etiketleri tahmin edilir ve elde edilen doğrulama oranı hesaplanır. Doğruluk, eğitilen ağın doğru olarak tahmin ettiği etiketlerin başarı oranıdır.

Doğruluğun hesaplanmasında kullanılan ölçüm yöntemleri

Doğruluk: Doğru tahminlerin (doğru pozitif ve doğru negatif) genel sonuca oranıdır. Doğruluk değeri formülü Eşitlik 1'de görülmektedir.

$$D = \frac{DP+DN}{DP+YP+YN+DN} \quad (1)$$

Hassasiyet: Tahmin edilen doğru pozitiflerin, pozitif tahmin edilen bütün sonuçlara oranıyla hesaplanır. Hassasiyet değeri formülü Eşitlik 2’de görülmektedir.

$$P = \frac{DP}{DP+YP} \quad (2)$$

Duyarlılık: Tahmin edilen doğru pozitiflerin, olması gereken bütün pozitiflere oranıyla hesaplanır. Duyarlılık değeri formülü Eşitlik 3’te görülmektedir.

$$R = \frac{DP}{DP+YN} \quad (3)$$

F1 Puanı: Yukarıdaki değerlerin harmonik ortalaması olarak hesaplanmaktadır. F1 Puanı değeri formülü Eşitlik 4’te görülmektedir.

$$F1 \text{ Puan} = 2x \frac{PxR}{P+R} \quad (4)$$

Sınıflandırma yapılırken birbiri arasında çok benzerlik gösteren üzüm çeşitlerinde ezberlemenin önüne geçilebilmesi için tek grupta elli adet sınıf kullanmak yerine, çeşitler arasından rastgele seçim yapılarak, yaprak görüntülerinde beş farklı kategori ve salkım-meyve görüntüleri ise dört farklı kategori olmak üzere toplamda dokuz farklı kategori kullanılmıştır. Yaprak görüntülerinin bulunduğu beş farklı kategorinin her biri on sınıftan oluşurken, salkım/meyve görüntülerinin bulunduğu dört farklı kategorinin her biri on bir sınıftan olmak üzere toplamda doksan dört sınıf kullanılmıştır. CNN modelinin başarısının değerlendirilmesinde kullanılan metrik yöntemler; Doğruluk, Hassasiyet, Duyarlılık ve F1 Puanı değerleri aşağıdaki çizelgelerde her sınıf için ayrı ayrı gösterilmektedir.

Çalışmada yukarıda anlatılan tüm bu model oluşturma basamakları gerçekleştirilerek yeni ve özgün bir CNN modeli oluşturulmuştur. Oluşturulan CNN modelinde görüntüler sisteme yüklenmiş ve ağ çalıştırılmıştır. Karar aşamasında ise modelin çalıştığı tespit edilmiştir. Oluşturulan her bir kategori için en az %80’in üzerinde hedeflenen başarı oranları ise bulgular kısmında gösterilmektedir.

4. BULGULAR ve TARTIŞMA

4.1. Bulgular

Çalışmada yeni ve özgün olarak geliştirilen CNN modeli, GoogleNet ve AlexNet modelleri ile elli adet üzüm çeşidinin yaprak ve salkım/meyve gruplarının karakterizasyon özellikleri kullanılarak bu üzüm çeşitlerinin sınıflandırılması yapıp elde edilen sonuçlar gösterilmiştir. Bu bölümde, derin öğrenme modellerinin performansını gösteren ve çalışmada hedeflenen yaprak ve salkım/meyve grupları için üç modele ait tahmin sınıfları ile gerçek sınıfların değerlerinin karşılaştırıldığı eğitim grafikleri, Başarım oranları, Karışıklık matrisi, Hassasiyet, Duyarlılık ve F1 Puan değerleri verilmiştir.


Yaprak grubunda beş kategori, her kategoride on sınıf ve salkım/meyve grubunda dört kategori, her kategoride on bir sınıf bulunmaktadır. Çizelgelerdeki sınıflar, kategorilerde açıklanan sıralamalardaki sayılarla gösterilmektedir. Akış diyagramlarında kullanılan parametrelere ait açıklamalar ise bulgular bölümünün sonunda verilmiştir.

4.1.1. Yaprak görüntülerine ait bulgular

Kategori 1

Sınıfları oluşturan çeşitler; 1. Bilecik irikarası, 2. Crimson seedlees, 3. Flame seedlees, 4. Horoz karası, 5. Karaerik, 6. Lival, 7. Michele palieri, 8. Royal, 9. Tekirdağ çekirdeksizi, 10. Trakya ilkeren.

Yaprak kategori 1 sınıflandırma doğruluk başarı oranı %82.50 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 19'da ve karışıklık matrisi ile performans değerleri Çizelge 6'da gösterilmektedir.



Şekil 19. Yaprak kategori 1 eğitim akış diyagramı

Çizelge 6. Yaprak kategori 1 karışıklık matrisi ve performans değerleri


		Tahmin										Hassasiyet	F1 Puanı
Sınıflar		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.		
Gerçek	1.	27	1	0	1	0	3	2	1	0	0	73	79
	2.	0	29	2	0	0	0	0	0	0	0	94	92
	3.	0	0	27	1	0	0	3	0	2	0	82	82
	4.	1	0	0	32	0	1	0	0	0	0	94	81
	5.	1	0	0	2	27	0	1	0	0	0	87	90
	6.	1	0	0	4	0	33	0	4	0	0	79	83
	7.	1	1	0	0	0	0	27	7	0	0	75	73
	8.	0	0	0	3	0	1	2	38	0	0	86	77
	9.	0	0	0	0	0	0	3	4	35	0	83	87
	10.	0	1	4	2	2	0	0	1	1	31	74	85
Duyarlılık		85	91	82	71	93	87	71	70	92	100	(%)	
DOĞRULUK												82.50	

Kategori 1 için Çizelge 6 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Crimson seedlees çeşidinde yaparken en düşük tahminini Trakya ilkeren çeşidinde yapmıştır. Genel toplamda ise 370 test görüntüsünden 306 görüntü doğru tahmin edilerek %82.50 sınıflandırma başarı oranı elde edilmiştir.

Kategori 2

Sınıfları oluşturan çeşitler; 1. Abalıhoca, 2. Alphonse L. 3. Cardinal, 4. Erciş, 5. Mevlana, 6. Narince, 7. Pinot noir, 8. Vakkas, 9. İtalia, 10. İzabel

Yaprak kategori 2 sınıflandırma doğruluk başarı oranı %90.03 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 20’de ve karışıklık matrisi ile performans değerleri Çizelge 7’de gösterilmektedir.



Şekil 20. Yaprak kategori 2 eğitim akış diyagramı

Çizelge 7. Yaprak kategori 2 karışıklık matrisi ve performans değerleri


	Sınıflar	Tahmin										Hassasiyet	F1 Puanı
		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.		
Gerçek	1.	44	2	0	0	2	0	1	0	0	0	90	92
	2.	1	31	6	0	1	0	0	0	0	0	80	84
	3.	0	2	36	0	3	0	0	0	0	0	88	80
	4.	0	0	0	32	0	0	0	2	0	0	94	97
	5.	0	0	3	0	28	0	0	0	3	1	80	79
	6.	0	0	1	0	1	27	0	0	0	0	93	96
	7.	0	0	0	0	0	0	48	0	0	0	100	99
	8.	2	0	0	0	0	0	0	39	0	0	95	95
	9.	0	0	1	0	0	0	0	0	30	2	91	89
	10.	0	0	2	0	1	0	0	0	1	28	88	89
Duyarlılık		94	89	74	100	78	100	98	95	88	90	(%)	
DOĞRULUK												90.03	

Kategori 2 için Çizelge 7 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Pinot noir çeşidinde yaparken en düşük tahminini Alphonse lavelle ve Mevlana çeşidinde yapmıştır. Genel toplamda ise 381 test görüntüsünden 343 görüntü doğru tahmin edilerek %90.03 sınıflandırma başarı oranı elde edilmiştir.

Kategori 3

Sınıfları oluşturan çeşitler; 1. Cabernet france, 2. Cabernet sauvignon, 3. Hasandede, 4. Kyoho, 5. Prima, 6. Red globe, 7. Sultani çekirdeksiz, 8. Syrah, 9. Süperior seedless, 10. Victoria

Yaprak kategori 3 sınıflandırma doğruluk başarı oranı %87.44 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 21’de ve karışıklık matrisi ile performans değerleri Çizelge 8’de gösterilmektedir.



Şekil 21. Yaprak kategori 3 eğitim akış diyagramı


Çizelge 8. Yaprak kategori 3 karışıklık matrisi ve performans değerleri

		Tahmin										Hassasiyet	F1 Puanı
Sınıflar		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.		
Gerçek	1.	40	0	0	0	0	0	0	2	0	0	95	90
	2.	1	38	1	1	0	0	0	1	1	0	88	85
	3.	0	0	39	1	2	0	0	0	0	0	93	91
	4.	4	2	4	38	0	0	0	2	0	0	76	84
	5.	0	1	0	0	33	3	1	0	1	0	85	83
	6.	0	0	0	0	3	30	2	0	0	0	86	80
	7.	1	0	0	0	2	1	30	0	0	1	86	86
	8.	0	3	0	0	0	0	0	59	0	0	95	93
	9.	0	0	0	0	0	4	1	0	29	3	78	85
	10.	0	2	0	0	0	2	1	0	0	40	89	90
Duyarlılık		88	83	89	95	83	75	86	92	94	91	(%)	
DOĞRULUK												87.44	

Kategori 3 için Çizelge 8 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Cabernet franc çeşidinde yaparken en düşük tahminini Kyoho çeşidinde yapmıştır. Genel toplamda ise 430 test görüntüsünden 376 görüntü doğru tahmin edilerek %87.44 sınıflandırma başarı oranı elde edilmiştir.

Kategori 4

Sınıfları oluşturan çeşitler; 1. 1103 Paulsen, 2. 110R, 3. Black magic, 4. Corinth, 5. Helvani, 6. Merlot, 7. Muhammediye, 8. Rub. Du. Lot., 9. Tayfi, 10. Çavuş Yaprak kategori 4 sınıflandırma doğruluk başarı oranı %94.14 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 22’de ve karışıklık matrisi ile performans değerleri Çizelge 9’da gösterilmektedir.



Şekil 22. Yaprak kategori 4 eğitim akış diyagramı

Çizelge 9. Yaprak kategori 4 karışıklık matrisi ve performans değerleri


	Sınıflar	Tahmin										Hassasiyet	F1 Puanı
		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.		
Gerçek	1.	41	0	0	0	0	0	0	2	0	3	89	85
	2.	5	33	0	0	3	0	0	0	1	0	79	87
	3.	1	1	46	0	0	0	0	0	0	0	96	97
	4.	0	0	0	36	0	0	0	0	0	0	100	95
	5.	0	0	0	0	46	0	0	0	0	0	100	97
	6.	0	0	0	4	0	46	0	0	0	0	92	94
	7.	0	0	0	0	0	0	42	0	0	0	100	100
	8.	1	0	0	0	0	2	0	44	0	0	94	95
	9.	0	0	0	0	0	0	0	0	42	0	100	99
	10.	2	0	1	0	0	0	0	0	0	42	93	93
	Duyarlılık	82	97	98	90	94	96	100	96	98	93	(%)	
DOĞRULUK												94.14	

Kategori 4 için Çizelge 9 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Corint, Helvani, Muhammediye ve Tayfi çeşitlerinde yaparken en düşük tahminini 110R çeşidinde yapmıştır. Genel toplamda ise 444 test görüntüsünden 418 görüntü doğru tahmin edilerek %94.14 sınıflandırma başarı oranı elde edilmiştir.

Kategori 5

Sınıfları oluşturan çeşitler; 1. 41B, 2. 5BB, 3. Autumn royal, 4. Bronx seedlees, 5. Kısmışh vatkana, 6. Regent, 7. Rizellim, 8. Rizessi, 9. Rizpem, 10. Yalova incisi

Yaprak kategori 5 sınıflandırma doğruluk başarı oranı %92.40 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 23’de ve karışıklık matrisi ile performans değerleri Çizelge 10’da gösterilmektedir.



Şekil 23. Yaprak kategori 5 eğitim akış diyagramı

Çizelge 10. Yaprak kategori 5 karışıklık matrisi ve performans değerleri

		Tahmin										Hassasiyet	F1 Puanı
Sınıflar		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.		
Gerçek	1.	52	0	0	0	0	0	0	0	0	0	100	95
	2.	0	49	0	0	0	0	1	0	0	0	98	97
	3.	3	0	45	2	0	0	0	0	0	0	90	92
	4.	0	0	0	46	0	0	0	0	0	0	100	96
	5.	0	2	2	2	34	2	0	3	0	3	71	80
	6.	0	0	0	0	1	39	0	3	2	0	87	87
	7.	0	0	1	1	2	0	46	0	0	0	92	95
	8.	0	0	0	0	0	0	0	48	1	0	98	93
	9.	0	0	0	0	0	0	0	0	42	0	100	96
	10.	2	0	0	0	0	4	0	0	0	46	89	91
Duyarlılık		91	96	94	90	92	87	98	89	93	94	(%)	
DOĞRULUK												92.40	


Kategori 5 için Çizelge 10 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini 41B, Bronx seedlees ve Rizpem çeşitlerinde yaparken en düşük tahminini Kısmış vatkana çeşidinde yapmıştır. Genel toplamda ise 484 test görüntüsünden 447 görüntü doğru tahmin edilerek %92.40 sınıflandırma başarı oranı elde edilmiştir.

4.1.2. Salkım/Meyve görüntülerine ait bulgular

Kategori 1

Sınıfları oluşturan çeşitler; 1. Alphonse L., 2. Bilecik karası, 3. Crimson seedlees, 4. Flame seedlees, 5. Horoz karası, 6. Karaerik, 7. Lival, 8. Michele palieri, 9. Royal, 10. Tekirdağ çekirdeksizi, 11. Trakya ilkeren

Salkım/meyve kategori 1 sınıflandırma doğruluk başarı oranı %85.80 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 24'te ve karışıklık matrisi ile performans değerleri Çizelge 11'de gösterilmektedir.



Şekil 24. Salkım/meyve kategori 1 eğitim akış diyagramı

Çizelge 11. Salkım/meyve kategori 1 karışıklık matrisi ve performans değerleri


	Sınıflar	Tahmin											Hassasiyet	F1 Puanı
		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.		
Gerçek	1.	37	3	0	1	0	0	0	0	2	0	3	80	87
	2.	0	36	0	0	0	2	0	0	2	1	0	88	86
	3.	0	0	37	0	0	0	0	0	0	0	0	100	100
	4.	0	1	0	24	3	0	0	0	1	0	4	73	76
	5.	0	0	0	1	35	0	3	0	1	1	1	83	78
	6.	0	0	0	0	1	32	1	0	4	1	0	82	88
	7.	0	1	0	0	3	0	33	0	0	0	0	89	86
	8.	0	0	0	2	0	0	0	40	0	0	2	91	95
	9.	0	2	0	0	0	0	1	0	32	0	1	89	82
	10.	0	0	0	2	2	0	0	0	0	38	1	88	90
	11.	2	0	0	0	4	0	3	0	0	0	31	80	76
Duyarlılık		95	84	100	80	73	94	83	100	76	72	72	(%)	
DOĞRULUK													85.81	

Kategori 1 için Çizelge 11 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Crimson seedlees çeşidinde yaparken en düşük tahminini Flame seedlees çeşidinde yapmıştır. Genel toplamda ise 438 test görüntüsünden 375 görüntü doğru tahmin edilerek %85.81 sınıflandırma başarı oranı elde edilmiştir.

Kategori 2

Sınıfları oluşturan çeşitler; 1. Cardinal, 2. Mevlana, 3. Narince, 4. Prima, 5. Red globe, 6. Sultani çekirdeksiz, 7. Sperior seedlees, 8. Vakkas, 9. Victoria, 10. İtalia, 11. İzabel

Salkım/meyve kategori 2 sınıflandırma doğruluk başarı oranı %84.90 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 25'te ve karışıklık matrisi ile performans değerleri Çizelge 12'de gösterilmektedir.



Şekil 25. Salkım/meyve kategori 2 eğitim akış diyagramı


Çizelge 12. Salkım/meyve kategori 2 karışıklık matrisi ve performans değerleri

		Tahmin													
Sınıflar		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.	Hassasiyet	F1 Puanı	
Gerçek	1.	25	0	2	2	4	0	0	0	2	0	2	68	74	
	2.	0	32	0	0	0	0	0	0	1	6	0	82	84	
	3.	0	2	38	0	0	2	0	0	4	1	0	81	86	
	4.	2	0	0	33	2	0	0	0	0	0	0	89	88	
	5.	2	0	1	3	24	0	0	2	0	0	2	71	74	
	6.	0	1	1	0	0	31	1	0	5	0	0	80	84	
	7.	0	0	0	0	0	1	29	0	5	1	0	81	88	
	8.	0	0	0	0	0	0	0	35	0	0	0	100	97	
	9.	0	1	0	0	0	1	0	0	35	0	0	95	79	
	10.	0	1	0	0	0	0	0	0	0	36	0	97	89	
	11.	2	0	0	0	1	0	0	0	0	0	36	92	91	
	Duyarlılık		81	87	91	87	77	89	97	95	67	82	90	84.90	
DOĞRULUK														84.90	

Kategori 2 için Çizelge 12 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Vakkas çeşidinde yaparken en düşük tahminini Cardinal çeşidinde yapmıştır. Genel toplamda ise 417 test görüntüsünden 354 görüntü doğru tahmin edilerek %84.90 sınıflandırma başarı oranı elde edilmiştir.

Kategori 3

Sınıfları oluşturan çeşitler; 1. Abalıhoca, 2. Cabarnet sauvignon, 3. Corinth, 4. Erciş, 5. Hasandede, 6. Kyoho, 7. Merlot, 8. Muhammediye, 9. Pinot noir, 10. Syrah, 11. Çavuş Salkım/meyve kategori 3 sınıflandırma doğruluk başarı oranı %96.40 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 26’da ve karışıklık matrisi ile performans değerleri Çizelge 13’te gösterilmektedir.



Şekil 26. Salkım/meyve kategori 3 eğitim akış diyagramı

Çizelge 13. Salkım/meyve kategori 3 karışıklık matrisi ve performans değerleri


	Sınıflar	Tahmin											Hassasiyet	F1 Puanı
		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.		
Gerçek	1.	33	0	1	0	0	0	0	0	0	0	0	97	98
	2.	0	33	0	0	0	0	0	0	0	4	0	89	94
	3.	0	0	52	0	0	0	0	0	0	0	2	96	97
	4.	0	0	0	37	0	0	0	0	0	0	0	100	98
	5.	0	0	0	0	37	0	2	0	0	0	0	95	97
	6.	0	0	0	1	0	38	0	0	0	0	0	97	98
	7.	0	0	0	0	0	0	44	0	0	2	0	96	96
	8.	0	0	0	0	0	0	0	39	0	0	0	100	100
	9.	0	0	0	0	0	0	0	0	35	4	0	90	95
	10.	0	0	0	0	0	0	0	0	0	36	0	100	88
	11.	0	0	0	0	0	0	0	0	0	0	41	100	97
Duyarlılık		100	100	98	97	100	100	96	100	100	78	95	(%)	
DOĞRULUK													96.40	

Kategori 3 için Çizelge 13 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini Muhammediye, Syrah ve Çavuş çeşitlerinde yaparken en düşük tahminini Pinot noir çeşidinde yapmıştır. Genel toplamda ise 441 test görüntüsünden 425 görüntü doğru tahmin edilerek %96.40 sınıflandırma başarı oranı elde edilmiştir.

Kategori 4

Sınıfları oluşturan çeşitler; 1. 41B, 2. Autumn royal, 3. Black magic, 4. Bronx seedlees, 5. Kısmışh vatkana, 6. Regent, 7. Rizellim, 8. Rizessi, 9. Rizpem, 10. Tayfi, 11. Yalova incisi

Salkım/meyve kategori 4 sınıflandırma doğruluk başarı oranı %97.20 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 27’de ve karışıklık matrisi ile performans değerleri Çizelge 14’te gösterilmektedir.



Şekil 27. Salkım/meyve kategori 4 eğitim akış diyagramı

Çizelge 14. Salkım/meyve kategori 4 karışıklık matrisi ve performans değerleri

		Tahmin											Hassasiyet	F1 Puanı
Sınıflar		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.		
Gerçek	1.	39	0	0	0	0	0	0	0	0	0	0	100	100
	2.	0	36	0	0	2	0	2	0	0	0	0	90	95
	3.	0	0	38	0	0	0	0	0	0	0	0	100	97
	4.	0	0	0	38	0	0	0	0	0	0	0	100	96
	5.	0	0	0	0	32	0	0	0	1	0	0	97	94
	6.	0	0	1	0	1	30	0	0	0	0	0	94	97
	7.	0	0	0	1	0	0	39	0	0	0	0	98	96
	8.	0	0	1	0	0	0	0	30	0	0	0	97	98
	9.	0	0	0	0	0	0	0	0	35	0	0	100	98
	10.	0	0	0	0	0	0	0	0	0	40	0	100	100
	11.	0	0	0	2	0	0	0	0	0	0	32	94	97
Duyarlılık		100	100	95	92	91	100	95	100	97	100	100	(%)	
DOĞRULUK													97.20	

Kategori 4 için Çizelge 14 incelendiğinde, karışıklık matrisinde oluşturulan yeni model, en yüksek tahminini 41B, Black magic, Rizpem ve Tayfi çeşitlerinde yaparken en düşük tahminini Autumn royal çeşidinde yapmıştır. Genel toplamda ise 400 test görüntüsünden 389 görüntü doğru tahmin edilerek %92.20 sınıflandırma başarı oranı elde edilmiştir.


4.1.3. GoogleNet ve AlexNet modellerine ait bulgular

Her iki modelin eğitilmesinde de salkım/meyve grubunda bulunan kategori 4'e ait sınıflar kullanılmıştır. GoogleNet ve AlexNet'ten elde edilen bulgular aşağıda gösterilmektedir.

GoogleNet

Sınıfları oluşturan çeşitler; 1. 41B, 2. Autumn royal, 3. Black magic, 4. Bronx seedlees, 5. Kısmışh vatkana, 6. Regent, 7. Rizellim, 8. Rizessi, 9. Rizpem, 10. Tayfi, 11. Yalova incisi

GoogleNet sınıflandırma doğruluk başarı oranı %84.39 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 28'de ve karışıklık matrisi ile performans değerleri Çizelge 15'te gösterilmektedir.



Şekil 28. GoogleNet modeline ait eğitim akış diyagramı

Çizelge 15. GoogleNet karışıklık matrisi ve performans değerleri


	Sınıflar	Tahmin											Hassasiyet	F1 Puanı
		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.		
Gerçek	1.	36	7	0	0	0	0	0	0	0	0	0	84	91
	2.	0	42	1	0	0	0	1	0	0	0	0	96	75
	3.	0	7	29	1	3	2	0	0	0	0	0	69	77
	4.	0	0	0	34	0	0	5	0	0	0	1	85	88
	5.	0	2	1	0	32	0	2	0	0	0	0	87	79
	6.	0	5	1	0	5	23	2	0	0	0	0	64	73
	7.	0	0	0	0	0	0	43	0	0	0	1	98	86
	8.	0	6	1	2	4	2	0	18	2	0	0	52	66
	9.	0	0	0	0	0	0	1	2	36	0	0	92	93
	10.	0	0	0	0	0	0	0	0	0	44	0	100	100
	11.	0	0	0	0	0	0	2	0	0	0	36	95	95
Duyarlılık		100	61	88	92	73	85	77	90	95	100	95	(%)	
DOĞRULUK													84.39	

GoogleNet için Çizelge 15 incelendiğinde, karışıklık matrisinde en yüksek tahminini Tayfi çeşidinde yaparken en düşük tahminini Rizessi çeşidinde yapmıştır. Genel toplamda ise 442 test görüntüsünden 373 görüntü doğru tahmin edilerek %84.39 sınıflandırma başarı oranı elde edilmiştir.

AlexNet

Sınıfları oluşturan çeşitler; 1. 41B, 2. Autumn royal, 3. Black magic, 4. Bronx seedlees, 5. Kısmışh vatkana, 6. Regent, 7. Rizellim, 8. Rizessi, 9. Rizpem, 10. Tayfi, 11. Yalova incisi

AlexNet sınıflandırma doğruluk başarı oranı %92.31 olarak bulunmuştur. Sınıflandırmaya ait akış diyagramı Şekil 29'da ve karışıklık matrisi ile performans değerleri Çizelge 16'da gösterilmektedir.



Şekil 29. AlexNet modeline ait eğitim akış diyagramı

Çizelge 16. AlexNet karışıklık matrisi ve performans değerleri

		Tahmin												
Sınıflar		1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.	Hassasiyet	F1 Puanı
Gerçek	1.	43	0	0	0	0	0	0	0	0	0	0	100	100
	2.	0	35	8	0	0	0	0	1	0	0	0	80	87
	3.	0	1	39	0	0	2	0	0	0	0	0	93	87
	4.	0	0	0	36	0	0	3	0	0	0	1	90	93
	5.	0	2	1	0	34	0	0	0	3	0	0	92	91
	6.	0	1	0	0	2	33	0	0	0	0	0	92	90
	7.	0	0	0	1	0	0	38	0	0	0	5	86	88
	8.	0	0	1	0	2	2	0	30	0	0	0	86	91
	9.	0	0	0	0	0	0	0	0	39	0	0	100	96
	10.	0	0	0	0	0	0	0	0	0	44	0	100	100
	11.	0	0	0	0	0	0	1	0	0	0	33	97	91
Duyarlılık		100	95	81	97	90	89	91	97	93	100	86	(%)	
DOĞRULUK													92.31	

AlexNet için Çizelge 16 incelendiğinde, karışıklık matrisinde en yüksek tahminini Tayfi çeşidinde yaparken en düşük tahminini Regent ve Yalova incisi çeşitlerinde yapmıştır. Genel toplamda ise 441 test görüntüsünden 404 görüntü doğru tahmin edilerek %92.31 sınıflandırma başarı oranı elde edilmiştir.

Çizelge 17’de yeni model kategorilerinden ve GoogleNet ile AlexNet modellerinden elde edilen, Doğruluk, Hassasiyet, Duyarlılık ve F1 Puan ortalama değerleri karşılaştırılarak gösterilmektedir.

Çizelge 17. Yeni model, GoogleNet ve AlexNet modellerinin performans değerleri

			Kullanılan Ölçüm Yöntemleri			
			Hassasiyet	Duyarlılık	F1 Puanı	Doğruluk
Yeni model kategorileri	Yaprak	Kategori 1	87.10	84.42	85.73	82.50
		Kategori 2	89.90	90.60	90.24	90.03
		Kategori 3	87.10	87.60	87.34	87.44
		Kategori 4	94.30	94.40	94.30	94.10
		Kategori 5	92.50	92.40	92.44	92.40
	Salkım-meyve	Kategori 1	85.72	84.45	85.08	85.88
		Kategori 2	85.09	85.72	85.40	84.90
		Kategori 3	96.30	96.72	96.50	96.40
		Kategori 4	97.27	97.27	97.27	97.20
	Ön eğitilmiş modeller	GoogleNet	83.80	86.90	83.90	84.39
		AlexNet	92.36	92.63	92.18	92.31
Genel ortalama			90.13	90.28	90.03	90.00

Çizelge 17 incelendiğinde, Doğruluk %97.20 değeri ile en yüksek salkım/meyvede kategori 4’te bulunurken en düşük oran ise %82.50 değeri ile yaprakta kategori 1’de bulunmuştur. Genel ortalama değerlendirmelerinde ise Doğruluk %90.00, Hassasiyet %90.13, Duyarlılık %90.28 ve F1 Puanı %90.03 olarak ortaya çıkarılmıştır.

Akış diyagramlarında bütün modeller için 42 devir sayısı kullanılmıştır. Yeni model için iterasyon başına yaprak grubunda 12 devir, salkım/meyve grubunda 13 devir, GoogleNet ve AlexNet modelleri için iterasyon başına 171 devir kullanılmıştır. Yeni model için maksimum iterasyon yaprak grubunda 504 iterasyon, salkım/meyve grubunda 546 iterasyon, GoogleNet ve AlexNet modelleri için ise maksimum iterasyon 7182 olarak belirlenmiştir. Yeni modelde, yaprak ve salkım/meyve grubunda 0.1 öğrenme oranı kullanılırken, GoogleNet modeli için 0.001 ve AlexNet modeli için 0.0001 öğrenme oranı kullanılmıştır.

Bu parametrelerle akış diyagramlarındaki başarı oranları elde edilmiştir. Akış diyagramlarında görüldüğü üzere eğitim doğruluğu iterasyonları ve eğitim kaybı iterasyonları arasındaki ilişki, modellerle çeşitleri ezberlemek yerine kararlı bir şekilde öğrenmeyi sağlayarak eğitim kaybı fonksiyonunu en aza indirip en yüksek başarı oranını elde edilmeye çalışılmıştır.

4.2. Tartışma

Yeni geliştirilen model, derin öğrenme modellerinden GoogleNet ve AlexNet ile karşılaştırılarak performans değerlendirilmesi yapılmış ve sonuçlar değerlendirilmiştir. Hazırlanan veri seti farklı üç modelde de eğitilerek elde edilen başarı oranı sonuçları çizelgelerde verilmiştir. Bütün modeller için devir sayısı, mini batch sayısı ve doğrulama frekansı sayısı eşit seçilmiş fakat öğrenme oranları farklı seçilmiştir. Parametrelerin bu şekilde seçilmesini nedeni modellerin başarımlarının karşılaştırılmasının model algoritmasına göre yapılmasını sağlamaktır. Mini batch ve devir sayısında artırma veya azaltma işlemleri veri setinin durumuna göre başarımlarını etkileyebilmektedir. Modellerde en yüksek başarıyı veren devir sayısı, mini batch sayısı, doğrulama frekansı sayısı ve öğrenme oranı sayısı kullanılmıştır. Çizelge 18’de hazırlanan veri seti ile eğitilen ve yeni geliştirilen modelin diğer modellerle karşılaştırıldığı başarımlar oranı sonuçları gösterilmektedir.

Çizelge 18. Yeni geliştirilen modelin diğer modellerle karşılaştırılması

	Model türü		
	GoogleNet	AlexNet	Yeni model
Katman sayısı	144	25	15
Sınıf sayısı	11	11	11
Mini batch sayısı	10	10	10
Devir sayısı	42	42	42
Optimizer	SGD	SGD	SGD
Öğrenme oranı	0.001	0.0001	0.1
Başarım oranı (%)	84.39	92.31	97.20

Çizelge 18’de derin öğrenme modellerinden GoogleNet, AlexNet ve yeni modelin eğitim parametreleri ve başarımları karşılaştırılmıştır. Çizelgede de görüldüğü üzere yeni oluşturulan veri seti ile eğitilen modeller içerisinde en iyi sonuç %97.20 başarı oranı ile yeni geliştirilen modelden elde edilmiştir. AlexNet modelinden %92.31 başarı oranı ve GoogleNet modelinden %84.39 başarı oranı elde edilmiştir.

Çalışmada önerilen bu modelin, diğer modellerden daha iyi sonuçlar verdiği görülmektedir. Bu sonuç diğer model sonuçları ile karşılaştırıldığında, yeni modelin bu alanda oldukça başarılı olduğunu ve üzüm çeşitlerinin karakterizasyon özellikleriyle sınıflandırılmasında kullanılabilirliğini ortaya çıkarmıştır.

5. SONUÇ ve ÖNERİLER

5.1. Sonuç

Tarımsal üretimde, düşük maliyet ve minimum girdi ile maksimum verim ve yüksek kalite elde etmek için geleneksel üretim uygulamalarının yerine son teknolojik uygulamaların kullanılması gerekmektedir. Bundan dolayı ülkemiz ekonomisi için önemli bir etkiye sahip olan tarımsal üretimin geliştirilmesi, doğal kaynakların korunması, bilişim ve teknolojik alandaki uygulamaların tarıma uyarlanması amacıyla yapılan araştırmalar tarım açısından gerekli ve önemlidir. Çalışmada, yeni ve özgün olarak geliştirilen derin öğrenme tekniği olan CNN modeli önerilmiştir. Özgün olarak oluşturulan CNN modeli ile birlikte, ön eğitilmiş modellerden GoogleNet ve AlexNet modelleri de kullanılarak modeller arası performans değerlendirilmesi yapılmıştır. Çalışmanın en önemli özgülüğü ise hem yeni oluşturulan veri seti ve CNN modeli hem de bu veri setinin ön eğitilmiş modellerde yüksek başarı elde etmesi olmuştur. Bu bakımdan bu çalışmayla literatüre yeni bir veri seti kazandırılmıştır.

Önerilen 15 katmanlı CNN modeli ile 227x227x3 boyutunda, 9 854 yaprak, 8 745 salkım ve 8 721 meyve olmak üzere toplam 27 320 veri seti görüntüsü kullanılarak, MATLAB 2021a platformunda elli adet üzüm çeşidinin sınıflandırılması yapılmıştır. Sınıflandırma işlemi hem yaprak hem de salkım/meyve görüntüleri kullanılarak iki aşamada gerçekleştirilmiştir. Çeşitler, yaprak grubunda beş farklı, salkım/meyve grubunda ise dört farklı kategori olmak üzere toplam dokuz farklı kategoride sınıflandırılmışlardır. Yaprak grubunun her birinde onar sınıf bulunurken salkım/meyve grubunun her birinde on birer sınıf bulunmaktadır. Her bir kategorinin Doğruluk, Hassasiyet, Duyarlılık ve F1 Puanı değerleri ayrı ayrı hesaplanarak sonuçlar ortaya çıkarılmıştır. Çalışmada yeni oluşturulan CNN modelinin yanı sıra ön eğitilmiş derin öğrenme modellerinden GoogleNet ve AlexNet ile de veri seti eğitilerek başarılı sonuçlar elde edilmiştir.

Yeni geliştirilen CNN modeli için yaprak grubunda doğruluk başarı oranları; Kategori 1 için %82.50, Kategori 2 için %90.03, kategori 3 için %87.44, kategori 4 için %94.10 ve kategori 5 için %92.40 olarak hesaplanmıştır. Salkım/meyve grubunda ise doğruluk başarı oranları; Kategori 1 için %85.88, Kategori 2 için %84.90, kategori 3 için %96.40 ve Kategori 4 için %97.20 olarak hesaplanmıştır. GoogleNet modelinde başarı oranı

%84.39, AlexNet modelinde ise başarı oranı %92.31 olarak elde edilmiştir. Bu oranlara göre en yüksek başarı oranı, salkım/meyve grubunda bulunan ve yeni geliştirilen CNN modelinin en iyi performansı olan Kategori 4'te %97.20 olarak bulunurken, en düşük başarı oranı ise yaprak grubunda bulunan Kategori 1'de 82.50 olarak bulunmuştur.

Üzüm çeşitlerinin sınıflandırılması amacıyla geliştirilen CNN modelinin başarı oranı sonuçlarına bakıldığında ve diğer modellerle karşılaştırıldığında bu modelin daha başarılı sonuçlar verdiği görülmektedir. Model üzerinde geliştirme çalışmalarına devam edilerek daha iyi sonuçlar vermesi hedeflenmektedir. Böylece ilerleyen zamanlarda modelin geliştirilerek ve yapılacak yeni çalışmalarla, üzüm görüntülerinden çeşitlerin gerçek zamanlı ve otomatik olarak sınıflandırıldığı sistemlerin geliştirilmesine çalışılacaktır.

5.2. Öneriler

- 1- Çalışma kapsamında elli adet üzüm çeşidinin sınıflandırılmasıyla sınırlı olan ve sınıflandırılmada kullanılan yaprak, salkım/meyve karakterizasyon özellikleri artırılarak veri seti büyütülebilir.
- 2- Bu alanda derin öğrenme modelleri daha fazla geliştirilerek dünyada üreticiliği yapılan tüm üzüm çeşitlerinin derin öğrenme modellerine öğretilmesi mümkün olabilir.
- 3- Çalışmada önerilen model ile elde edilen sonuçlar literatürde yapılan diğer çalışmalarla kıyaslanarak modeller daha fazla geliştirilebilir.
- 4- Başka bilimsel çalışmalarda, üzüm çeşitlerinin yaprak ve salkım/meyve haricindeki diğer karakterizasyon özelliklerinin de veri setine eklenmesiyle artırılması ya da yaprak ve salkım/meyveye başka ampelografik özellikler eklenerek sınıf sayısı artırılıp derin öğrenme modellerinin başarı oranları değerlendirilmeye devam edilebilir.
- 5- Önerilen bu modelden yola çıkılarak iyi geliştirilmiş bir yazılımla ortaya çıkarılacak akıllı telefon uygulamasıyla, günlük hayatta da görüntüden üzüm çeşitlerinin tespit edilmesi mümkün olabilir.
- 6- Önerilen bu model sadece üzüm çeşitlerinin tespiti ile kalmayıp tarımsal üretimde, diğer çalışmalarda da kullanılabilir.
- 7- Oluşturan veri seti güncellenen modellere uygulanarak daha fazla bilimsel çalışma yapılabilir.

5.3. Çalışmanın sınırlılıkları

- 1- Çalışmada toplam elli adet üzüm çeşidi kullanılmıştır.
- 2- Üzüm çeşitlerinin belirlenmesinde elli sekiz ampelografik özellik içerisinde derin öğrenme yöntemlerine uygun olan, yaprak profili, yaprak dış şekli, salkım yoğunluğu ve meyve şekli karakterizasyon özellikleri kullanılmıştır.
- 3- Çalışma veri kümesinde toplam 48 946 görüntü bulundurulmuş bunların 27 320 tanesi veri setinde kullanılmıştır.
- 4- Üzüm çeşitlerine ait görüntüler daha çok Tokat ilinde bulunan bağlardan alınmıştır.
- 5- Çalışmada on beş katmanlı yeni bir derin öğrenme mimarisi oluşturulmuştur.
- 6- Çalışmada, yeni oluşturulan CNN modeli ve ön eğitilmiş GoogleNet ile AlexNet modeli kullanılmıştır.

6. KAYNAKLAR

- Ağaoğlu, Y.S., 1999. Bilimsel ve Uygulamalı Bağcılık. Ankara Üniversitesi, Ziraat Fakültesi, Kavaklıdere Eğitim Yay. No.1, 205 s, Ankara.
- Adem, K., 2018. Exudate Detection for Diabetic Retinopathy with Circular Hough Transformation and Convolutional Neural Networks. Expert Systems with Applications, 2018, (114): 289-295.
- Adem, K., Ozguven, M.M. ve Altas, Z., 2022. A sugar beet leaf disease classification method based on image processing and deep learning. Multimedia Tools and Applications.
- Adem, K. ve Közkurt, C., 2019. Defect Detection of Seals in Multilayer Aseptic Packages Using Deep Learning. Turkish Journal of Electrical Engineering and Computer Sciences: 27 (6): 4220-4230.
- Adige, S., Kurban, R., Durmuş, A. ve Karaköse, E., 2022. Görüntü İşleme Tekniklerinden Faydalanan Elma Çeşitlerinin Türlerine Göre Sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı 37, 131-137.
- Aktaş, A., 2020. Derin Öğrenme Yöntemleri ile Görüntü İşleme Uygulamaları. Yüksek Lisans Tezi. Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Allewelt, G., 1997. Genetics of Grapevine Breeding. Progress in Botany, 58: 441-454.
- Altas, Z., Ozguven, M.M. ve 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, A.F. ve Yeroğlu, C., 2019. Identification of Apricot Varieties Using Leaf Characteristics and KNN Classifier. In: 2019 International Artificial Intelligence and Data Processing Symposium, 1-6.
- Atik, I., 2022. Derin Öğrenme Yöntemleri Kullanılarak Bitki Yaprağındaki Hastalıkların Sınıflandırılması. Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 25 (2): 126-137.
- Anonim, 2022a. Evrişimli Sinir Ağlarına Giriş. Miuul, <https://miuul.com/not-defteri/evrisimli-sinir-aglarına-giris> (10.12.2022).
- Anonim, 2022b. Evrişimli Sinir Ağlarına Giriş. Miuul, <https://miuul.com/not-defteri/evrisimli-sinir-aglarına-giris> (28.11.2022).
- Anonim, 2022c. IndianTechWarrior. <https://indiantechwarrior.com/fully-connected-layers-in-convolutional-neural-networks/> (25.12.2022).
- Anonim, 2022d. CUDA Nedir. <https://programlamadilleri.net/cuda-nedir/> (23.12.2022)
- Anonim, 2022e. MathWorks. https://www.mathworks.com/?s_tid=gn_logo (05.12.2022).
- Anonymous, 1997. Descriptors for Grapevine (*Vitis* spp.). International Plant Genetic Resources Institute. ISBN 92-9043-352-3.
- Arslan, T., Doğan, A. ve Uyak, C., 2018. Ampelographic Identification of Grape Varieties Grown in Yüksekova (Hakkari) Region. Journal of Agricultural Faculty of Gaziosmanpaşa University, 35 (3): 217-226.
- Bahar, E., Korkutal, İ., Şahin, N., Sağır, F.S., Kök, D., Ergönül, O., Uysal, T. ve Özalp, Z.O., 2019. Ganos Dağları Doğal Florasında Bulunan Kültür Asmalarının (*Vitis vinifera* L.) Molaküler ve Ampelografik Karakterizasyonu. Journal of Tekirdag Agricultural Faculty, 16 (1): 92-102.

- Bengio, Y., Courville, A. ve Vincent, P., 2013. Representation Learning: A Review and New Perspectives, *IEEE Trans. Pattern Anal. Mach. Intell.*, 35 (8): 1798-1828.
- Bounab, O. ve Laiadi, Z., 2019. A Multivariate Approach for the Ampelographic Characterization of Algerian Grapevine Genotypes (*Vitis Vinifera* L.): Insights into Conservation and Commercialization. *South African Journal of Botany*, 124 (2019): 71-79.
- Cangi, R., Adınır, M., Yağcı, A., Topçu, N. ve Sucu, S., 2011. Salamuralık Yaprak Üretilen Bağlarda Farklı Üretim Modellerinin Ekonomik Analizi. *Iğdır Üni. Fen Bilimleri Enst. Der.*, 1(2): 77-84.
- Couliably, S., Foguem, B.K., Kamissoko, D. ve Traore, D., 2022. Deep learning for precision agriculture: A Bibliometric Analysis. Elsevier, *Intelligent Systems with Applications*, p:45, doi:org/10.1016/j.iswa.2022.200102. (15.11.2022)
- Çarkacı, N., 2018. Derin Öğrenme Uygulamalarında En çok Kullanılan Parametreler. Medium, <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> (08.12.2022).
- Çelik, H., Ağaoğlu, Y.S., Fidan, Y., Maraslı, B. ve Söylemezoğlu, G., 1998. Genel Bağcılık. *Sun Fidan Mesleki Kitaplar Serisi-1*, 253, Ankara.
- Çelik, H. ve C. Karanis, 1998. Amasya'da Yetiştirilen Bazı Üzüm Çeşitlerinin Ampelografik Özelliklerinin Saptanması Üzerine Bir Araştırma. 4. Bağcılık Sempozyumu, 357-361, Yalova.
- Çelik, M., Uzun, M.A., Karadeniz M., Koçak, O. ve Dibekalan, E., 2019. Bazı Sofralık Üzüm Çeşitlerinin Erken Gelişme Dönemlerindeki Ampelografik Özelliklerinin Belirlenmesi. 2. Uluslararası Tarım, Çevre ve Sağlık Kongresi.
- Deng, L. ve Yu, D., 2014. Deep Learning: Methods and Applications. *Found. Trends Signal Process*, 7 (3): 197-387.
- Dexheimer, F., 2011. The Science of Ampelography. *Sommelier Journal*, 6 (4): 87-91.
- Diaz, Y.P., Tomczak, J.M. ve Bhulai, S., 2021. Deep Learning for White Cabbage Seedling Prediction. *Computers and Electronics in Agriculture*, 184, doi:org/10.1016/j.compag.2021.106059. (12.12.2022)
- Doğan, A., Uyak, C. ve İlhan, E., 2017. Adıyaman Merkez İlçede Yetiştirilen Yerel Üzüm Çeşitlerinin Ampelografik Tanımlanması. *YYÜ. TAR. BİL. DERG.*, 27 (1): 118-131.
- Doğan, F. ve Türkoğlu, İ., 2018. Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(2018): 10-21.
- Doğan, M.S. 2019. Bitkilerde Görülen Hastalıkların Derin Öğrenme Yöntemleriyle Tespiti ve Sınıflandırılması. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bilgisayar mühendisliği Anabilim Dalı, Yalova.
- Durmuş, H., Güneş, E.O. ve Kırıcı, M., 2017. Disease Detection on the Leaves of the Tomato Plants by Using Deep Learning. 2017 6th International Conference on Agro-Geoinformatics. IEEE. doi: 10.1109/Agro-Geoinformatics.2017.8047016.
- Ensari, T. ve Özpolat, K., 2002. Matlab Kullanım Klavuzu: 304 Bilgisayar Destekli Kontrol Sistemleri (400)-4. İstanbul Üniversitesi, Bilgisayar Mühendisliği Bölümü, <https://web.itu.edu.tr/kents/matlab.pdf>. (05.12.2022).
- Eren, F., 2012. Gemerek (Sivas) Yöresinde Yetiştirilen Üzüm Çeşitlerinin Ampelografik Özelliklerinin Belirlenmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Tokat.

- Fuentes, A., Yoon, S., Kim, S.C. ve Park, D.S., 2017. A Robust Deep Learning Based Detector for RealTime Tomato Plant Diseases and Pests Recognition. *Sensors*, doi:10.3390/s17092022.
- Franczyk, B., Hernes, M., Kozierkiewicz, A., Kozina, A., Pietranik, M., Roemer, I. ve Schieck, M., 2020. Deep learning for grape variety recognition. *Procedia Computer Science*, 176:1211-1220.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016. Regularization for Deep Learning. (2016): 216-261.
- Grace, R.K., Anitha, J., Sivaramakrishnan, R. ve Sivakumari, M.S.S., 2021. Crop and Weed Classification Using Deep Learning. *Turkish Journal of Computer and Mathematics Education*, 12 (7): 935-938.
- Heinrich, K., Roth, A., Breithaupt, L., Möller, B. ve Maresch, J., 2019. Yield Prognosis for the Agrarian of Vineyards using Deep Learning for Object Counting. 14th International Conference on Wirtschaftsinformatik, February 24-27, 2019, Siegen, Germany.
- İlim Serhat, M., Eydurhan, S.P. ve Aslantaş, R., 2017. Iğdır Yöresinde Yetiştirilen Yerel Üzüm Çeşitlerinin Ampelografik Özelliklerinin Belirlenmesi. *YYÜ. TAR. BİL. DERG.* 27 (4): 634-645.
- İnik, Ö. ve Ülker, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 3 (6): 85- 104.
- Kairoldayeva, A., 2019. Automatic Determination of Plant Type and Phenological Stage with Deep Learning Methods. M.Sc. Thesis, İstanbul Technical University Informatics Institute, İstanbul.
- Karkacier, O. ve Karabaş, S., 2016. Türkiye’de Arazi Toplulaştırma Uygulamalarının Ekonomik Etkinliği, Sorunları ve Çiftçi Memnuniyet Analizi. Gıda Tarım ve Hayvancılık Bakanlığı, Araştırma Geliştirme Destekleri Proje Sonuç Raporu, TAGEM 14/AR-GE 61.
- Karabaş, S. ve Tekmen, E.E., 2019. Tarım Sektöründe Sosyal Sermaye ve Bilişim Teknolojileri Kullanım Düzeyi. *Uluslararası Sosyal Araştırmalar Dergisi*, 12 (62): 1395- 1411.
- Kılıçarslan, S., 2022. Kuru Üzüm Tanelerinin Sınıflandırılması için Hibrit bir Yaklaşım. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4 (1): 62-71.
- Kayaalp, K. ve Süzen, A.A., 2018. Derin Öğrenme ve Türkiye’deki Uygulamaları. İKSAD Publishing House, 90, Gaziantep.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015. Deep Learning. *nature* 531.7553 (2015): 436-444.
- Lee, S.H., Chan, C.S., Wilkin, P. ve Remagnino, P., 2015. Deep-Plant: Plant Identification with Convolutional Neural Networks. 2015 IEEE international conference on image Processing, 452-456.
- Lim, T.K., 2013. Edible Medicinal and Non-Medicinal Plants. Springer Science and Business Media Dordrecht, Volume 6, 450-482.
- Liu, Y., Su, J., Shen, L., Lu, N., Fang, Y., Liu, F., Song, Y. Ve Su, B., 2021. Development of a Mobile Application for Identification of Grapevine *Vitis Vinifera* L.) Cultivars Via Deep Learning. *Int J Agric & Biol Eng*, 2021; 14(5): 172- 179.
- Maras, V., 2019. Ampelographic and Genetic Characterization of Montenegrin Grapevine Varieties. *Advances in Grape and Wine Biotechnology*. doi:org/10.5772/intechopen.85676.

- Mureşan, H. ve Oltean, M., 2018. Fruit Recognition from images Using Deep Learning. *Acta Univ. Sapientiae, Informatica* 10 (1): 26-42.
- Okşit, S., 2018. Mihalgazi (Eskişehir) Yöresinde Yetiştirilen Üzüm Çeşitlerinin Ampelografik Özelliklerinin Belirlenmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bahçe Bitkileri Ana Bilim Dalı, Tokat.
- Ozguven, M.M., 2018. The Newest Agricultural Technologies. *Current Investigations in Agriculture and Current Research*, 5(1); 573-580.
- Ozguven, M.M. ve Adem K. 2019. Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A*, 535 (2019) 122537.
- Ozguven, M.M. ve Altas, Z., 2022. A New Approach to Detect Mildew on Cucumber (*Pseudoperonospora cubensis*) Leaves with Image Processing. *J Plant Pathol*, (2022): doi.org/10.1007/s42161-022-01178-z.
- Ozguven, M.M. ve Yanar Y., 2022. The Technology Uses in The Determination of Sugar Beet Diseases. In: *Sugar Beet Cultivation, Management And Processing*. Springer, Editör: Misra, V., Srivastava, S., Mall, A.K. (Eds), Sayfa: 621-642, ISBN: 978-981-19-2729-4.
- Ozguven, M.M., 2023. *The Digital Age in Agriculture*. Florida: CRC Press Taylor & Francis Group LLC. ISBN 9781032385808.
- Özgür, A. ve Nar, F., 2019. Derin Öğrenme Yöntemleri Kullanarak Ekin ile Yabancı Otların Birbirinden Ayırt Edilmesi. *International Conference on Computer Technologies and Applications in Food and Agriculture*, 76-89.
- Özgüven, M.M. 2018. Hassas Tarım. Akfon Yayınları, Sayfa Sayısı: 334, Kırıkkale.
- Özgüven, M.M. 2019. Teknoloji Kavramları ve Farkları. *International Erciyes Agriculture, Animal & Food Sciences Conference*, 296-304.
- Özgüven, M.M., Altaş, Z., Güven, D. ve Çam, A., 2022. Tarımda Drone Kullanımı ve Geleceği. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 2022, 12(1): 64-83.
- Peng, Y., Zhao, S. ve Liu, J., 2021. Fused deep features-based grape varieties identification using support vector machine. *Agriculture*, 11:869. <https://doi.org/10.3390/agriculture11090869>.
- Pınar, H., Çöçen, E., Yaman, M., Uzun, A. ve 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.
- Savaş, S., 2020a. Derin Öğrenme Algoritmaları. Meium, <https://medium.com/yapay-zeka-makine-%C3%B6%C4%9Frenmesi-derin-%C3%B6%C4%9Frenme/derin-%C3%B6%C4%9Frenme-algoritmalar%C4%B1-8dea99d9b41f> (08.12.2022).
- Savaş, S., 2020b. Derin Öğrenme Kütüphaneleri. Meium, <https://medium.com/yapay-zeka-makine-%C3%B6%C4%9Frenmesi-derin-%C3%B6%C4%9Frenme/derin-%C3%B6%C4%9Frenme-k%C3%BCt%C3%BCphaneleri-8ef12c7e35f8> (10.12.2022).
- Semerci, A., Kızıltuğ, T., Çelik, A.D. ve Kiracı, M.M., 2015. Türkiye Bağcılığının Genel Durumu. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 20 (2): 42-51.
- Song, H.A. ve Lee, S.Y., 2013. Hierarchical Representation Using NMF. In *International Conference on Neural Information Processing*, 2013, 466-473.
- Söylemezoğlu, G., 1996. Türkiye'de Yetiştirilen Sofralık ve Şaraplık Üzüm Çeşitlerinin İzoenzimlerden Yararlanılarak Page Tekniği ile Teşhisleri Üzerinde Çalışmalar. TUBİTAK, Proje No: TOTAG-1321, 26 S, Ankara.

- Sucu, S. ve Yağcı, A., 2020. Farklı Anaçlar Üzerinde Aşılı Şaraplık Üzüm Çeşitlerinde Fidan Randıman ve Kalite Özelliklerinin Belirlenmesi. BŞEÜ Fen Bilimleri Dergisi, 7 (2): 790-801.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Andrew, R., 2014. Going Deeper with Convolutions, <https://doi.org/10.48550/arXiv.1409.4842>. (10.12.2022)
- Tarhan, S. ve Özgüven, M.M., 2015. Translation Preface. CIGR Handbook of Agricultural Engineering Information Technology. Edited by CIGR-The International Commission of Agricultural Engineering; Volume Editor, Axel Munack. St. Joseph, Michigan, USA.
- Terzi, İ., Özgüven, M.M. ve Yağcı, A., 2022. Derin Öğrenme Teknikleri ile Bazı Üzüm Çeşitlerinin Tespiti. Turkish Journal of Agriculture- Food Science and Technology, ISSN: 2148-127X.
- Terzi, İ., Özgüven, M.M., Altaş, Z. ve Uygun, T., 2019. Tarımda Yapay Zeka Kullanımı. International Erciyes Agriculture, Animal & Food Sciences Conference, 245-255.
- Türkben, C., 2010. Sofralık Üzümlerin Muhafazası. Hasad Yayıncılık, p. 48, İstanbul.
- Turkoglu, M. ve Hanbay, D., 2019. Derin Özelliklere ve Renkli-YİÖ Yöntemine Dayalı Bitki Tanıma Sistemi. 2019 27th Signal Processing and Communications Applications Conference (SIU). doi: 10.1109/SIU.2019.8806592.
- Türkoğlu, M. ve Hanbay, D., 2018. Derin Öğrenme Algoritmalarından Elde Edilen Özniteliklere Dayalı Kayısı Hastalık Tespiti. 978-1-5386-6878-8/18/\$31.00.
- Ünal, M.S., 2020. Şırnak Yöresel Üzüm Çeşitlerinin Bazı Özelliklerinin Belirlenmesi. ÇOMÜ Zir. Fak. Derg., 8 (2): 277-287.
- Ünal, M.S. ve Yıldırım, M., 2019. Şırnak İli İdil İlçesinde Yetiştirilen Üzüm Çeşitlerinin Bazı Ampelografik Özelliklerinin Tespiti. BŞEÜ Fen Bilimleri, 6. Cilt-Prof. Dr. Fuat SEZGİN Bilim Yılı Özel Sayısı, 190-203.
- Yağcı, A., Bıyık, A. ve Erdem, H., 2018. Omcadan Salamuraya Yaprakta Ağır Metal Değişimi. BAHÇE 47, (Özel Sayı 1: Türkiye 9. Bağcılık ve Teknolojileri Sempozyumu): 43-48.
- Yağcı, A. ve İlter, E., 2018. Sultani Çekirdeksiz Üzüm Tiplerinin Hasat Sırasındaki Verim ve Bazı Kalite Özellikleri. Türkiye Tarımsal Araştırma Dergisi, 5(3): 286-292.
- You, Y., Zhang, Z., Hsieh, C.J., Demmel, J. ve Keutzer, K., 2018. ImageNet Training with AlexNet in 24 Minutes. ArXiv: 1709.05011v3. (10.12.2022)
- Zheng, Y.Y., Kong, J.L., Jin, X.B., Wang, X.Y., Su, T.L. ve Zuo, M., 2019. CropDeep: The Crop Vision Dataset for Deep-Learning-Based Classification and Detection in Precision Agriculture. Sensors, 19 (5): 1058.
- Xia, E.Q., Deng, G.F., Guo, Y.J. ve Li, H.B., 2010. Biological Activities of Polyphenols From Grapes. International Journal of Molecular Science, 622-646.

7. ÖZGEÇMİŞ

