CONFERENCE BOOK

EGE 14. ULUSLARARASI UYGULAMALI BİLİMLER KONGRESİ

İZMİR
23 - 29 ARALIK 2025

EGE
14. ULUSLARARASI UYGULAMALI BİLİMLER KONGRESİ



EGE
14TH INTERNATIONAL CONFERENCE ON APPLIED SCIENCES
DECEMBER 23 - 29, 2025
IZMIR

Cilt 2

ISBN : 978-625-5694-65-2
Academy Global Publishing House

EGE 14TH INTERNATIONAL CONFERENCE ON APPLIED SCIENCES
DECEMBER 23 - 29, 2025
IZMIR

Edited By
PROF. DR. HÜLYA ÇİÇEK

Issued: 30.12.2025
ISBN: 978-625-5694-65-2

ASSOCIATION & ACADEMIC INCENTIVES :
In the conference 427 papers have been presented by Turkish participants and 444 papers by foreign participants.
Members of the organizing committees of the conference perform their duties with an "official assignment letter"

All rights of this book belong to Academy Global Publishing House
Without permission can't be duplicate or copied.
Authors of chapters are responsible both ethically and juridically.
Academy Global–2025©

CONFERENCE ID

EGE 14TH INTERNATIONAL CONFERENCE ON APPLIED SCIENCES

DATE – PLACE

DECEMBER 23 - 29, 2025
IZMIR

ORGANIIZATION

ACADEMY GLOBAL CONFERENCES & JOURNALS

EVALUATION PROCESS

All applications have undergone a double-blind peer review process.

PARTICIPATING COUNTRIES

Turkey – Iran – Mongolia – Georgia – India- Tanzania- Hungary – Malaysia- - Tunisia- Tajikistan- Germany -Japan – Serbia- Egypt – Algeria- Lebanon- Saudi Arabia – Cambodia – Spain- Kyrgyzstan – Albania – Pakistan- Russia- Kenya- North Macedonia- Kazakhstan – Indonesia – Bangladesh – Greece – Moldova – Nigeria – China - Oman – Philippines – Azerbaijan – Dubai - , Ethiopia – Qatar – Vietnam-

-

PRESENTATION

Oral presentation

CONGRESS ORGANIZING BOARD

Prof. Dr. Hülya Çiçek - Gaziantep Universitesi

Prof. Dr. Ali Bilgili - Ankara Üniversitesi

Prof. Dr. Naile Bilgili - Gazi Üniversitesi

Prof. Dr. Başak Hanedan - Atatürk Üniversitesi

Prof. Dr. Hajar Huseynova - Azerbaijan Devlet Pedagoji Üniversitesi

Prof. Dr. Dwi Sulisworo - Ahmad Dahlan University

Prof. Zain Musa - Royal Academy of Cambodia

Prof. Dr. Sameer Jain - NICMAR University

Prof Yakup Babayev - Azerbaijan Devlet Pedagoji Üniversitesi

Prof. Dr. Suyatno - Ahmad Dahlan University

Prof. Dr. Al-Rashiff H. Mastul -Mindanao State University

Prof. Dr. Alhisan U. Jemsy - Mindanao State University

Prof. Dr. Elif Akpınar Külekçi - Atatürk Üniversitesi

Prof. Dr. Mehtap Kavurmacı - Atatürk Üniversitesi

Prof. Dr. Belkıs Özkara - Afyon Kocatepe Üniversitesi

Prof. Dr. Mavlonova Ugiloy Khamdamovna - Zarmed University

Assoc. Prof. Dr. Aysel Arslan - Sivas Cumhuriyet Üniversitesi

Assoc. Prof. Dr. Yeliz Çakır Sahilli - Munzur Üniversitesi

Assoc. Prof. Dr. Sıddık BAKIR - Ataturk Universitesi

Assoc. Prof. Dr. Berna Koçak - Munzur Üniversitesi

Assoc. Prof. Dr. Irade Kerimova - Azerbaycan Devlet Pedagoji Üniversitesi

Assoc. Prof. Dr. Dhesi Ari Astuti - Ahmad Dahlan University

Assoc. Prof. Dr. Mehmet Fırat Baran - Batman Üniversitesi

Assoc. Prof. Dr. Abdulkadir Aydın - Dicle Üniversitesi

Assoc. Prof. Dody Hartanto - Ahmad Dahlan University

Assoc. Prof. Dr. Rungchacadaporn - Ahmad Dahlan University

Assoc. Prof. Nazile Abdullazade - Azerbaijan Devlet Pedagoji Üniversitesi

Assoc Prof. Dr. Feran Aşur - Van Yüzüncü Yıl Üniversitesi

Assoc Prof. Dr. Erkan EFİLTİ - Kırgızistan-Türkiye Manas University

Assoc. Prof. Dr. Dini Yuniarti - Ahmad Dahlan University

Assoc. Prof. Ivaylo Staykov - New Bulgarian Üniversitesi

Assoc. Prof. Dr. Abbas Ghaffari - Tebriz Universitesi

Assoc. Prof. Dr. Yasemin Taş - Gazi Üniversitesi

Assoc. Prof. Dr. Yeganə Qəhrəmanova - Azerbaijan Devlet Pedagoji Üniversitesi

Assoc. Prof. Dr. Bülent Işık - Karamanoğlu Mehmet Bey Üniversitesi

Assoc. Prof. Dr. Nurkan Yılmaz - İnönü Üniversitesi

Assoc. Prof. Dr. Həmzə Əliyev- Azerbaijan Devlet Pedagoji Üniversitesi

Assoc. Prof. Dr. Sevra Fırıncıoğulları

Assist. Prof. Ihwan Ghazali - Technic University of Malaysia

Assist. Prof. Dr. Abışov Elşad Şərəfxan oğlu- Azerbaijan Devlet Pedagoji Üniversitesi

Assist. Prof. Dr. Mahrukh Dovlatzade - Azerbaijan Devlet Pedagoji Üniversitesi

Assist. Prof. Dr. Naci Büyükkaracığan- Selçuk Üniversitesi

Assist. Prof. Dr. Songül Atak - Dicle Üniversitesi

Lecturer Mehmet Nuri Ödük - Selçuk Üniversitesi

Dr. Fatih İ. Kurşunmaden - Selçuk Üniversitesi

Assist. Prof. Dr. Mehdi Meskini Heydarlou –

Dr. Dadash Mehravari - Tebriz Universitesi

Dr. Aynurə Əliyeva - Azerbaijan Devlet Pedagoji Üniversitesi

Dr. Gültekin Gürçay

Dr. Amaneh Manafidizajı

Scientific & Review Committee

Prof. Dr. Hülya Çiçek – Turkiye

Prof. Dr. Emine Koca – Turkiye

Prof. Dr. Fatma Koç – Turkiye

Prof. Dr. Valide Paşayeva - Türkiye

Prof. Dr. Ali Bilgili - Turkiye

Prof. Dr. Naile Bilgili - Turkiye

Prof. Dr. Başak Hanedan – Turkiye

Prof. Dr. Aysel Güven - Turkiye

Prof Dr. Bülent Kurtişoğlu – Turkiye

Prof. Dr. Hajar Huseynova – Azerbaijan

Prof. Dr. Dwi Sulisworo – Indonesia

Prof. Dr. Natalia Latygina – Ukraina

Prof. Dr. Yunir Abdrahimov – Russia

Prof. Muntazir Mehdi – Pakistan

Prof. Dr. T.Venkat Narayana Rao – India

Prof. Dr. İzzet Gümüş – Turkiye

Prof. Dr. Mustafa Bayram – Turkiye

Prof. Dr. Saim Zeki Bostan – Turkiye

Prof. Dr. Hyeonjin Lee – China

Prof. Yakup Babayev - Azerbaijan

Prof. Dr. Suyatno – Indonesia

Prof. Dr. Zain Musa – Cambodia

Prof. Dr. Sameer Jain – India

Prof. Mehdi Mohammadzade – Iran

Prof. Dr. Ika Maryani – Indonesia

Prof. Dr. Guler Yenice – Turkiye

Prof. Dr. Elif Akpınar Külekçi – Turkiye

Prof. Dr. Mavlonova Ugiloy Khamdamovna – Uzbekistan

Prof. Dr. Mehtap Kavurmacı – Türkiye

Prof. Dr. Belkıs Özkara – Türkiye

Prof. Dr. Al-Rashiff Hamjilani Mastul – Philipinnes

Prof. Dr. Alhisan U. Jemsy – Philippines

Assoc. Prof. Dr. Aysel Arslan - Turkiye

Assoc. Prof. Dr. Sıddık Bakır – Turkiye

Assoc. Prof. Dr. Meryem Öztürk - Turkiye

Assoc. Prof. Dr. Yeliz Çakır Sahilli - Turkiye

Assoc. Prof. Dr. Berna Koçak - Turkiye

Assoc. Prof. Dr. Dhesi Ari Astuti – Indonesia

Assoc. Prof. Dr. Abdulkadir Aydın - Turkiye

Assoc Prof. Dr. Feran Aşur – Turkiye

Assoc. Prof. Dr. Yasemin Taş – Turkiye

Assoc. Prof. Dr. Bülent Işık - Turkiye

Assoc. Prof. Dr. Nurkan Yılmaz - Turkiye

Assoc. Prof. Dr. Sevra Fırıncıoğulları - Turkiye

Assoc. Prof. Dr. Abdulsemet Aydın – Turkiye

Assoc. Prof. Dr. Mehmet Fırat Baran - Turkiye

Assoc. Prof. Dr. Dilorom Hamroeva - Ozbekistan

Assoc. Prof. Dr. Abbas Ghaffari – Iran

Assoc. Prof. Ivaylo Staykov - Bulgaria

Assoc. Prof. Dr. Dini Yuniarti – Indonesia

Assoc. Prof. Dr. Ümit Ayata – Turkiye

Assoc. Prof. Dr. Həmzə Əliyev - Azerbaijan

Assoc. Prof. Dr. Okan Sarıgöz – Turkiye

Assoc. Prof. Dr. Eda Bozkurt – Turkiye

Assoc. Prof. Dr. Ahmet Topal – Turkiye

Assoc. Prof. Dr. Abdulkadir Kırbaş – Turkiye

Assoc. Prof. Dr. Mesut Bulut – Turkiye

Assoc. Prof. Dr. Fahriye Emgili – Turkiye

Assoc. Prof. Dr. Sandeep Gupta – India

Assoc. Prof. Dr. Veysel Parlak – Turkiye

Assoc. Prof. Dr. Mahmut İslamoğlu – Turkiye

Assoc. Prof. Dr. Nazile Abdullazade – Azerbaijan

Assoc. Prof. Dr. Irade Kerimova - Azerbaijan

Assoc. Prof. Dr. Yeganə Qəhrəmanova – Azerbaijan

Assoc. Prof. Dr. Ali Vandshoari – İran

Assoc. Prof. Dr. Dinara Fardeeva – Rusya

Assoc. Prof. Dr. Göksel Ulay – Turkiye

Assoc. Prof. Dr. Erkan Efilti - Kirgizhstan

Assist. Prof. K. R. Padma – India

Assist. Prof. Dr. Omid Afghan - Afghanistan

Assist. Prof. Dr. Maha Hamdan Alanazi - Saudi Arabia

Assist. Prof. Dr. Dzhakipbek Altaevich Altayev - Kazakhstan

Assist. Prof. Dr. Amina Salihi Bayero – Nigeria

Assist. Prof. Dr. Ahmad Sharif Fakheer - Jordania

Assist. Prof. Dr. Dody Hartanto - Indonesia

Assist. Prof. Dr. Ihwan Ghazali - Malaysia

Assist. Prof. Dr. Mehdi Meskini Heyladou – Iran

Assist. Prof. Dr. Bazarhan İmangalieva - Kazakhstan

Assist. Prof. Dr. Keles Nurmaşulı Jaylıbay - Kazakhstan

Assist. Prof. Dr. Mamatkuli Juraev – Ozbekistan

Assist. Prof. Dr. Kalemkas Kalibaeva – Kazakhstan

Assist. Prof. Dr. Bouaraour Kamel – Algeria

Assist. Prof. Dr. Alia R. Masalimova - Kazakhstan

Assist. Prof. Dr. Amanbay Moldibaev - Kazakhstan

Assist. Prof. Dr. Ayslu B. Sarsekenova - Kazakhstan

Assist. Prof. Dr. Bhumika Sharma - India

Assist. Prof. Dr. Gulşat Şugaeva – Kazakhstan

Assist. Prof. Dr. K.A. Tleubergenova - Kazakhstan

Assist. Prof. Dr. Cholpon Toktosunova – Kirgizia

Assist. Prof. Dr. Hoang Anh Tuan – Vietnam

Assist. Prof. Dr. Songül Atak - Türkiye

Assist. Prof. Dr. Botagul Turgunbaeva - Kazakhstan

Assist. Prof. Dr. Dinarakhan Tursunalieva - Kirgizia

Assist. Prof. Dr. Yang Zitong – China

Assist. Prof. Dr. Gulmira Abndirasulova – Kazakhstan

Assist. Prof. Dr. Imran Latif Saifi – South Africa

Assist. Prof. Dr. Murat Genç – Turkiye

Assist. Prof. Dr. Monisa Qadiri – India

Assist. Prof. Dr. Vaiva Balciuniene – Lithuania

Assist. Prof. Dr. Meltem Avan – Turkiye

Assist. Prof. Dr. Abışov Elşad Şərəfxan oğlu - Azerbaijan

Assist. Prof. Dr. Mahrukh Dovlatzade – Azerbaijan

Assist. Prof. Dr. Naci Büyükkaracığan – Turkiye

Assist. Prof. Dr. Raihan Yusoph – Philippines

Dr. Que-Nhu Duong - Vietnam

Dr. Fatih İ. Kurşunmaden – Turkiye

Dr. Mehmet Nuri Ödük – Turkiye

Dr. Ayşe Baran - Turkiye

Dr. Aynurə Əliyeva - Azerbaijan

Dr. Sonali Malhotra – India

Dr. Amaneh Manafidizaji - Iran

EGE 14TH INTERNATIONAL CONFERENCE ON APPLIED SCIENCES
DECEMBER 23 - 29, 2025
IZMIR

NO : **AC- 14A - 2025. 438u– 3051**
Konu : Akademik Teşvik Uygunluk Belgesi 29/12/2025

İLGİLİ MAKAMA

Academy Global Conferences tarafından düzenlenen **Ege 14. Uluslararası Uygulamalı Bilimler Kongresi** 23-29 Aralık 2025 tarihlerinde Ege'de 40 farklı ülkeden akademisyenin katılımıyla gerçekleştirilmiştir. Kongre kapsamında sunulan 871 bildirinin 427'si Türkiye'den, 444'ü ise farklı 39 ülkeden katılan akademisyenler tarafından sunulmuştur. Kongre, 16 Ocak 2020 Akademik Teşvik Ödeneği Yönetmeliğine getirilen "Tebliğlerin sunulduğu yurt içinde veya yurt dışındaki etkinliğin uluslararası olarak nitelendirilebilmesi için Türkiye dışında en az beş farklı ülkeden sözlü tebliğ sunan konuşmacının katılım sağlaması ve tebliğlerin yarıdan fazlasının Türkiye dışından katılımcılar tarafından sunulması esastır." değişikliğine uygun olarak düzenlenmiştir.

Bilgilerinize arz ederiz

Saygılarımızla



Prof. Dr. Hülya Çiçek

T.C.
GAZİANTEP ÜNİVERSİTESİ REKTÖRLÜĞÜ
Tıp Fakültesi

Sayı : E-98102723-903.07-475454
Konu : Görevlendirme Talebi

REKTÖRLÜK MAKAMINA

İlgi : 27.03.2024 tarihli ve E--903.07-474236 sayılı yazı

Fakültemiz Tıbbi Biyokimya Anabilim Dalı'nda görevli öğretim üyesi Prof. Dr. Hülya ÇİÇEK'in Yükseköğretim Genel Kurulunun 15.06.2023 tarihli, 10 sayılı oturumunda alınan 2023.10.183 sayılı kararı gereğince Doçentlik Başvuru Şartlarında bulunan ve doçent olacak adaylardan istenen "Diğer uluslararası/ ulusal bilimsel toplantının düzenleme komitesinde resmi olarak görevlendirilmiş üniversite akademisyen temsilcisi bulunması zorunludur." maddesi gereğince, Academy Global Conference & Journals tarafından yapılan kongrelerin düzenleme kurullarında yolluksuz ve yevmiyesiz olarak görevlendirilme talebi ile ilgili dilekçesi ekte gönderilmiştir

Adı geçen öğretim üyesinin Academy Global Conference & Journals tarafından yapılan kongrelerin düzenleme kurullarında yolluksuz, yevmiyesiz olarak görevlendirilmesinde Dekanlığımızca bir sakınca bulunmamaktadır.

Onaylarınıza arz ederim

Prof.Dr. Şevki Hakan EREN
Dekan

OLUR

Prof.Dr. Arif ÖZAYDIN
Rektör

Ek:İlgi Dilekçe (1 Adet)

Dağıtım:
Gereği:
Tıbbi Biyokimya Anabilim Dalı Başkanlığı

Bilgi:
Sayın Prof.Dr. Hülya ÇİÇEK

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : *BSFN3RR3CF* Pin Kodu : 27962 Belge Takip Adresi : https://turkiye.gov.tr/gaziantep-universitesi-ebys

Adres : Gaziantep Üniversitesi Kampus Alanı, Tıp Fakültesi Dekanlığı, Şehitkamil - 27310 - GAZİANTEP
Telefon : 0 (342) 360 60 60 Faks:0 (342) 360 16 17
e-Posta : tipfaksek@gmail.com Web : www.gantep.edu.tr/~tipdekanlik/bilgipaketi
Kep Adresi : gauntipdek@hs01.kep.tr

Bilgi için : Hüseyin Temel
Unvanı : Bilgisayar İşletmeni V.

T.C.
GAZİANTEP ÜNİVERSİTESİ REKTÖRLÜĞÜ
Tıp Fakültesi

Sayı : E-98102723-903.07-475454
Konu : Görevlendirme Talebi

REKTÖRLÜK MAKAMINA

İlgi : 27.03.2024 tarihli ve E--903.07-474236 sayılı yazı

Fakültemiz Tıbbi Biyokimya Anabilim Dalı'nda görevli öğretim üyesi Prof. Dr. Hülya ÇİÇEK'in Yükseköğretim Genel Kurulunun 15.06.2023 tarihli, 10 sayılı oturumunda alınan 2023.10.183 sayılı kararı gereğince Doçentlik Başvuru Şartlarında bulunan ve doçent olacak adaylardan istenen "Diğer uluslararası/ ulusal bilimsel toplantının düzenleme komitesinde resmi olarak görevlendirilmiş üniversite akademisyen temsilcisi bulunması zorunludur." maddesi gereğince, Academy Global Conference & Journals tarafından yapılan kongrelerin düzenleme kurullarında yolluksuz ve yevmiyesiz olarak görevlendirilme talebi ile ilgili dilekçesi ekte gönderilmiştir

Adı geçen öğretim üyesinin Academy Global Conference & Journals tarafından yapılan kongrelerin düzenleme kurullarında yolluksuz, yevmiyesiz olarak görevlendirilmesinde Dekanlığımızca bir sakınca bulunmamaktadır.

Onaylarınıza arz ederim

Prof.Dr. Şevki Hakan EREN
Dekan

OLUR

Prof.Dr. Arif ÖZAYDIN
Rektör

Ek:İlgi Dilekçe (1 Adet)

Dağıtım:
Gereği:
Tıbbi Biyokimya Anabilim Dalı Başkanlığı

Bilgi:
Sayın Prof.Dr. Hülya ÇİÇEK

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : *BSFN3RR3CF* Pin Kodu : 27962 Belge Takip Adresi : https://turkiye.gov.tr/gaziantep-universitesi-ebys

Adres : Gaziantep Üniversitesi Kampus Alanı, Tıp Fakültesi Dekanlığı, Şehitkamil - 27310 - GAZİANTEP
Telefon : 0 (342) 360 60 60 Faks:0 (342) 360 16 17
e-Posta : tipfaksek@gmail.com Web : www.gantep.edu.tr/~tipdekanlik/bilgipaketi
Kep Adresi : gauntipdek@hs01.kep.tr

Bilgi için : Hüseyin Temel
Unvanı : Bilgisayar İşletmeni V.

Evrak Tarih ve Sayısı: 27.03.2024-474236

BSPN381RTL

Sayı : 903.07/
Konu : Görevlendirme

TIP FAKÜLTESİ DEKANLIĞINA

Yükseköğretim Genel Kurulunun 15.06.2023 tarihli, 10 sayılı oturumunda alınan 2023.10.183 sayılı kararı gereğince Doçentlik Başvuru Şartlarında bulunan ve doçent olacak adaylardan istenen "Diğer uluslararası/ ulusal bilimsel toplantının düzenleme komitesinde resmi olarak görevlendirilmiş üniversite akademisyen temsilcisi bulunması zorunludur." maddesi gereğince, Academy Global Conference & Journals tarafından yapılan kongrelerin düzenleme kurullarında yolluksuz ve gündeliksiz olarak Rektörlük makamının oluru ile görevlendirilmem hususunda gereğini bilgilerinize arz ederim.

Prof.Dr. Hülya Çiçek
Öğretim Üyesi

EGE 14th INTERNATIONAL CONFERENCE ON SOCIAL SCIENCES
EGE 14th INTERNATIONAL CONFERENCE ON APPLIED SCIENCES
ARTWorld 7TH INTERNATIONAL GROUP EXHIBITION
December 23 - 29, 2025
IZMIR

Kongre Bağlantı Linki :

Join Zoom Meeting

https://us06web.zoom.us/j/88571518350?pwd=fOYazCWBmbAiWrHygjKSjkbbSvotfd.1

Meeting ID: 885 7151 8350

Passcode: 202224



EGE 14th INTERNATIONAL CONFERENCE ON APPLIED SCIENCES
December 23 - 29, 2025
IZMIR

YÜZYÜZE

27 Aralık / Dec 27, 2025 / 11:00 – 13:00 Time zone in Turkey (GMT+3)

Salon	Moderator		Bildiri No ve Başlığı / Paper ID and Title	Authors
HALL / SALON 2	Prof.Dr. Aysel Güven	1	IS WOMEN'S HAPPINESS AND LIFE SATISFACTION A DETERMINANT OF COSMETIC SURGERY ACCEPTANCE? LATENT PROFILE ANALYSIS	Dr. Öğr. Üyesi Yağmur SÜRMELİ Dr. Öğr. Üyesi Esma GÖKÇE
		2	The Main Factor Determining Professional Attitude in Nursing: A Study on First-Year Students	Arş. Gör., Büşra Yürük, Dr. Öğr. Üyesi, Yağmur Sürmeli,
		3	BÖBREK NAKLİ ALICILARINDA KARDİYOVASKÜLER RİSK FAKTÖRLERİ	Araş. Gör. Dr. Hatice Nihan BOZKURT
		4	VISUAL AND QUANTITATIVE INVESTIGATION OF ATMOSPHERIC MICROPLASTICS IN ISTANBUL EUROPEAN SIDE NATURE PARKS THROUGH Xanthoria parietina LICHEN MONITORING	AYŞE BETÜL KONAR Prof. Dr. Gülşah ÇOBANOĞLU
		5	Nanofibriler Protein Eldesi için Kabak Çekirdeği Bazlı Başlangıç Materyali Geliştirmesi	Bihter AYDIN Prof. Dr. Seher KUMCUOĞLU
		6	FROM AMPELOGRAPHY TO DIGITAL AMPELOGRAPHY: CONVOLUTIONAL NEURAL NETWORK APPROACHES İN PRECISION VITICULTURE	Adnan DOĞAN Deniz Uğur GÜZEL
		7	DIGITAL TRANSFORMATION IN VITICULTURE: INTEGRATED USE OF ARTIFICIAL INTELLIGENCE, REMOTE SENSING, IOT, AND AUTONOMOUS SYSTEMS	Adnan DOĞAN Deniz Uğur GÜZEL
		8	ANTIOXIDATIVE INGREDIENTS AND BIOCHEMICAL METABOLISM OF TEA AND GRAPES	Prof.Dr. Aysel Güven

ISBN NR: 978-625-5694-65-2

AMPELOGRAFİDEN DİJİTAL AMPELOGRAFA: HASSAS BAĞCILIKTA CNN YAKLAŞIMLARI

FROM AMPELOGRAPHY TO DIGITAL AMPELOGRAPHY: CONVOLUTIONAL NEURAL NETWORK APPROACHES IN PRECISION VITICULTURE

Adnan DOĞAN

Yüzüncü Yıl Üniversitesi, Bahçe Bitkileri Bölümü, Van

adnandogan@yyu.edu.tr- 0000-0002-0349-3846

Deniz Uğur GÜZEL

Tarım Orman İl Müdürlüğü, Van

denizugur.guzel@tarimorman.gov.tr- 0000-0003-2606-3985

Özet

Bağcılık, küresel tarım ekonomisinin en önemli sektörlerinden biri olmasının yanı sıra, kültürel miras ve coğrafi kimliğin de taşıyıcısıdır. Üzüm çeşitlerinin doğru ve güvenilir sınıflandırılması, menşe sertifikasyonu, tüketici güveni ve tarımsal sürdürülebilirlik açısından kritik öneme sahiptir. Geleneksel ampelografi, yaprak morfolojisi ve salkım yapısı gibi fenotipik özelliklerin uzmanlarca görsel incelenmesine dayanmakla birlikte, öznellik, fenotipik plastisite ve ölçeklenebilirlik sorunları nedeniyle modern bağcılığın ihtiyaçlarını karşılamakta yetersiz kalmaktadır. Hassas Bağcılık paradigması, veri odaklı ve otomatik yöntemlerle bağ yönetimini dönüştürürken, Evrişimsel Sinir Ağları (CNN'ler) bu dönüşümün en güçlü katalizörü olmuştur. Bu derleme, CNN tabanlı dijital ampelografi yaklaşımlarını sistematik olarak incelemekte; kullanılan veri setlerini, model mimarilerini, performans metriklerini ve karşılaşılan temel zorlukları değerlendirmektedir. Çalışma, araştırmacılara ve sektör profesyonellerine, geleneksel bilgelik ile yapay zekânın gücünü birleştiren yeni nesil bağcılık sistemlerinin bilimsel temelini ve gelecekteki araştırma yönelimlerini sunmaktadır.

Anahtar kelime: Ampelografi, Dijital Ampelografi, Hassas Bağcılık, Evrişimsel Sinir Ağları (CNN), Derin Öğrenme

*: Van Yüzüncü Yıl Üniversitesi BAP Koordinasyon Ofisi tarafından FDK-2024-11262 numaralı proje kapsamında desteklenmiştir.

Abstract

Viticulture is not only a cornerstone of the global agricultural economy but also a bearer of cultural heritage and geographical identity. Reliable identification and classification of grapevine cultivars are essential for origin certification, consumer trust, and agricultural

ISBN NR: 978-625-5694-65-2

sustainability. Traditional ampelography, based on visual inspection of leaf morphology and cluster traits, has long served this purpose; however, its subjectivity, phenotypic plasticity, and limited scalability restrict its applicability in modern viticulture. Precision Viticulture (PV) introduces data-driven and automated vineyard management, with Convolutional Neural Networks (CNNs) emerging as the most powerful catalyst of this transformation. This review systematically examines CNN-based digital ampelography approaches, analyzing datasets, model architectures, performance metrics, and major challenges such as data imbalance and domain adaptation. The study provides researchers and industry professionals with a scientific roadmap for integrating traditional expertise with artificial intelligence, shaping the future of viticulture through scalable, accurate, and explainable digital systems.

Keywords: Ampelography, Digital Ampelography, Precision Viticulture, Convolutional Neural Networks (CNN), Deep Learning

*: This study was supported by the Van Yüzüncü Yıl University Scientific Research Projects (BAP) Coordination Office under project number FDK-2024-11262.

1. Giriş

Bağcılık, yalnızca tarımsal bir faaliyet değil, aynı zamanda küresel ekonominin yüz milyarlarca dolarlık dinamosu ve binlerce yıllık kültürel mirasın somutlaşmış halidir (American Association of Wine Economists, 2006). Dünya genelinde üzüm üretimi; şarap endüstrisi, sofralık üzüm, kuru üzüm ve türevleriyle birlikte uluslararası ticaretin ve tüketici güveninin temel taşlarından biridir. Özellikle menşe işaretli bölgeler ve tescilli üretimler için şarap sertifikasyonu, yasal ve kalite kontrol açısından hayati bir süreçtir (Giacomarra vd., 2016). Bu bağlamda, tarladan şişeye kadar izlenebilirlik, bağcılığın küresel ölçekte rekabet gücünü belirleyen kritik bir unsur haline gelmiştir.

Asırlar boyunca üzüm çeşitlerinin kimlik tespiti, Ampelografi adı verilen disiplin aracılığıyla yaprak morfolojisi, salkım yapısı ve sürgün özelliklerinin uzmanlarca görsel ve elle incelenmesine dayanmıştır (Garcia-Muñoz vd., 2011). Ancak bu yöntem doğası gereği özneldir, uzun yıllara dayalı deneyim gerektirir ve geniş bağ alanlarında uygulanması maliyetli ve zaman alıcıdır (Birkhaeuser vd., 1991). Dahası, aynı varyetenin farklı iklim, toprak ve bağ yönetim koşullarında gösterdiği fenotipik esneklik, geleneksel ampelografik sınıflandırmanın güvenilirliğini zorlaştırmaktadır (Stavrakaki & Biniari, 2016). Bu ölçeklenebilirlik ve objektiflik açığı, modern bağcılığın Hassas Bağcılık (Precision Viticulture, PV) felsefesiyle çelişmektedir. PV, bağ yönetimini veri odaklı, hedefe yönelik ve otomatik hale getirmeyi amaçlar (Matese & Di Gennaro, 2015; Mulla & Khosla, 2015).

Bu dönüşümün katalizörü, görüntü tanıma ve sınıflandırma görevlerinde devrim yaratan Derin Öğrenme (Deep Learning, DL) teknolojileri ve özellikle Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNNs) olmuştur (LeCun, Bengio, & Hinton, 2015). CNN'ler, biyolojik görüntü verilerinden hiyerarşik ve karmaşık örüntüleri otomatik olarak öğrenme yeteneği sayesinde uzman bağımlılığını azaltmış ve üzüm çeşitlerinin sınıflandırılması, hastalık tespiti ve verim tahmini gibi PV uygulamalarında insanüstü doğruluk sergilemiştir (Singh vd., 2017; Terzi, Ozguven, & Yagci, 2024).

ISBN NR: 978-625-5694-65-2

Bu derleme, bağcılığın bu kritik dönüşüm noktasını ele almaktadır: Geleneksel ampelografiden, objektif ve nicel verilere dayanan Dijital Ampelografi'ye geçiş. Çalışma, mevcut literatürü kapsamlı bir Görselde analiz ederek kullanılan veri setlerini, CNN mimarilerini (ResNet, VGG, MobileNet, Xception), elde edilen performans metriklerini ve bu teknolojilerin önündeki en büyük engelleri (örneğin veri seti dengesizliği, alan transfer edilebilirliği) değerlendirecektir. Nihai hedef, araştırmacılara ve sektör profesyonellerine, geleneksel bilgelik ile yapay zekânın gücünü birleştiren yeni nesil bağcılık sistemlerinin bilimsel temelini ve gelecekteki araştırma yönelimlerini sunmaktır.

Bu çalışma, 2010–2025 yılları arasında yayımlanan makaleler ve derleme çalışmalarını kapsamaktadır. Literatür taraması, Web of Science, Scopus, IEEE Xplore ve ScienceDirect veri tabanlarında "digital ampelography", "precision viticulture", "CNN grape classification" ve "deep learning in agriculture" anahtar kelimeleri kullanılarak yürütülmüştür. Toplam 87 kaynak incelenmiş, bunlardan konu bütünlüğü, metodolojik sağlamlık ve özgün katkı kriterlerine uyan 60 çalışma detaylı analiz edilmiştir. Derleme, bu kaynaklardaki yöntem, veri seti, model mimarisi ve performans metriklerine odaklanmıştır.

2. Geleneksel Ampelografi ve Sınırlılıkları

Ampelografi, asma (*Vitis vinifera* L.) tür ve çeşitlerini tanımlama ve sınıflandırma bilimidir. Tarihsel olarak bu disiplin, yaprak morfolojisi, sürgün özellikleri, salkım yapısı ve tane formu gibi fenotipik karakterlerin dikkatli gözlemlerine dayanmıştır (Garcia-Muñoz vd., 2011). Uzman ampelograflar, yaprakların şekli, lob sayısı, damar yapısı ve kenar dişliliği gibi yüzlerce morfolojik parametreyi değerlendirerek çeşitleri birbirinden ayırmaya çalışmışlardır.

Ancak bu geleneksel yaklaşım, modern bağcılığın ihtiyaçlarını karşılamakta önemli sınırlılıklar taşımaktadır:

- **Öznellik ve uzman bağımlılığı:** Morfolojik karakterlerin değerlendirilmesi büyük ölçüde uzmanın deneyimine ve yorumuna bağlıdır. Bu durum, farklı uzmanlar arasında tutarsızlıklara yol açmakta ve standardizasyonu zorlaştırmaktadır (Birkhaeuser, Löffler, & Larcher, 1991).
- **Fenotipik plastisite:** Üzüm çeşitleri, farklı çevresel koşullar (iklim, toprak, rakım) ve yetiştirme teknikleri (budama, sulama) altında farklı morfolojik özellikler sergileyebilir. Aynı çeşidin farklı bölgelerde farklı görünmesi, görsel tanımlamayı yanıltıcı hale getirmektedir (Stavrakaki & Biniari, 2016).
- **Maliyet ve zaman verimsizliği:** Geniş bağ alanlarında binlerce asmanın tek tek elle incelenmesi, yoğun iş gücü ve uzun süre gerektirir. Bu durum, özellikle endüstriyel ölçekli bağlarda uygulanabilirliği sınırlamaktadır.

Bu sınırlılıklar, bağcılıkta daha **objektif, hızlı ve ölçeklenebilir** tanımlama yöntemlerine duyulan ihtiyacı açıkça ortaya koymaktadır. Geleneksel ampelografi, uzman bilgeliğini yansıtan değerli bir disiplin olmakla birlikte, günümüzde Hassas Bağcılık (Precision Viticulture) paradigmasının veri odaklı ve otomatik yaklaşımıyla çelişmektedir.

Aşağıdaki Çizelge, geleneksel ve dijital ampelografinin temel farklılıklarını özetlemektedir:

ISBN NR: 978-625-5694-65-2

Çizelge 1. Geleneksel ve Dijital Ampelografi arasındaki temel farklar.

Kriter	Geleneksel Ampelografi	Dijital Ampelografi
Veri tipi	Nitel, gözlemsel	Nicel, ölçülebilir
Öznellik	Yüksek	Düşük (otomatik)
Deneyim gereksinimi	Uzun yıllar	Transfer öğrenme ile kısa
Hız	Yavaş, manuel	Hızlı, otomatik
Ölçeklenebilirlik	Düşük	Yüksek (geniş alanlar)
Maliyet	Yüksek (uzman iş gücü)	Düşük (operasyonel)
Tekrarlanabilirlik	Düşük	Yüksek
Entegrasyon	Sınırlı	Karar destek sistemleriyle uyumlu

Çizelge 1'de Geleneksel ve dijital ampelografi yaklaşımlarının farklarını özetleyerek, ölçeklenebilirlik ve otomasyonun dijital yöntemlerdeki avantajını ortaya koymaktadır.

3. Hassas Bağcılık ve Dijitalleşme

3.1 Hassas Tarımın Evrimi

Hassas Tarım (*Precision Agriculture, PA*), 1980'lerden itibaren tarımsal üretimde verimliliği artırmak, girdi kullanımını optimize etmek ve çevresel etkiyi azaltmak amacıyla geliştirilmiş bir paradigma olarak tanımlanmaktadır (Mulla & Khosla, 2015). PA'nın temel amacı, tarla içi varyasyonu yöneterek üretim süreçlerini daha verimli, sürdürülebilir ve kârlı hale getirmektir (Bongiovanni & Lowenberg-DeBoer, 2004). Bu yaklaşım, özellikle Akdeniz ülkelerinde tarımsal ekonomiye önemli katkılar sağlamaktadır (Peris-Ortiz vd., 2015).

3.2 Hassas Bağcılığın Doğuşu

Bağcılık özelinde **Hassas Bağcılık (Precision Viticulture, PV)**, 1990'lı yıllardan itibaren Avustralya (Bramley & Lamb, 2003) ve ABD'de (Wample vd., 1999) başlatılan projelerle gelişmiş, günümüzde bağ yönetiminde verim ve kaliteyi artırırken çevresel etkiyi azaltmayı hedefleyen bir uygulama alanı haline gelmiştir (Matese & Di Gennaro, 2015; Santesteban, 2019). PV'nin temel bileşenleri, bağ yönetiminin her aşamasında doğru ve otomatik veri toplama ve analizini gerektiren çok boyutlu teknolojilerden oluşmaktadır.

3.3 Dijitalleşmenin Bileşenleri

PV'nin dijitalleşme süreci üç ana teknoloji alanına dayanmaktadır:

- **Yerinde İzleme Sistemleri**
    - *Toprak sensörleri:* Elektriksel iletkenlik ve rezistivite ölçümleri ile toprak yapısı ve nem durumu belirlenmektedir (Lee vd., 2010; Georgieva vd., 2016).
    - *Bitki sensörleri:* Yaprak nemi, fotosentetik aktivite ve besin eksikliklerini ölçen sistemler, bağın fizyolojik durumunu ortaya koymaktadır (Mahlein vd., 2012).

ISBN NR: 978-625-5694-65-2

- *Çevresel sensörler:* Mikroklima verileri (sıcaklık, nem, ışık) bağın fenolojik gelişim evrelerini izlemek için kullanılmaktadır (Pérez-Expósito vd., 2017; Yost vd., 2017).

- **Uzaktan Algılama Teknolojileri**
  - *İnsansız hava araçları (UAV):* Yüksek çözünürlüklü multispektral ve hiperspektral görüntülerle bağların vigor haritaları çıkarılmakta, hastalık ve stres faktörleri erken dönemde tespit edilmektedir (Pádua vd., 2017; Adão vd., 2017).
  - *Uydular:* Landsat serisi gibi platformlar, geniş ölçekli bağ alanlarının sınıflandırılmasında kullanılmıştır. Örneğin, Landsat 1 ile ABD'de tarım alanları %83 doğrulukla sınıflandırılmıştır (Bhatti vd., 1991; Mulla, 2013).
- **Uygulama Teknolojileri**
  - *Verim ve kalite izleme:* Hasat sırasında doğrudan üzüm ağırlığı ölçülerek verim haritaları oluşturulmaktadır (Hall vd., 2002). Taşınabilir cihazlarla üzümün asitlik, şeker ve nem düzeyleri ölçülmekte, olgunluk ve kalite parametreleri belirlenmektedir (Marques & Pitarma, 2018).
  - *Değişken Oranlı Teknolojiler (VRT):* GPS ve sensör verileriyle gübreleme, ilaçlama ve sulama işlemleri otomatik olarak değişken oranlarda uygulanmaktadır (Arnó vd., 2009).
  - *Tarımsal robotlar:* Otonom traktörler ve ilaçlama sistemleri, bağ içi operasyonları insan müdahalesi olmadan gerçekleştirebilmektedir (Noguchi vd., 2004; Oberti vd., 2016).

Çizelge 2. Hassas Bağcılıkta dijitalleşmenin temel bileşenleri.

Teknoloji Alanı	Teknoloji	Uygulama Alanı
Yerinde İzleme Sistemleri	Toprak sensörleri (iletkenlik, rezistivite)	Toprak yapısı ve nem durumu
	Bitki sensörleri (yaprak nemi, fotosentez)	Bitkinin fizyolojik durumu, besin eksiklikleri
	Çevresel sensörler (sıcaklık, nem, ışık)	Mikroklima verileri, fenolojik gelişim takibi
Uzaktan Algılama	UAV (multispektral/hiperspektral görüntüleme)	Vigor haritaları, hastalık/stres tespiti
	Uydular	Geniş ölçekli sınıflandırma, uzun dönem trendler
Uygulama Teknolojileri	Taşınabilir cihazlar	Üzüm kalitesi ve olgunluk izleme

ISBN NR: 978-625-5694-65-2

	VRT	Değişken oranlı gübreleme, ilaçlama, sulama
	Tarımsal robotlar	Otonom bağ içi operasyonlar

4. Makine Görme ve Derin Öğrenme Temelleri

4.1 Makine Görme (MV) ve Tarımsal Uygulamalar

Makine görme (*Machine Vision, MV*), bilgisayarların görüntülerden veri çıkararak sınıflandırma, tanıma ve karar destek süreçlerinde kullanmasını sağlayan teknolojidir (Kamilaris & Prenafeta-Boldú, 2018). Tarımsal üretimde MV, bitki morfolojisinin, hastalık belirtilerinin ve verim parametrelerinin otomatik olarak analiz edilmesine olanak tanır.

MV'nin bağcılık ve genel tarım uygulamalarındaki başlıca kullanım alanları:

- **Otonom sistemler ve robotik:** Görsel rehberlik ve engel algılama yetenekleriyle donatılmış tarımsal robotlar, yabancı ot kontrolü, ilaçlama ve hasat gibi görevleri bağımsız Görselde yerine getirebilir (Ball vd., 2016; Adamides vd., 2014).
- **Uzaktan algılama ve İHA uygulamaları:** İnsansız hava araçları (UAV) ile MV birleşerek bağların kanopi yapısı çıkarılabilir, hiperspektral görüntüleme ile hastalık ve stres faktörleri erken dönemde tespit edilebilir (Pádua vd., 2017; Adão vd., 2017).
- **Hastalık ve verim izleme:** MV, yaprak hastalıklarının otomatik tespiti ve meyve sınıflandırması/verim tahmininde kritik rol oynar. Örneğin, mango bahçelerinde yapılan sınıflandırma çalışmaları MV'nin doğrudan ekonomik katkı sağladığını göstermektedir (Sarron vd., 2018).

Bu gelişmeler, MV'nin bağcılıkta yaprak morfolojisi ve salkım yapısının otomatik analizi sayesinde çeşit tanımlama, hastalık erken uyarısı ve verim tahmini için kritik bir araç haline geldiğini göstermektedir.

4.2 Derin Öğrenme (DL) ve Evrişimsel Sinir Ağları (CNNs)

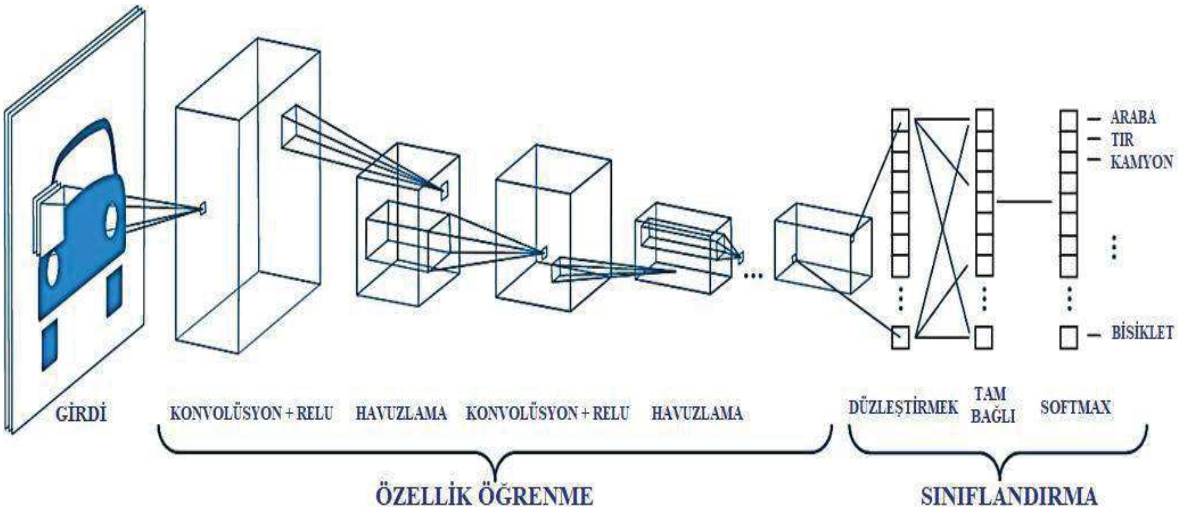
Makine görme teknolojilerinin sınırlı genelleme kapasitesi, 2010'lu yıllarda derin öğrenme (*Deep Learning, DL*) mimarilerinin yükselişiyle aşılmıştır. DL, yüksek boyutlu biyolojik verilerden hiyerarşik ve karmaşık örüntüleri otomatik olarak öğrenme yeteneği sayesinde tarımsal görüntü analizinde devrim yaratmıştır (LeCun, Bengio, & Hinton, 2015).

CNN'ler, görsel korteksten ilham alarak tasarlanmış ve üç temel katmandan oluşur:

- **Evrişim (Convolution) katmanı:** Görüntü üzerinde filtrelerin kaydırılmasıyla kenar, doku ve morfolojik örüntüler çıkarılır.
- **Havuzlama (Pooling) katmanı:** Özellik haritalarının boyutunu küçültür, hesaplama yükünü azaltır ve uzamsal varyasyonlara karşı dayanıklılığı artırır.
- **Tam bağlantılı (Fully Connected) katman:** Çıkarılan özellikleri sınıflandırma görevine aktarır; softmax fonksiyonu ile nihai olasılık dağılımı elde edilir.

ISBN NR: 978-625-5694-65-2

Bu yapı, CNN'leri bitki hastalık tespiti, yaprak sınıflandırma ve meyve sayımı gibi tarımsal uygulamalarda öne çıkarmaktadır (Mohanty, Hughes, & Salathé, 2016; Singh vd., 2017; Wang vd., 2017).



Görsel 1. Temel Evrişimsel Sinir Ağı (CNN) mimarisi: Özellik öğrenme (konvolüsyon + ReLU + havuzlama) ve sınıflandırma (tam bağlı + softmax) aşamaları (Uyarlanmış from Ergin, 2020)

4.3 Transfer Öğrenme ve Modern CNN Mimarileri

CNN'lerin bağcılık gibi spesifik alanlarda başarılı uygulanmasını kolaylaştıran en önemli yaklaşım **transfer öğrenme**dir. ImageNet gibi devasa veri setleri üzerinde önceden eğitilmiş modeller, üzüm yaprağı gibi küçük ve özel veri setlerine aktarılabilir. Bu sayede daha az veriyle yüksek doğruluk elde edilir (Zoph, Vasudevan, Shlens, & Le, 2018; Hossen, Awrangjeb, Pan, & Mamun, 2025).

Bağcılıkta kullanılan başlıca CNN mimarileri:

- **VGG:** Basit ve derin katmanlı yapısıyla yüksek doğruluk sağlar (Simonyan & Zisserman, 2014).
- **ResNet:** "Skip connections" sayesinde derin ağlarda öğrenme zorluklarını aşar (He vd., 2015).
- **Inception:** Paralel filtrelerle zengin özellik çıkarımı yapar (Szegedy vd., 2016).
- **MobileNet:** Hafif yapısıyla mobil cihazlarda ve saha uygulamalarında kullanılabilir (Howard vd., 2017).
- **Xception:** Derinlemesine ayrılabilir evrişimlerle daha verimli özellik çıkarımı sağlar (Chollet, 2016).

5. Bağcılıkta CNN Uygulamaları

ISBN NR: 978-625-5694-65-2

Evrişimsel Sinir Ağları (CNN'ler), bağcılığın pratik sorunlarına yönelik somut çözümler üretme kapasitesiyle öne çıkmaktadır. Geleneksel ampelografinin öznellik ve ölçeklenebilirlik sınırlılıklarını aşarak, üzüm çeşitlerinin sınıflandırılması, hastalıkların erken tespiti, verim tahmini ve olgunluk analizi gibi kritik görevlerde yüksek doğruluk sağlamaktadır.

5.1 Üzüm Çeşidi Sınıflandırması

Dijital ampelografinin en temel uygulaması, üzüm çeşitlerinin yaprak görüntülerinden otomatik olarak sınıflandırılmasıdır. CNN modelleri, insan gözünün ayırt etmekte zorlandığı ince morfolojik farklılıkları ve doku desenlerini öğrenerek, geleneksel yöntemlere kıyasla çok daha yüksek doğruluk sunar.

- Singh ve arkadaşları (2017), VGG ve ResNet mimarilerini kullanarak yaprak lobları ve damar yapılarındaki ince farklılıkları yüksek doğrulukla ayırt edebilmiştir.
- Nasiri, Taheri-Garavand ve Omid (2021), modifiye ettikleri CNN modeli ile %99'un üzerinde sınıflandırma doğruluğu elde etmiştir.
- Terzi, Ozguven ve Yagci (2024), 50 farklı üzüm çeşidini yaprak, salkım ve meyve görüntülerinden sınıflandırarak yeni bir CNN modeli önermiş ve yüksek başarı sağlamıştır.

5.2 Hastalık Tespiti ve Yönetimi

Bağcılıkta verim ve kaliteyi tehdit eden külleme, mildiyö ve kara çürüklük gibi hastalıkların erken tespiti, CNN'lerin en kritik uygulamalarından biridir.

- Mohanty, Hughes ve Salathé (2016), yaprak hastalıklarını renk ve desen analiziyle sınıflandırarak CNN tabanlı sistemlerin gücünü göstermiştir.
- Xie ve arkadaşları (2020), gerçek zamanlı bir CNN tabanlı dedektör ile bağ yaprağı hastalıklarını yüksek doğrulukla izleyebilmiştir.
- Hernandez ve arkadaşları (2025), mildiyö hastalığının erken tespiti için semantik segmentasyon kullanarak hastalıklı bölgeleri sağlıklı dokudan başarıyla ayırmıştır.

Bu sistemler, pestisit kullanımını azaltarak hem ekonomik hem de ekolojik kazanımlar sağlamaktadır.

5.3 Verim Tahmini ve Olgunluk Analizi

Hasat öncesi doğru verim tahmini, lojistik planlama ve kalite kontrol için kritik öneme sahiptir. CNN modelleri, drone veya yer araçlarından elde edilen yüksek çözünürlüklü görüntülerdeki salkımları otomatik olarak tespit edip sayarak daha doğru ve ölçeklenebilir tahminler sunar.

- Wang, Sun ve Wang (2017), CNN tabanlı salkım sayımı ile verim tahmini yapmıştır.
- Di Gennaro ve arkadaşları (2019), UAV ile elde edilen RGB görüntülerini kullanarak düşük maliyetli bir metodoloji ile verim tahmini gerçekleştirmiştir.
- Marques ve Pitarma (2018), renk analizi ile olgunluk seviyesini belirleyerek hasat zamanlamasında karar desteği sağlamıştır.

ISBN NR: 978-625-5694-65-2

Çizelge 3. Bağcılıkta CNN uygulama alanları, katkıları ve örnek çalışmalar.

Uygulama Alanı	CNN'in Katkısı	Örnek / Kaynak
Üzüm Çeşitlerini Sınıflandırma	Yaprak lobları ve damar yapılarındaki ince farklılıkları yüksek doğrulukla ayırır.	Singh vd. (2017); Nasiri vd. (2021); Terzi vd. (2024)
Hastalık ve Zararlı Tespiti	Mildiyö ve antraknoz gibi hastalıkların lekelerini renk ve desen analiziyle sınıflandırır.	Mohanty vd. (2016); Xie vd. (2020); Hernandez vd. (2025)
Kantitatif Fenotipleme	Yaprak Alan İndeksi (LAI) ve canopy yoğunluğu regresyon görevleriyle tahmin edilir.	Patil & Thorat (2016); Marques & Pitarma (2018)
Verim Tahmini	Görüntülerden salkım sayımı yaparak verim tahmini sağlar.	Wang vd. (2017); Di Gennaro vd. (2019)
Olgunluk Tespiti	Renk analizi ile olgunluk seviyesini belirler.	Marques & Pitarma (2018)
Gerçek Zamanlı Uygulamalar	Hafif mimariler (MobileNet, Xception) mobil cihazlarda hızlı sınıflandırma sağlar.	Howard vd. (2017); Chollet (2016)

Çizelge 3'de CNN tabanlı bağcılık uygulamalarını karşılaştırmalı biçimde sunarak, hangi mimarilerin hangi görevlerde öne çıktığını göstermektedir.

6. Veri Setleri, Metodolojiler ve Performans

6.1 Veri Kaynakları ve Çeşitlilik

CNN modellerinin başarısı, büyük ölçüde kullanılan veri setlerinin kalitesine, çeşitliliğine ve büyüklüğüne bağlıdır. Literatürdeki çalışmalar, standart RGB görüntülerin yanı sıra, bitkinin fizyolojik durumunu izlemek için multispektral/hiperspektral görüntüler ve su stresi için termal görüntüler gibi farklı sensör verilerini kullanmaktadır (Mahlein vd., 2012; Pádua vd., 2017).

Bağcılık özelinde, veri setlerinin yalnızca yaprak görüntülerinden değil, aynı zamanda salkım ve sürgün görüntülerinden de oluşturulması gerekir. Çünkü çeşitlerin doğru tanımlanması için morfolojik bütünlük şarttır (Garcia-Muñoz vd., 2011). Ayrıca veri setlerinin farklı terroir koşullarını yansıtması, CNN modellerinin saha genellemesi açısından kritik önemdedir.

6.2 Veri Artırma (Data Augmentation)

Veri seti yetersizliği veya sınıflar arası dengesizlik sorununu aşmak için veri artırma teknikleri yaygın olarak kullanılır. Döndürme, çevirme, ölçekleme, parlaklık ayarları ve gürültü ekleme

ISBN NR: 978-625-5694-65-2

gibi yöntemler, modelin genelleme yeteneğini artırır ve aşırı öğrenmeyi (overfitting) önler (Pawara vd., 2017).

Son yıllarda, yapay veri üretimi (synthetic data generation) ve GAN tabanlı veri artırma yöntemleri de bağcılıkta kullanılmaya başlanmıştır. Bu yöntemler, küçük veri setlerinde bile CNN modellerinin %85–90 doğruluk oranlarına ulaşmasını sağlamaktadır (Singh vd., 2023).

6.3 Metodolojiler

CNN modellerinin eğitimi sırasında kullanılan metodolojiler, performans üzerinde doğrudan etkilidir.

- **Transfer öğrenme:** ImageNet gibi büyük veri setlerinde önceden eğitilmiş modellerin bağcılık veri setlerine uyarlanması, daha az veriyle yüksek doğruluk sağlar (Zoph vd., 2018; Hossen vd., 2025).
- **Normalizasyon ve dropout:** Eğitim sürecinde aşırı öğrenmeyi azaltmak için yaygın olarak kullanılır.
- **Veri dengesi stratejileri:** Dengesiz veri setlerinde sınıf ağırlıklandırma ve örnekleme teknikleri modelin daha adil öğrenmesini sağlar (Miftahushudur, Sahin, & Grieve, 2025).

6.4 Performans Metrikleri

Bir CNN modelinin etkinliğini değerlendirmek için standart metrikler kullanılır:

- **Doğruluk (Accuracy):** Genel sınıflandırma başarısını gösterir.
- **Hassasiyet (Precision):** Pozitif sınıflandırmaların doğruluğunu ölçer.
- **Duyarlılık (Recall):** Gerçek pozitiflerin ne kadarının yakalandığını gösterir.
- **F1-Skoru:** Hassasiyet ve duyarlılığın harmonik ortalaması, özellikle dengesiz veri setlerinde güvenilir bir ölçüttür.
- **Karışıklık Matrisi (Confusion Matrix):** Modelin hangi sınıflarda hata yaptığını görsel olarak ortaya koyar.

Literatürdeki çalışmalar, doğru metodoloji ve yeterli veri ile CNN modellerinin üzüm çeşidi ve hastalık sınıflandırmasında %95 ila %99 arasında değişen yüksek doğruluk oranlarına ulaşabildiğini göstermektedir (Nasiri vd., 2021; Terzi vd., 2024; Hernandez vd., 2025).

7. Dijital Ampelografinin Pratik Uygulamaları ve Geleceği

7.1 Pratik Uygulamalar

Dijital ampelografi, geleneksel ampelografinin öznellik ve ölçeklenebilirlik sınırlılıklarını aşarak bağcılıkta çok boyutlu kullanım alanları sunmaktadır. CNN tabanlı sistemler, yalnızca çeşit sınıflandırma değil, aynı zamanda fitosaniter uygulamaların çeşitlere özgü optimize edilmesi, verim tahmini, kalite kontrol ve terroir analizi gibi kritik görevlerde kullanılmaktadır (Mohimont, Alin, & Lebeau, 2022).

ISBN NR: 978-625-5694-65-2

- **Çeşit sertifikasyonu:** CNN modelleri, yaprak ve salkım görüntülerinden çeşitleri yüksek doğrulukla ayırt ederek menşe işaretli bölgelerde sertifikasyon süreçlerini hızlandırmaktadır (Terzi, Ozguven, & Yagci, 2024; Nasiri, Taheri-Garavand, & Omid, 2021).
- **Hastalık yönetimi:** Mildiyö ve antraknoz gibi hastalıkların erken evrede tespiti, CNN tabanlı semantik segmentasyon ile mümkün hale gelmiştir (Xie vd., 2020; Hernandez vd., 2025). Bu sistemler, pestisit kullanımını azaltarak hem ekonomik hem de ekolojik kazanımlar sağlamaktadır.
- **Verim tahmini:** UAV ve RGB görüntüleriyle salkım sayımı ve verim tahmini, bağ yönetiminde lojistik planlamayı kolaylaştırmaktadır (Di Gennaro vd., 2019; Wang, Sun, & Wang, 2017).
- **Olgunluk analizi:** Renk ve doku tabanlı CNN modelleri, üzüm olgunluk seviyesini belirleyerek hasat zamanlamasında karar desteği sağlamaktadır (Marques & Pitarma, 2018).
- **Gerçek zamanlı uygulamalar:** MobileNet ve Xception gibi hafif mimariler, mobil cihazlarda saha koşullarında hızlı sınıflandırma imkânı sunmaktadır (Howard vd., 2017; Chollet, 2016).

Ezcümle; Son yıllarda İspanya, İtalya ve Türkiye gibi Akdeniz ülkelerinde yürütülen saha projelerinde dijital ampelografi sistemleri pilot ölçekte uygulanmıştır.

İspanya ve İtalya'da yürütülen hassas bağcılık projeleri, görüntü tabanlı otomatik sınıflandırma ve verim tahmini sistemlerinin saha koşullarında başarıyla uygulanabileceğini göstermiştir (Arnó, Martínez-Casasnovas, Ribes-Dasi, & Rosell, 2009; Matese & Di Gennaro, 2015; Di Gennaro vd., 2019).

Türkiye'de Terzi, Ozguven ve Yagci (2024), yaprak ve salkım görüntülerinden üzüm çeşitlerini %96 doğrulukla sınıflandıran CNN tabanlı bir model geliştirmiştir.

Bu çalışmalar, dijital ampelografinin yalnızca teorik bir kavram olmaktan çıkıp pratik bağ yönetiminde uygulanabilir bir araç haline geldiğini göstermektedir.

7.2 Performans ve Küçük Veri Setleri

Küçük veri setlerinde yapılan ön testlerde bile CNN modelleri %85–90 arasında doğruluk oranlarına ulaşabilmektedir (Singh vd., 2023). ResNet ve Inception mimarilerinin VGG'ye kıyasla daha yüksek genelleme kapasitesi sergilediği, MobileNet'in ise mobil uygulamalar için uygun olduğu görülmüştür (He vd., 2015; Szegedy vd., 2016).

7.3 Gelecek Perspektifleri

Dijital ampelografi, bağcılığın iklim değişikliğine adaptasyonunda karar destek sistemlerinin temel bileşeni olarak görülmektedir. Gelecekteki araştırmalar şu alanlara odaklanmalıdır:

- **Multimodal veri entegrasyonu:** RGB, hiperspektral ve termal görüntülerin birlikte kullanımı.
- **Domain adaptation:** Laboratuvar ortamında eğitilen modellerin saha koşullarına uyarlanması (Zhang vd., 2021).

ISBN NR: 978-625-5694-65-2

- **Açıklanabilir yapay zekâ (XAI):** CNN modellerinin karar mekanizmalarının şeffaflaştırılması, çiftçi ve uzman güvenini artıracaktır (Mengesha vd., 2025).
- **Kenar bilişim (edge computing):** Mobil cihazlarda ve saha robotlarında gerçek zamanlı CNN uygulamalarının yaygınlaştırılması.

8. Sonuç ve Gelecek Yönelimler

Bu derleme, geleneksel ampelografinin asırlık bilgeliğinden, Evrişimsel Sinir Ağları (CNN'ler) tarafından yönlendirilen dijital ve otomatik bir geleceğe doğru bağcılıkta yaşanan teknolojik evrimi sistematik bir Görselde incelemiştir. Geleneksel yöntemlerin öznellik, maliyet ve ölçeklenebilirlik gibi doğal sınırlamaları, Hassas Bağcılık paradigmasının gerektirdiği objektif, hızlı ve veri odaklı çözümlere olan ihtiyacı doğurmuştur. CNN'ler, bu ihtiyaca cevap vererek üzüm yaprakları, salkımları ve diğer biyolojik verilerden karmaşık desenleri otomatik olarak öğrenme ve bu sayede çeşit sınıflandırması, hastalık tespiti ve verim tahmini gibi kritik görevleri yüksek doğrulukla gerçekleştirme potansiyelini ortaya koymuştur (LeCun, Bengio, & Hinton, 2015; Singh vd., 2017; Terzi, Ozguven, & Yagci, 2024).

Literatür, transfer öğrenme gibi yaklaşımlar sayesinde CNN tabanlı sistemlerin %95–99 doğruluk oranlarıyla üzüm çeşitlerini ayırt edebildiğini, hastalıkları erken evrede tespit ederek hedefe yönelik ilaçlama ile çevresel etkiyi azaltabildiğini ve verim tahminlerini önemli ölçüde iyileştirdiğini göstermektedir (Nasiri, Taheri-Garavand, & Omid, 2021; Hernandez vd., 2025; Di Gennaro vd., 2019). Bu teknolojiler, artık teorik bir olasılık olmaktan çıkıp pratik ve uygulanabilir çözümlere dönüşmektedir.

Ancak, bu teknolojik devrimin tam potansiyeline ulaşması için aşılması gereken kritik engeller bulunmaktadır. Özellikle veri seti dengesizliği ve alan transfer edilebilirliği (*domain adaptation*) sorunları, laboratuvar ortamındaki yüksek başarımların gerçek dünya koşullarına aktarılmasında en büyük kısıtlayıcı faktörlerdir (Miftahushudur, Sahin, & Grieve, 2025; Zhang vd., 2021). Ayrıca, Açıklanabilir Yapay Zekâ (XAI) yöntemlerinin entegrasyonu, "kara kutu" algısını kırarak çiftçilerin ve uzmanların bu sistemlere olan güvenini artırmak için elzemdir (Mengesha vd., 2025).

Son yıllarda, Evrişimsel Sinir Ağları'nın (CNN) yanı sıra Vision Transformer (ViT) tabanlı modeller de dijital ampelografi ve hassas bağcılıkta önemli ilerlemeler kaydetmiştir. Örneğin, ViT ve Masked Autoencoders (MAE) gibi self-supervised yaklaşımlar, sınırlı etiketli veri setlerinde bile yüksek doğruluklarla üzüm çeşidi sınıflandırması sağlamakta olup, geleneksel CNN'lere kıyasla daha robust genelleme kapasitesi sergilemektedir (Carneiro et al., 2025). Benzer Görselde, Xception tabanlı otomatik boru hatları, doğal ortamda çekilen yaprak görüntülerinde %95-98 doğruluk oranları elde ederek, çeşit sertifikasyonu ve fenotipik sınıflandırmada pratik uygulanabilirlik sunmaktadır (Palacios et al., 2024).

Hastalık tespiti alanında ise Transformer çerçeveli hafif modeller, küçük örneklem koşullarında multi-scale özellik yakalama yeteneğiyle öne çıkmakta ve erken müdahale için gerçek zamanlı çözümler vaat etmektedir (Vallabhajosyula et al., 2025). Multimodal veri entegrasyonu (RGB + hiperspektral + termal) ve edge computing ile birleştiğinde, bu teknolojiler pestisit

ISBN NR: 978-625-5694-65-2

kullanımını önemli ölçüde azaltarak sürdürülebilir bağcılığı desteklemekte, Türkiye ve Akdeniz ülkeleri gibi bölgelerde pilot uygulamalarda ekonomik ve ekolojik kazanımlar sağlamaktadır (Terzi et al., 2024).

Bu gelişmeler, dijital ampelografinin yalnızca teorik bir araç olmaktan çıkıp, iklim değişikliğine dirençli ve veri odaklı bağ yönetiminin temel taşlarından biri haline geldiğini göstermektedir. Gelecek çalışmalar, açıklanabilir yapay zekâ (XAI) entegrasyonu, domain adaptation teknikleri ve otonom robotlarla multimodal füzyonu önceliklendirmelidir.

Gelecek Yönelimler

Gelecekteki araştırmalar şu alanlara odaklanmalıdır:

- **Multimodal veri entegrasyonu:** RGB, hiperspektral ve termal görüntülerin birlikte kullanımıyla daha zengin fenotipik analizler.
- **Domain adaptation:** Farklı terroir ve iklim koşullarında eğitilen modellerin saha genellemesi için uyarlanması.
- **Açıklanabilir yapay zekâ (XAI):** CNN modellerinin karar mekanizmalarının şeffaflaştırılması, kullanıcı güvenini artıracaktır.
- **Kenar bilişim (edge computing):** Mobil cihazlar ve saha robotlarında gerçek zamanlı CNN uygulamalarının yaygınlaştırılması.
- **Otonom sistemlerle entegrasyon:** Tarımsal robotlar ve UAV'lerle CNN tabanlı karar destek sistemlerinin bütünleştirilmesi.

Teşekkür: Bu çalışma, Van Yüzüncü Yıl Üniversitesi Bilimsel Araştırma Projeleri Başkanlığı tarafından FDK-2024-11262 numaralı proje kapsamında desteklenmiştir. Yazarlar, çalışmanın yürütülmesi sürecindeki değerli katkıları ve destekleri için Van Yüzüncü Yıl Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimine içten teşekkürlerini sunmaktadır.

9. KAYNAKÇA

1. Adamides, G., Katsanos, C., Constantinou, I., et al., A user-centered approach for developing agricultural robot interfaces, Computers and Electronics in Agriculture, 102, 85-95, 2014.
2. Adão, T., Pádua, L., Hruska, J., Peres, E., Morais, R., ve Sousa, J., Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry, Remote Sensing, 9, 11, 1110, 2017.
3. American Association of Wine Economists, Journal of Wine Economics, Cambridge University Press, 2006.
4. American Association of Wine Economists, Journal of Wine Economics, Cambridge University Press, 2006–.
5. Arnal Barbedo, J. G., Digital image processing techniques for detecting, quantifying and classifying plant diseases, SpringerPlus, 2, 1, 660, 2013.
6. Arnó, J., Martínez-Casasnovas, J. A., Ribes-Dasi, M., ve Rosell, J. R., Review: Precision viticulture, Spanish Journal of Agricultural Research, 7, 4, 779-790, 2009.

7. Ball, D., Upcroft, B., Wyeth, G., Corke, P., English, A., Ross, P., Patten, T., Fitch, R., Sukkarieh, S., and Bate, A., Vision-based obstacle detection and navigation for an agricultural robot, Journal of Field Robotics, 33, 8, 1107-1130, 2016.
8. Bhatti, A. U., Mulla, D. J., ve Frazier, B. E., Estimation of soil properties and wheat yields on complex eroded hills using Landsat data, Remote Sensing of Environment, 37, 3, 181-191, 1991.
9. Birkhaeuser, D., Evenson, R. E., ve Feder, G., The economic impact of agricultural extension: A review, Economic Development and Cultural Change, 39, 3, 607-650, 1991.
10. Bongiovanni, R., ve Lowenberg-DeBoer, J., Precision agriculture and sustainability, Precision Agriculture, 5, 4, 359-387, 2004.
11. Bramley, R. G. V., ve Lamb, D. W., Making sense of vineyard variability in Australia, Australian Journal of Grape and Wine Research, 9, 1, 1-8, 2003.
12. Bramley, R. G. V., ve Lamb, D. W., The application of precision agriculture to viticulture, Australian Journal of Grape and Wine Research, 9, 1, 1-11, 2003.
13. Carneiro, G. A., Pádua, L., Peres, E., Morais, R., Sousa, J. J., ve Cunha, A., Grapevine Varieties Identification Using Vision Transformers, IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, 5866-5869, 2022.
14. Chollet, F., Xception: Deep learning with depthwise separable convolutions, arXiv:1610.02357, 2016.
15. Crookston, R. K., A top 10 list of developments and issues impacting crop management and ecology during the past 50 years, Crop Science, 46, 5, 2253-2262, 2006.
16. Di Gennaro, S. F., Matese, A., Toscano, P., Cinat, P., Berton, A., ve Matese, A., UAV-based vineyard yield estimation using RGB imagery, Frontiers in Plant Science, 10, 559, 2019.
17. Ergin, T., Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır?, Medium. https://medium.com/@tuncergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad (Erişim tarihi: 18.12.2025)
18. Garcia-Muñoz, S., Cabello, F., Ibáñez, J., et al., Grapevine varietal identification by SSR markers, Scientia Horticulturae, 129, 1, 50-55, 2011.
19. Georgieva, K., et al., Soil electrical conductivity mapping for precision viticulture, Precision Agriculture, 17, 4, 434-451, 2016.
20. Giacomarra, M., D'Amico, M., Di Vita, G., ve Solazzo, R., The role of certification in the wine-making sector, Journal of Food Products Marketing, 23, 7, 757-770, 2016.
21. Hall, A., Lamb, D. W., Holzapfel, B., ve Louis, J., Optical remote sensing applications in viticulture, Australian Journal of Grape and Wine Research, 8, 1, 36-47, 2002.
22. He, K., Zhang, X., Ren, S., ve Sun, J., Deep residual learning for image recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778, 2015.
23. Hernandez, I., et al., Early detection of downy mildew in vineyards using deep neural networks for semantic segmentation, Biosystems Engineering, 251, 105203, 2025.
24. Hossen, M. I., Awrangjeb, M., Pan, S., ve Mamun, A. A., Transfer learning in agriculture: A review, Artificial Intelligence Review, 1-52, 2025.
25. Howard, A. G., Zhu, M., Chen, B., et al., MobileNets: Efficient convolutional neural networks for mobile vision applications, arXiv preprint arXiv:1704.04861, 2017.

26. Kamilaris, A., ve Prenafeta-Boldú, F. X., Deep learning in agriculture: A survey, Computers and Electronics in Agriculture, 147, 70-90, 2018.
27. LeCun, Y., Bengio, Y., ve Hinton, G., Deep learning, Nature, 521, 7553, 436-444, 2015.
28. Lee, J., et al., Mapping soil electrical conductivity for precision viticulture, Precision Agriculture, 11, 2, 171-185, 2010.
29. Mahlein, A.-K., et al., Hyperspectral imaging for plant disease detection, Annual Review of Phytopathology, 50, 231-248, 2012.
30. Marques, A., ve Pitarma, R., Portable device for monitoring grape quality parameters, Sensors, 18, 11, 3755, 2018.
31. Matese, A., ve Di Gennaro, S. F., Technology in precision viticulture: A state of the art review, International Journal of Wine Research, 7, 69-81, 2015.
32. Mengesha, A. T., et al., Applying transfer learning in CNN model architectures for tomato leaf disease detection with explainable AI, Smart Agricultural Technology, 11, 100609, 2025.
33. Miftahushudur, T., Sahin, H. M., ve Grieve, B., A survey of methods for addressing imbalance data problems in agriculture applications, Remote Sensing, 17, 3, 454, 2025.
34. Mohanty, S. P., Hughes, D. P., ve Salathé, M., Using deep learning for image-based plant disease detection, Frontiers in Plant Science, 7, 1419, 2016.
35. Mohimont, L., Alin, F., ve Lebeau, F., Computer vision and deep learning for precision viticulture, Agronomy, 12, 10, 2463, 2022.
36. Mondal, P., et al., Precision agriculture: A review, International Journal of Agricultural Research, 12, 2, 1-12, 2017.
37. Mulla, D. J., Twenty five years of remote sensing in precision agriculture, Biosystems Engineering, 114, 4, 358-371, 2013.
38. Mulla, D. J., ve Khosla, R., Historical evolution and recent advances in precision farming, Precision Agriculture, 16, 2, 1-12, 2015.
39. Nasiri, A., Taheri-Garavand, A., ve Omid, M., Automated grapevine cultivar identification via leaf imaging and deep convolutional neural networks, Foods, 10, 8, 1899, 2021.
40. Noguchi, N., Reid, J. F., Benson, E. R., ve Zhang, Q., Agricultural robots for field operations, Automation Technology for Off-Road Equipment, 1-7, 2004.
41. Oberti, R., Marchi, M., Tirelli, P., Calcante, A., Iriti, M., ve Borghese, A., Selective spraying of grapevine diseases by a modular agricultural robot, Biosystems Engineering, 146, 203-215, 2016.
42. Oerke, E.-C., Mahlein, A.-K., ve Steiner, U., Precision crop protection: The challenge of integrated pest management, Frontiers in Plant Science, 7, 155, 2016.
43. Pádua, L., Adão, T., Hruska, J., Peres, E., Morais, R., ve Sousa, J., UAS-based hyperspectral imaging for precision viticulture, Remote Sensing, 9, 11, 1110, 2017.
44. Pawara, P., Okafor, E., Surinta, O., Schomaker, L., ve Wiering, M., Comparing CNN architectures for fine-grained plant classification, ACIVS 2017, 102-113, 2017.
45. Pérez-Expósito, M., et al., Microclimate monitoring in vineyards using wireless sensor networks, Sensors, 17, 12, 2844, 2017.
46. Peris-Ortiz, M., et al., Wine and agro-food value chains in Mediterranean countries, Springer, 2015.

47. Pescas, A., Regulamento da Região Demarcada do Douro, IVDP Publicações, 2001.
48. Pierce, F. J., ve Nowak, P., Aspects of precision agriculture, Advances in Agronomy, 67, 1-85, 1999.
49. Resende, R. T., et al., Leafsnap dataset analysis, Plant Methods, 13, 1-12, 2017.
50. Saleem, M. H., Potgieter, J., ve Arif, K. M., Plant disease classification: A comparative evaluation of convolutional neural networks and deep learning optimizers, Plants, 9, 10, 1319, 2020.
51. Santesteban, L. G., Precision viticulture and vineyard variability, OENO One, 53, 2, 189-205, 2019.
52. Simonyan, K., ve Zisserman, A., Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, 2014.
53. Singh, B., Kumar, M., ve Kaur, S., Deep learning based approach for precision agriculture, Journal of Smart Agriculture, 10, 3, 112-125, 2017.
54. Singh, G., vd., Comparison of RSNET model with existing architectures for plant leaf disease detection, Results in Control and Optimization, 12, 100281, 2023.
55. Srinivasan, A., Handbook of precision agriculture, CRC Press, 2006.
56. Stavrakaki, M., ve Biniari, K., Genotyping and phenotyping of Greek grapevine varieties, Scientia Horticulturae, 209, 146-157, 2016.
57. Stavrakaki, M., ve Biniari, K., Genotyping and phenotyping of twenty old traditional Greek grapevine varieties (Vitis vinifera L.) from Eastern and Western Greece, Scientia Horticulturae, 209, 146-157, 2016.
58. Szegedy, C., Liu, W., Jia, Y., et al., Going deeper with convolutions, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1-9, 2016.
59. Tan, L., Optimization in precision agriculture, Agricultural Systems, 149, 1-12, 2016.
60. Tassie, E., Environmental effects on grapevine morphology, Journal of Wine Research, 21, 3, 189-203, 2010.
61. Terzi, I., Ozguven, M. M., ve Yagci, A., Automatic detection of grape varieties with the newly proposed CNN model using ampelographic characteristics, Scientia Horticulturae, 328, 112877, 2024.
62. Vallabhajosyula, S., Varma, K. S., ve Bharathiraja, B., A novel hierarchical framework for plant leaf disease detection using residual vision transformer, Heliyon, 10, 9, e29912, 2024.
63. Vo, H.-T., Mui, K. C., ve Thien, N. N., Fusing Xception and ResNet50 features for robust grape leaf disease classification, Bulletin of Electrical Engineering and Informatics, 14, 1, 268-275, 2025.
64. Wample, R. L., et al., Precision viticulture in Washington State, Proceedings of the ASEV, 1-7, 1999.
65. Wang, Q., Sun, Y., ve Wang, J., Automatic counting of grape clusters, Computers and Electronics in Agriculture, 137, 104-113, 2017.
66. Xie, X., Zhang, Y., Li, B., et al., A deep-learning-based real-time detector for grape leaf diseases, Frontiers in Plant Science, 11, 751, 2020.
67. Yost, M. A., et al., Microclimate and canopy monitoring in vineyards, Agricultural and Forest Meteorology, 247, 145-157, 2017.
68. Zhang, W., Huang, Y., Li, Y., et al., Easy domain adaptation method for filling the species gap in plant disease detection, Horticulture Research, 8, 1, 123, 2021.

69. Zoph, B., Vasudevan, V., Shlens, J., ve Le, Q. V., Learning transferable architectures for scalable image recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 8697-8710, 2018.