

**YAPAY ZEKANIN TARIM, TEKNOLOJİ VE
EĞİTİM ALANLARINA YANSIMALARI
ÜZERİNE DİSİPLİNLERARASI BİR İNCELEME**



EDİTÖR

Dr. Öğr. Üyesi Ertuğrul KIRAC

Prof. Dr. Abdullah KAPLAN

Doç. Dr. Gürcan UZAL

Doç. Dr. Aytekin ERDEM

Dr. Öğr. Üyesi Hasan METE

Dr. Öğr. Üyesi Erdal KILIÇ

Dr. Osman BURAN

ISBN: 978-625-5753-22-9

Ankara -2025

**YAPAY ZEKANIN TARIM, TEKNOLOJİ VE
EĞİTİM ALANLARINA YANSIMALARI
ÜZERİNE DİSİPLİNLERARASI BİR İNCELEME**

EDİTÖR

Dr. Öğr. Üyesi Ertuğrul KIRIÇ
Doğuş Üniversitesi
ORCID ID: 0000-0001-6645-5444

YAZARLAR

Prof. Dr. Abdullah KAPLAN¹

Doç. Dr. Gürhan UZAL²

Doç. Dr. Aytekin ERDEM³

Dr. Öğr. Üyesi Hasan METE⁴

Dr. Öğr. Üyesi Erdal KILIÇ⁵

Dr. Osman BURAN⁶

¹Atatürk Üniversitesi, Kazım Karabekir Eğitim Fakültesi, Matematik ve Fen Bilimleri Eğitimi, Erzurum, Türkiye
akaplan@atauni.edu.tr
ORCID ID: 0000-0001-6743-6368

²Tekirdağ Namık Kemal Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon, Tekirdağ, Türkiye
guzal@nku.edu.tr
ORCID ID: 0000-0002-2029-8612

³Tekirdağ Namık Kemal Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon, Tekirdağ, Türkiye
aerdem@nku.edu.tr
ORCID ID: 0000-0002-1760-4789

⁴Tekirdağ Namık Kemal Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Gıda İşleme, Tekirdağ, Türkiye
hmete@nku.edu.tr
ORCID ID: 0000-0002-8701-379X

⁵Tekirdağ Namık Kemal Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Motorlu Araçlar ve Ulaştırma Teknolojileri Tekirdağ, Türkiye,
ekilic@nku.edu.tr
ORCID ID: 0000-0001-8212-5533

⁶Şükrüpaşa Ortaokulu, Erzurum, Türkiye
osman830@gmail.com
ORCID ID: 0000-0002-1922-1570

DOI: <https://doi.org/10.5281/zenodo.17777225>



Copyright © 2025 by UBAK publishing house

All rights reserved. No part of this publication may be reproduced, distributed or transmitted in any form or by

any means, including photocopying, recording or other electronic or mechanical methods, without the prior written permission of the publisher, except in the case of brief quotations embodied in critical reviews and certain other noncommercial uses permitted by copyright law. UBAK International Academy of Sciences Association Publishing House®

(The Licence Number of Pubicator: 2018/42945)

E mail: ubakyayinevi@gmail.com

www.ubakyayinevi.org

It is responsibility of the author to abide by the publishing ethics rules.

UBAK Publishing House – 2025©

ISBN: 978-625-5753-22-9

December / 2025

Ankara / Turkey

ÖNSÖZ

Yapay zeka, günümüzde pek çok alanda üretim süreçlerini, tasarım anlayışını ve öğrenme pratiklerini yeniden şekillendiren temel bir güç hâline gelmiştir. Bu kitap, yapay zeka teknolojilerinin tarımsal faaliyetlerden mühendislik uygulamalarına, eğitim ortamlarından öğrenci öğrenme davranışlarına kadar uzanan geniş etkilerini disiplinlerarası bir bakış açısıyla ele almaktadır.

Tarımsal üretimde verimliliği artırmaya yönelik yenilikçi uygulamalar, elektronik sistem tasarımında yapay zeka destekli araçların sunduğu olanaklar ve öğrencilerin matematik öğreniminde karşılaştıkları güçlüklerin analizi, bu dönüşümün farklı yönlerine ışık tutmaktadır. Bu çalışmaların bir araya getirilmesiyle ortaya çıkan bu eser, hem pratik hem kuramsal açıdan yapay zekanın güncel kullanım alanlarına dair kapsamlı bir çerçeve sunmayı amaçlamaktadır.

Bu eserin, yapay zeka uygulamalarının güncel yönelimlerini anlamaya çalışan araştırmacılar, eğitimciler ve uygulayıcılar için yararlı bir başvuru kaynağı olmasını diliyorum.

Kitabın hazırlanmasında emeği geçen tüm araştırmacılara, katkı sağlayan ve destek olan meslektaşlara ve UBAK yayınevine teşekkür ederim.

01.12.2025

Dr. Öğretim Üyesi Ertuğrul KIRAC

İÇİNDEKİLER

ÖNSÖZ	4
İÇİNDEKİLER	6

BÖLÜM 1

TARIMSAL ÜRETİMDE YAPAY ZEKÂ KULLANIMININ DEĞERLENDİRİLMESİ.....	(8-44)
---	---------------

Hasan METE

Gürcan UZAL

Erdal KILIÇ

Aytekın ERDEM

BÖLÜM 2

ELEKTRONİK SİSTEM TASARIMINDA, SİMÜLASYONUNDA VE EĞİTİMİNDE KULLANILAN YAPAY ZEKÂ ARAÇLARININ TANITILMASI.....	(45-89)
---	----------------

Gürcan UZAL

Hasan METE

Aytekın ERDEM

Erdal KILIÇ

BÖLÜM 3

ORTAOKUL 8. SINIF ÖĞRENCİLERİNİN DENKLEMLER VE ÖZDEŞLİKLER KONUSUNDA YAPMIŞ OLDUKLARI HATALAR.....(90-119)

Osman BURAN

Abdullah KAPLAN

BÖLÜM 1

TARIMSAL ÜRETİMDE YAPAY ZEKÂ KULLANIMININ DEĞERLENDİRİLMESİ¹

Dr. Öğr. Üyesi Hasan METE

Doç. Dr. Gürcan UZAL

Dr. Öğr. Üyesi Erdal KILIÇ

Doç. Dr. Aytekin ERDEM

GİRİŞ

Dünya nüfusunun hızlı artması nedeniyle, başta gıda olmak üzere insanın diğer gereksinimlerinin karşılanması gerekmektedir. Ancak tarım yapılan alanlar genişletilemeyeceği için bu alanlarda gerçekleştirilen tarımsal üretimin verimliliğinin artırılmasının zorunlu olduğu düşünülmektedir. Tarımsal üretimin verimliliğini azaltan faktörlerin belirlenerek verimliliği arttıracak en uygun çözümler ortaya koyulmalıdır. Ayrıca günümüzde yapay zekâ destekli teknolojilerden yararlanılarak tarımsal üretimde verimliliğin artırılması da mümkün olmaktadır.

Yapay zekâ destekli teknolojilerden biri olan akıllı tarım teknolojileri, üretim ile başlayıp tüketim ile sonuçlanan süreçteki her kademede tarımsal ürünün nicelik ve niteliğini artırmayı amaçlayan teknolojilerdir. Tarımsal üretimde verimliliğin artırılması için öncelikle bitkinin iyi bir şekilde tanınması, bitkinin gelişim sürecinde ihtiyaç duyduğu girdilerin en uygun miktarda ve zamanda sağlanmasıdır. Bu

¹UBAK, IV. INTERNATIONAL SCIENTIFIC COMPILATION RESEARCH
CONGRESS, 02-03 Eylül 2025 tarihinde sözlü bildiri olarak sunulmuştur.

işlemlerin gerçekleştirilebilmesi için akıllı ve dijital teknolojiler ile bazı algoritmalar, simülasyonlar ve optimizasyonlar geliştirilerek bitkinin gereksinimi olan besin maddeleri sulama, bakım ve hasat zamanları kestirilerek birim alandan yüksek verim elde edilmesi amaçlanmaktadır. Ayrıca ürün rekoltesinin ve piyasasının izlenebilmesi, üretim planlamalarının sağlıklı yapılması açısından da bu teknolojilerin kullanılması önem kazanmaktadır (Ağızan, Bayramoğlu ve Ağızan, 2022: 1698).

Yapay zekâ destekli dijital tarım uygulamaları, tarımsal faaliyet yürütülen alanlardan toplanan bilgiler ve verilerin çeşitli kamera, sensör veya sistemlerden gerçek zamanlı olarak toplanması, elde edilen verilerin bu konuya özgü geliştirilen yazılımlara iletilmesi, verilerin analiz edilmesi, verilerin arşivlenmesi ve veriye bağlı işlemlerin yönetilmesi kademelerinden meydana gelmektedir (Özgüven, 2023: 175). Yapay zekâ insan zekâsının yetenek alanları olan öğrenme, algılama, düşünme ve tecrübe etme yeteneklerinin bilgisayar ve benzeri sistemlere işlenerek yeni sorunlar karşısında karar verilmesini temin etmesi ve süreci yönetebilmesidir. Karar verme işlemi sürecinde insan zekâsı tarafından belirlenen parametreler yapay zekâyâ öğretilerek, insanın zihinsel fonksiyonlarını taklit ederek yorumlar yapabilen bilgisayar modelleri aracılığıyla formüller meydana getirilmektedir (Özgüven, 2019: 300).

Endüstri 4.0 kavramının ortaya çıkışıyla birlikte, tarım sektörünün de içinde olduğu birçok alanda değişim eğilimi ortaya çıkmıştır. Endüstri 4.0 (4. sanayi devrimi), yalnızca makineleşmeyi

değil aynı zamanda sanallaştırma ve dijitalleştirme süreçlerini de kapsayan bütüncül bir dönüşümü ortaya koymaktadır. Bu dönüşüm, yeni teknolojilerin makinelerle bütünleştirilip bu sürece insan faktörünün de katılmasıyla birbirleri arasında eksiksiz bir bütünleştirme sağlamayı amaçlar. Bu bütünleştirme, ileri sensör teknolojileri yardımıyla otomatik olarak veri aktarımı, karmaşık makine öğrenmesi algoritmaları ile veri analizi ve verileri işleme ile bu bilgilerin optimizasyon işlemleri için kullanılması gibi birbiri ile yakından ilişkili aşamaları kapsamaktadır (Chlingaryan vd., 2018, Aktaran: Ayberkin, 2025: 13). Günümüzdeki gelişmiş teknolojilerin tarımsal üretim faaliyetlerinde kullanılması gün geçtikçe yaygınlaşmaktadır.

İnsanlık tarihi boyunca tarım, hayatta kalmanın ve toplumsal gelişimin temel taşı olmuştur. Ekonomik büyüme, iş gücü yaratımı ve sürdürülebilir yaşam hedeflerinde merkezi bir rol üstlenen tarım sektörü, zaman içinde üç temel mekanizasyon aşamasından geçmiştir: ilk aşamada el aletleriyle başlayan üretim, ikinci aşamada hayvanların üretime dâhil edilmesi ve üçüncü aşama ise sanayi devrimiyle birlikte makinelerin kullanımının artması olarak gerçekleşmiştir. Bu aşamalar, toplumsal ve ekonomik yapıları derinden etkilemiştir. Özellikle ikinci tarımsal devrimde sabanın geliştirilmesiyle verim artışı sağlarken, buhar teknolojisinin ve içten yanmalı motorların benimsenmesi tarımda kalıcı değişimlere yol açmıştır. Günümüzde ise Tarım 4.0 dönemi ile birlikte, dijital teknolojilerin kullanımı sayesinde üretim süreçleri daha akıllı hale gelmekte; çevre dostu ve sürdürülebilir üretim modelleri yaygınlaşmaktadır. Yapay zekâ, IoT (Nesnelerin İnterneti) ve büyük

veri teknolojileri sayesinde tarımda su ve enerji kullanımında verimlilik artmakta, ürün izlenebilirliği ve gıda güvenliği daha etkin bir şekilde sağlanmaktadır. Bu dijitalleşme süreci aynı zamanda küresel sorunlara çözüm üretme potansiyeline sahiptir; örneğin iklim krizine karşı uyum sağlama ve yoksulluğu azaltma gibi hedefler bu dönüşümle desteklenmektedir (Öztürk ve Çelik, 2024: 149).

Türkiye 1924 yılında Almanya ve Avusturya menşeli traktör, pulluk ve harman makinelerini ülkeye getirerek tarımda modernleşme sürecini başlatmıştır. Bu ekipmanlar, Ankara ve Konya bölgesindeki tarım işletmelerine dağıtılmış; İstanbul'daki Halkalı Ziraat Mektebi'nden gelen öğrenciler, makinelerin kullanımına ve teknik bakımına dair eğitim almıştır. Beş yıl gibi kısa bir sürede, 1929 yılı itibarıyla Türkiye'de kayıtlı traktör sayısı 221'e çıkmıştır (Yurtoğlu, 2017). Günümüzde tarımda verimliliği artırmak amacıyla mekanik güç kullanımı yaygınlaştı. İnsan ve hayvan gücünün yerini büyük ölçüde makineler aldı. (T.C. Cumhurbaşkanlığı Strateji Ve Bütçe Başkanlığı, 2023). Öztürk vd., (2024: 153-154) göre, tarımsal üretimin dijitalleşmesi, veri odaklı teknolojilerin süreçlere entegre edilmesini içerir. Bu yenilikçi sistemler, çiftçilerin daha bilinçli ve etkin kararlar almasına olanak tanıyarak çağdaş tarımın temelini oluşturmaktadır.

Öne Çıkan Dijital Tarım Teknolojileri

- IoT: Toprak nem oranı, hava koşulları ve sıcaklık gibi çevresel faktörleri anlık olarak takip ederek tarımsal planlamayı destekler (Tzounis et al., 2017).

- Drone Kullanımı: Ekim, sulama ve tarla görüntüleme görevlerinde etkin rol üstlenerek üretim verimliliğini artırır (Finger et al., 2019).
- GPS ve GIS Sistemleri: Tarımsal işlemlerde konum tabanlı hassasiyet sağlayarak kaynak kullanımı optimize edilir.
- Robotik Otomasyon: İnsan gücüne olan bağımlılığı azaltarak zaman ve iş gücü tasarrufu sağlar.
- Bulut Bilişim ve Büyük Veri Analitiği: Tarımsal verilerin toplanıp işlenmesi ile üretim stratejileri daha etkili biçimde planlanır (Wolfert et al., 2017).

Günümüzde teknolojik gelişmelerin ivme kazanmasıyla birlikte ortaya çıkan yenilikler, tarımsal üretim alanında da önemli dönüşümlere zemin hazırlamaktadır. Bu gelişmeler, bitkisel ve hayvansal üretim süreçlerinin daha ekonomik, sürdürülebilir ve verimli bir yapıya kavuşmasına olanak tanımaktadır. Özellikle yazılım geliştirme alanında kullanılan yapay zekâ teknikleri, tarımsal faaliyetlerin etkinliğini artırmak ve süreçlerde karşılaşılan sorunlara çözüm üretmek amacıyla stratejik bir araç olarak öne çıkmaktadır. Tarım uygulamalarına entegre edilen çeşitli algoritmalar ve yazılımlar sayesinde; bitkisel üretimin planlanması, bitki türlerinin sınıflandırılması, verim tahminlerinin yapılması ile bitki hastalıkları, zararlılar ve yabancı otların tespiti gibi konularda bilimsel araştırmaların sayısı giderek artmaktadır (Demir, Kula ve Uğurlu, 2021: 91). Bu araştırmalar yapay zekâ teknolojilerinin desteği ile hızlı, güvenilir tarımsal üretim yapılmasına zemin hazırlamaktadır.

Yapay zekâ, insan ve hayvan gibi doğal sistemlerin davranışlarını taklit edebilen bilgisayarlar, robotlar ve benzeri insan yapımı araçların geliştirilmesiyle ilgilidir. Bu alan, özellikle belirsizlik içeren bilgilerin bilgisayar ortamında nasıl temsil edilebileceğini ve bu temsiller aracılığıyla otomatik çıkarımların nasıl gerçekleştirilebileceğini araştırmaktadır. Aynı zamanda, depolanmış bilgilere dayanarak karar verme süreçlerinin nasıl yapılandırılabilirliği, eylem planlarının nasıl oluşturulabileceği ve bilgisayarların örnek verilerden öğrenme ya da uzman kişilerden bilgi edinme yoluyla işlenebilir bilgiye nasıl ulaşabileceği gibi konuları da kapsamaktadır (Borgelt ve Kruse, 2006). Yapay zekâ destekli teknolojilerin tarımsal üretimin çeşitli aşamalarında kullanımı gittikçe önem kazanmaktadır.

Teknolojik ilerlemelerle birlikte ortaya çıkan çeşitli teknik uygulamalar, tarımsal üretimin temel hedefleri arasında yer alan ekonomik, sürdürülebilir ve yüksek verimliliğe dayalı işletme modellerinin gerçekleştirilmesine önemli katkılar sunmaktadır. Bu bağlamda, yapay zekâ teknikleri, tarımsal süreçlerin daha etkin yönetilmesi ve mevcut problemlere yenilikçi çözümler geliştirilmesi açısından stratejik bir araç haline gelmiştir. Geliştirilen algoritmalar ve yazılım sistemleri aracılığıyla; bitkisel üretim planlaması, bitki türlerinin sınıflandırılması, verim tahminleri, bitki hastalıkları, zararlılar ve yabancı otların teşhisi, tarım robotlarında rota optimizasyonu, sera ortamlarında uygun çevresel koşulların belirlenmesi, işletme düzeyinde karar destek sistemlerinin oluşturulması, sulama stratejilerinin yönetimi, ürün rotasyon

planlaması, gübreleme ve tarımsal ekipman seçimi, hayvan hastalıklarının teşhisi, dengeli yem rasyonlarının hazırlanması ve hayvan davranışlarının izlenmesi gibi çok sayıdaki alanda bilimsel çalışmalar yürütülmektedir (Terzi, Özgüven, Altaş ve Uygun, 2019: 245). Tarımsal üretimde teknoloji kullanımı yaygınlaşmasına rağmen tarım sektöründe çalışan insan sayısı gittikçe azalmaktadır.

Zaman içerisinde tarım sektöründe istihdam edilen genç nüfusun sayısında belirgin bir azalma gözlemlenmiş; bu durum, birçok tarım arazisinin üretim dışı kalmasına ve kırsal alanlardan kent merkezlerine yönelik göç hareketlerinin hız kazanmasına neden olmuştur. Günümüzde emek yoğun bir yapıya sahip olan tarım sektöründe, iş gücü yükünün hafifletilmesi ve üretim süreçlerinde insan kaynaklı hataların en aza indirilmesi amacıyla dijital tarım teknolojilerinin kullanımı kaçınılmaz hale gelmiştir. Toprak işleme aşamasından hasada, ürün işleme ve depolamaya kadar uzanan tüm üretim zincirinin daha etkin ve verimli biçimde yönetilebilmesi için dijital sistemlerin entegrasyonu büyük önem taşımaktadır (Altıkat, 2022: 158). Tarımsal üretimin çeşitli alanlarında ve aşamalarında yapay zeka destekli teknolojilerin kullanımı her geçen gün yaygınlaşmaktadır.

1.Tarım Makinelerinin Yapay Zekâ İle Desteklenmesi

Geliştirilen akıllı tarım uygulamaları ile verim arttırılabilir, maliyetler azaltılabilir ve israf önlenabilir. Bütünleşik karar destek sistemleri ekili alanlarda sensörler yardımı ile toplanan verileri tarım yönetimi konusunda bilgilere ulaşmak için analiz ederek, önerilerde bulunur (Munir vd., 2019, Aktaran: Ayberkin, 2025; 13). Akıllı tarım

uygulaması olarak nesnelerin interneti ve sensörlerin su yönetim sistemlerinde kullanılması yardımı ile akıllı sulama sistemleri, temiz su kaynaklarının korunmasını sağlayıp verimli sulama çözümlerini oluşturması temin edilmiştir (Huong vd, 2018; Munir vd., 2019, Aktaran: Ayberkin, 2025: 14). Günümüzde tatlı su kaynakları gün geçtikçe azalmaktadır. Ancak akıllı tarım uygulamaları ile kıt su kaynaklarının ekonomik olarak kullanımı mümkün olabilecektir.

Karar destek sistemleri akıllı tarım sistemleri içerisinde yer alıp verilerin analiz edilmesi, tahminlerde bulunulması ve bilgi kaynağı oluşturulmasını temin etmektedir. Günümüzde tarımda karar destek sistemleri; sulama kaynakları yönetiminde, görev planlamasında, israfın önlenmesinde ve atık yönetiminde, iklim değişikliğine uyum sağlanmasında, sürdürülebilirlik ve tarımsal tedarik zincirlerinde kullanılması ile önem kazanmaktadır (Zhai vd., 2020, Aktaran: Ayberkin, 2025: 14). Günümüzde olumsuz yönde iklim değişikliği tarımsal üretimde sorunlara yol açmaktadır. Bu sorunlar ile başa çıkmak için tarımsal üretimin akıllı tarım uygulamaları ile gerçekleştirilmesinin zorunluluk gerektirdiği görülmektedir.

Yapay zeka destekli teknolojiler, tarımsal üretimde verimliliği arttıran ve ürün kalitesini iyileştiren, zorluk içeren birçok tarımsal işlemdeki insan işgücü ve üretim maliyetlerini azaltarak çiftçi refahının arttırılmasını temin eden teknolojik cihaz ve sistemlerdir (Özgüven vd., 2016). Tarımsal üretimin çeşitli aşamalarında insan gücü yerine geçecek robotlar geliştirilmeye başlanmıştır.

Amos ve Ruckelshausen (2014) tarımsal üretimde kullanılmak amacıyla beş uygulama modülünden meydana gelen bir robot geliştirmişlerdir. Bu robot ile; 1.İzcilik (bitkinin sağlık durumu, bitki morfolojisi ve biyokütle), 2.Toprak analizi (beslenme, nem, toprak sıkışması), 3.Hassas ilaçlama (daha az toprak kirliliği, daha az pestisit), 4.Mekanik yabancı ot kontrolü (organik tarım, fidanların verimliliği), 5.Seçici hasat (marul, kuşkonmaz ve çilekte verimlilik) yapılabilmektedir (Aktaran Özgüven vd, 2016: 109). Çeşitli tarımsal üretim alanlarında görevli robotların yapay zekâ teknolojisinin alt dalları olarak tanınan makine öğrenmesi ve derin öğrenme konularında donatılmış olması önemlidir.

Akıllı sistem yazılımlarında sıklıkla karşılaşılan yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları, çoğu zaman birbirinin yerine kullanılsa da, aralarında belirli yapısal farklılıklar bulunmaktadır. Makine öğrenmesi, yapay zekâ disiplininin bir alt alanı olarak konumlanırken; derin öğrenme ise makine öğrenmesinin daha özelleşmiş bir alt kümesini oluşturmaktadır. Bu hiyerarşik yapı doğrultusunda, tüm makine öğrenmesi uygulamaları yapay zekâ kapsamında değerlendirilmekte; ancak her yapay zekâ uygulaması makine öğrenmesi içermemektedir (Aylak vd., 2021).

Makine öğrenmesi, geçmiş verilere dayanarak yeni veriler için en uygun tahmin modelini oluşturmayı amaçlayan bir yöntemdir. Özellikle büyük veri kümelerinin insan eli ile sisteme girilmesi hem zaman alıcı hem de oldukça zahmetli bir süreçtir. Bu nedenle, hazır olarak sunulan ya da açık erişimle paylaşılan veri setleri, makine öğrenmesi

algoritmalarının eğitilmesinde ve yüksek doğruluk oranına sahip modellerin geliştirilmesinde yaygın biçimde kullanılmaktadır. Makine öğrenmesinin günümüzde bu denli önem kazanmasının temel nedeni, uygulama alanından bağımsız olarak büyük veri yığınlarını analiz edebilmesi, geleceğe yönelik öngörülerde bulunabilmesi ve karar destek süreçlerine katkı sunabilmesidir (Kutlugün, 2017). Geniş alanlarda gerçekleştirilen tarımsal üretimlerde arazinin yerden kontrolü ve takibi zaman alabilmekte, çeşitli zorluklarla karşılaşılabilen ve ürüne zarar verilebilmektedir. Bu olumsuzlukları giderebilmek için drone teknolojisi kullanılmaktadır.

Bitki koruma alanında drone teknolojisinin sunduğu yenilikler, pestisit uygulamalarının ve tarımsal üretim yönetiminin daha etkin biçimde gerçekleştirilmesine olanak tanımaktadır. Multispektral ve hiperspektral görüntüleme sensörleriyle donatılmış ileri düzey insansız hava araçları, bitki sağlığı, stres düzeyleri ve olası zararlı istilaları hakkında yüksek çözünürlüklü veriler elde edebilmektedir. Bu kapsamlı veri setleri, üreticilerin daha bilinçli kararlar almasını ve müdahalelerini yalnızca gerekli alanlara yönlendirerek kaynak kullanımını optimize etmesini sağlamaktadır. Örneğin, drone tabanlı görüntüleme verilerinin analiz edilmesiyle, tarladaki hastalık veya zararlı baskısının yoğun olduğu bölgeler hassas biçimde tespit edilebilmekte; böylece pestisit uygulamaları yalnızca ihtiyaç duyulan alanlarla sınırlı tutulmakta, kimyasal kullanım miktarı azaltılmakta ve çevresel etkiler en aza indirilmektedir (Delavarpour vd., 2021).

Bilgi işleme ve kullanımına yönelik çeşitli araç ve sistemler günümüzde geliştirilmiş olup, tarım sektöründe yaygın biçimde kullanılmaktadır. Tarım 4.0 kapsamında değerlendirilebilecek bazı yenilikçi uygulamalar arasında; insansız hava araçları (drone) teknolojileri, tarımsal robotik sistemler, otomatik sulama çözümleri, değişken oranlı gübreleme teknolojileri, hayvan sağım ve besleme işlemlerine yönelik otomasyon sistemleri, sera ortamlarının iklimsel koşullarını düzenleyen otomasyonlar, zararlı organizmalar için erken uyarı ve tahmin sistemleri ile entegre akıllı çiftlik yönetim uygulamaları yer almaktadır (Pakdemirli, Birişik, Aslan, Sönmez ve Gezici, 2021: 81).

2.Tarla Bitkileri Yetiştiriciliğinde Yapay Zekâ Uygulamaları

Tarımda yetiştiriciliğin yapıldığı alan ve çevre koşullarının belirlenmesinde kullanılan çeşitli sensörler bulunmaktadır. Örneğin, toprak özelliklerinin belirlenmesi için organik madde, bitki besin elementleri ve pH düzeyi, nem içeriği ve toprak sıkışıklığı ile elektriksel iletkenlik gibi sensörler kullanılmaktadır. Ayrıca nem, sıcaklık, basınç, yağış, rüzgâr hızı ve konum gibi çevre hakkında bilgi edinilmesine yarayan çeşitli sensörler de bulunmaktadır (Özgüven, 2023: 177). Tarla bitkileri yetiştiriciliğinde çok geniş araziler kullanılmakta ve bunların insansız hava araçları ile havadan kontrolleri büyük kolaylık sağlamaktadır.

İnsansız Hava Araçları; kullanım kolaylığı ve üzerlerine monte edilen kamera ve sensörlerin yetenekleri sayesinde, tarımda genellikle izleme, inceleme, tespit, karar verme, haritalama, sınıflandırma, algılama, araştırma, değerlendirme, tahmin, yönetim vb. görevlerde sıklıkla kullanılmaktadır (Özgüven ve Yanar, 2022). Tarım sektöründe yapay zekâ teknolojileri, pek çok alanda etkili biçimde kullanılmaktadır. Bu akıllı sistemler sayesinde bitki üretim süreçlerinin planlanmasından, bitki türlerinin ayrıştırılmasına kadar birçok aşamada veri temelli kararlar alınabilmektedir. Ayrıca verim tahmini yapılması; hastalıklar, zararlılar ve yabancı otların erken tespiti mümkün hâle gelmiştir. Tarım robotlarında rota optimizasyonu ve uygulama senaryolarının belirlenmesi gibi operasyonel süreçler de yapay zekâ yardımıyla hızlandırılmakta; seralarda uygun iklimlendirme koşulları tespit edilerek ürün kalitesi korunmaktadır. Sulama sistemlerinin yönetimi, ürün döngüsü planlamaları, işletme stratejilerinin oluşturulması ve tarım ekipmanlarının en uygun şekilde seçimi gibi kararlar, bu teknolojilerin katkısıyla daha verimli hâle gelmektedir (Turgut vd., 2020). Yapay zekâ destekli teknolojilerin geliştirilmesi tarım 4.0 sürecine yol açmıştır.

Tarım 4.0 süreciyle birlikte elektronik donanımlar, yazılım sistemleri ve sensör teknolojilerinin tarımsal üretime entegrasyonu hız kazanmış; özellikle 2000 yılında GPS teknolojisinin sivil kullanıma açılmasıyla birlikte konum tabanlı veri toplama ve değişken oranlı uygulamalar gibi hassas tarım tekniklerinin uygulanabilirliği artmıştır. Bu gelişmeler, zamanla otomatik kontrol sistemlerinin geliştirilmesine

de zemin hazırlamıştır. Devam eden süreçte yapay zekâ, robotik teknolojiler, nesnelerin interneti (IoT), otonom sistemler, insansız hava araçları (drone), yüksek işlem kapasiteli bilgisayarlar, bulut tabanlı bilişim çözümleri ve büyük veri analitiği gibi ileri teknolojilerin yaygınlaşmasıyla günümüzdeki dijital tarım düzeyine ulaşılmıştır. Bu teknolojik ilerlemeler doğrultusunda, otonom traktörler, robotik tarım makineleri ve akıllı sistemlerle donatılmış ekipmanların geliştirilmesine yönelik çalışmalar hız kazanmıştır. Hâlihazırda, tarım makinelerinin akıllı sistemlerle donatılması ve gerçek zamanlı, otomatik çalışan uzman sistemlerin tasarlanması üzerine yoğun araştırmalar yürütülmektedir. Önümüzdeki dönemde Tarım 5.0 vizyonu kapsamında, kitlesel üretimden ziyade bireyselleştirilmiş çözümlerin ön plana çıkacağı ve tarım makineleri ile teknolojilerinin daha yüksek düzeyde otonomi ve zekâ kapasitesine sahip olacağı öngörülmektedir (Özgüven, Emiroğlu ve Çolak, 2024: 220). Tarımsal üretimde teknoloji kullanımının yanında, verimin arttırılmasında su kaynaklarının tasarruflu kullanılması da önem kazanmaktadır.

Türkiye'nin yıllık kullanılabilir su miktarı yaklaşık 110 km³ olup, bunun yaklaşık 40 km³'lük kısmı fiilen kullanılmaktadır. Bu kullanımın büyük bölümü tarımsal sulamaya ayrılırken (%75), geri kalan suyun %15'i içme ve kullanma amaçlı, %10'u ise sanayi alanında değerlendirilmektedir. Toprak ve su gibi hayati doğal kaynakların korunması, yalnızca bugünün değil, gelecek kuşakların yaşam güvencesi açısından da kritik öneme sahiptir. Bu nedenle tarımsal faaliyetlerde suyun verimli ve bilinçli biçimde kullanılması, ekosistem

sürdürülebilirliği ve kaynakların uzun ömürlü olması için kaçınılmaz bir gerekliliktir (Aras, 2006).

Akıllı sulama sistemleri, özellikle tarım ve peyzaj alanlarında suyun verimli kullanımını sağlamak amacıyla geliştirilen ileri düzey teknolojik çözümler arasında yer almaktadır. Bu sistemler; sensörler, kontrol birimleri, iletişim altyapıları, otomatik vanalar, yağmurlama düzenekleri, meteorolojik veri istasyonları ve veri analitiği yazılımlarından oluşan çok bileşenli bir yapıya sahiptir. Söz konusu bileşenler, su kaynaklarının korunması ve sürdürülebilir tarımsal üretimin desteklenmesi amacıyla entegre biçimde çalışmaktadır. Akıllı su yönetimi kapsamında kullanılan otomatik vanalar, oransal sulama imkânı sunmakta ve uzaktan erişimle su tüketiminin kontrol edilmesine olanak tanımaktadır. Bu vanalar; bir kontrol ünitesi, akış ölçer, kablosuz iletişim modülü ve enerji kaynağından oluşmaktadır. Sulama hatlarındaki su akışını izleyen akış ölçerler aracılığıyla elde edilen veriler, kablosuz bağlantı yoluyla bulut tabanlı bir yazılım platformuna aktarılmakta; kullanıcılar bu verilere mobil cihazlar veya bilgisayarlar üzerinden erişerek sistem üzerinde gerekli ayarlamaları gerçekleştirebilmektedir (Şahin, 2024: 43–44).

3. Bahçe Bitkileri Yetiştiriciliğinde Yapay Zekâ Uygulamaları

Bahçe bitkileri yetiştiriciliğinde fide dikimi, gübreleme, sulama, hastalık-zararlılarla mücadele ve hasat gibi işlemler yapay zekâ teknolojilerinden yararlanılarak otomatik izleme, kontrol sistemleri ve teknik olanakların kullanılması ile daha nitelikli ve verimli üretim

yapılması, minimum girdi kullanımı, tarımsal işlemlerin optimize edilmesi, daha etkin yönetim kararlarının alınması, daha rekabetçi bir tarımsal üretimi mümkün kılmaktadır (Özgüven, 2023; 175). Tarımda halen var olan bilgi ve tecrübelerin, dijital teknolojilerin ürünleri olan makine öğrenmesi, yapay zeka, derin öğrenme, simülasyon ve modelleme uygulamaları ile birlikte değerlendirilmesi sonucu, gerçek zamanlı ve otomatik çalışan uzman sistemler, otonom tarım makineleri ve tarımsal robotik uygulamaların geliştirilmesine neden olmuştur (Özgüven, 2018). Bahçe bitkileri yetiştiriciliğinde çeşitli zararlılara karşı zirai mücadele gerekmektedir. Bu mücadele insan gücüne dayalı olarak yapılmakta iken günümüzde yapay zekâ destekli teknolojiler yardımıyla gerçekleştirilmektedir.

Campos ve arkadaşları tarafından (2020), bağlarda değişken oranlı ilaçlama yapma gücüne sahip olan yeni bir püskürtme (pülvarizatör) aracı geliştirilmiş ve bu aletin çalışma başarısı kontrol edilmiştir. İnsansız hava aracına konumlandırılmış kamera kullanılarak reçeteli haritalar elde edilmiştir. Daha sonra bu haritalar VRA prototipine yüklenmiş ve uygulama süreçleri tamamlandıktan sonra gerçek değişken oranlı VRA haritalarının elde edildiği ifade edilmiştir. Bu teknik ile bağlarda ilaçlamalar gerçekleştirilmiştir.

Armut üretim alanlarında ateş yanıklığı hastalığının kontrol altına alınması bahçelerin bu hastalık açısından düzenli görsel denetimlerine ihtiyaç duyulmaktadır. Öte yandan, görsel izleme zaman alıcı olup aynı zamanda emek yoğun bir işlemdir. Bu sorunu aşmak amacıyla mevcut alan incelemelerinin İHA'lar üzerinde takılı spektral

sensörlü kameralar ile yapılması, daha geniş sahaların kısa sürede izlenmesini sağlamaktadır (Özgüven, 2023; 178). Bahçe bitkileri yetiştiriciliğinde üretim ve hasat sırasında ya da nakliye, depolama ve satış sırasında üründe çeşitli kayıplar oluşabilmektedir.

Küresel ölçekte tarımsal üretimde meydana gelen kayıpların nedenlerine bakıldığında, yaklaşık %9,1'inin bitki hastalıklarından, %11,2'sinin zararlı organizmalardan ve %14,7'sinin ise yabancı otlardan kaynaklandığı görülmektedir. Bu oranlar birlikte değerlendirildiğinde, dünya genelindeki toplam tarımsal üretimin yaklaşık üçte birinin bu etkenler nedeniyle kayba uğradığı anlaşılmaktadır. Ayrıca, hasat sonrası dönemde yaşanan ve %6 ile %12 arasında değişen kayıplar da dikkate alındığında, toplam kayıp oranı %50 seviyelerine yaklaşmaktadır (Toksöz ve ark., 2018). Bahçe bitkileri yetiştiriciliğinde zararlı organizmaların üründe kayıplara yol açacağı bilinmektedir.

Domates üretiminde karşılaşılan temel sorunlardan biri zararlı organizmalardır. Bu zararlılar, domates meyvesinin hem verim düzeyini hem de kalite özelliklerini olumsuz etkileyerek, özellikle pazarlama sürecinde önemli kayıplara yol açmaktadır (Yılmaz ve ark., 2014). Bitki hastalıklarının erken teşhisi ve gerekli önlemlerin zamanında alınabilmesi için uzman görüşüne başvurulması büyük önem taşımaktadır. Ancak mevcut zirai danışmanlık sistemleri, tüm üreticilere ihtiyaç duydukları anda etkin destek sunmakta yetersiz kalabilmektedir. Oysa bitki koruma uygulamalarında zamanlama kritik bir faktördür ve birçok durumda anlık müdahaleler gereklidir. Bu

bağlamda, üreticilerin bilgiye hızlı erişimini sağlayacak mobil uygulamaların geliştirilmesi önemli bir fırsat sunmaktadır. Özellikle yapay zekâ tabanlı çıkarım motorları, üretim sürecinde yer alan kullanıcıların karar alma süreçlerini destekleyerek, tarımsal faaliyetlerin daha verimli ve etkili yürütülmesine katkı sağlayabilir (Demir vd., 2021: 92). Bahçe bitkileri yetiştiriciliğinde bitkilerin beslenmesinde yapay zekâ teknolojilerinin kullanımı gittikçe önem kazanmaktadır.

Bitki kök sistemlerinin analizi, özellikle bitki dayanıklılığı ve besin alım etkinliğinin değerlendirilmesi açısından büyük önem taşımaktadır. Bu bağlamda geliştirilen ChronoRoot Sistemi, zaman serisi görüntüleme teknikleri ile derin öğrenme (DL) algoritmalarını birleştirerek, kök uzunluğu, dallanma yapısı ve diğer morfolojik özellikleri otomatik olarak ölçebilmektedir. Sistem, özellikle ResUNet ve SegNet gibi gelişmiş DL modelleri aracılığıyla kök yapılarını yüksek doğrulukla analiz edebilmektedir. ChronoRoot, kuraklık stresine dayanıklı bitki genotiplerinin belirlenmesine yönelik ıslah çalışmalarında etkili bir araç olarak öne çıkmaktadır. Bu teknoloji, kök sistemlerinin karmaşık yapısal dinamiklerini doğru biçimde modelleyerek, su kıtlığına karşı toleranslı çeşitlerin daha hızlı ve güvenilir şekilde seçilmesine katkı sağlamaktadır (Negus vd., 2023). Günümüzde akıllı telefonların ucuzlaması ve yaygınlaşması nedeniyle çiftçilerin çeşitli uygulamalar için bu cihazlardan yararlanmaları gittikçe artmaktadır.

Yapay zekâ destekli akıllı telefon uygulamaları, tarımsal üretimde özellikle bitki sağlığının anlık takibini mümkün kılan yenilikçi çözümler arasında yer almaktadır. Bu sistemler, görüntü işleme algoritmaları aracılığıyla yaprak hastalıkları, zararlı organizmalar ve besin eksiklikleri gibi sorunları tespit edebilme kapasitesine sahiptir. Akıllı telefon tabanlı bu uygulamalar, çiftçilere düşük maliyetli ve erişilebilir bir yöntemle tarla koşullarını değerlendirme ve hastalık yönetimine yönelik stratejiler geliştirme imkânı sunmaktadır (Sun vd., 2024). Günümüzde sensör teknolojilerinin tarımsal üretimde kullanımları da gün geçtikçe artmaktadır.

Düşük maliyetli sensör teknolojileri, tarımsal üretimde toprak nemi, sıcaklık ve bitki gelişimi gibi temel çevresel parametrelerin izlenmesine olanak tanıyarak üreticilere önemli ölçüde bilgi desteği sağlamaktadır. Bu sensörler, su ve gübre gibi girdilerin daha verimli kullanılmasını teşvik ederek hem üretim maliyetlerinin azaltılmasına katkı sunmakta hem de çevresel sürdürülebilirliğin güçlendirilmesine yardımcı olmaktadır (Nie vd., 2022; Negus vd., 2024). Yapay zeka teknolojilerinin robotik sistemlere entegre edilmesi verimli tarımsal üretimin gerçekleştirilmesine neden olmaktadır.

Muzun olgunluk düzeyine göre sınıflandırılması ve hasat zamanının belirlenmesine yönelik çalışmalarda, robotik sistemler üzerinde yer alan kameralar aracılığıyla elde edilen görüntüler analiz edilerek meyveler olgunluk seviyelerine göre ayrılmaktadır. Bu

sistemde, her bir robotun yalnızca belirli bir olgunluk sınıfına ait ürünleri toplamakla görevli olduğu varsayılmaktadır. Robotlar arasında kurulan iletişim ağı sayesinde, her ağacın üzerindeki meyvelerin olgunluk durumu tüm robotlarla paylaşmakta ve böylece görev dağılımı yapılmaktadır. İlgili olgunluk düzeyindeki ürünleri toplamakla sorumlu olan robot ya da robotlar, en uygun güzergâhı belirleyerek hasat işlemini gerçekleştirmektedir. Bu güzergâh planlaması, sıklıkla gezgin satıcı problemi (Travelling Salesman Problem) çözümünde kullanılan algoritmalar temel alınarak yapılmaktadır (Dulkadir ve Gültekin, 2023: 27). Bahçe bitkileri yetiştiriciliğinde yapay zekâ destekli teknolojiler yardımı ile etkin ve verimli sulama sistemleri kurulabilmektedir.

Yüzey altı damla sulama sistemleri, 1990'lı yıllardan itibaren Amerika Birleşik Devletleri, İsrail ve İtalya gibi ülkelerde çim alanları, yem bitkileri ve meyve bahçeleri gibi çok yıllık bitkilerin sulanmasında yaygın biçimde kullanılmaktadır. Türkiye'de ise bu sistemlerin kurulumu son yıllarda önemli bir artış göstermiştir. Ancak yapılan araştırmalar, bu yöntemin tek yıllık bitkilerde uygulanmasında bazı teknik sınırlamaların bulunduğunu ortaya koymuştur. En sık karşılaşılan sorunlardan biri, ekim veya dikim sonrası, tohum yatağı ya da fide kök bölgesine ulaşmak amacıyla lateral boruların bulunduğu derinliğe kadar aşırı miktarda su verilmesidir. Bu durum, hem suyun israfına yol açmakta hem de topraktaki bazı besin elementlerinin yıkanarak kaybına neden olmaktadır. Öte yandan, meyve ağaçlarında ilk iki yıl boyunca yüzey damlama ya da alternatif sulama sistemlerinin

kullanılması, ardından yüzey altı damlama sistemine geçilmesi daha uygun bir yaklaşım olarak değerlendirilmektedir. Araştırma bulguları, toprak yapısı, bitki türü, iklim koşulları ve işletme özellikleri dikkate alınarak tasarlanan ve teknik esaslara uygun şekilde işletilen basınçlı sulama sistemlerinin, %20 ila %40 arasında su tasarrufu sağlayabildiğini göstermektedir. Bu nedenle, basınçlı sulama sistemlerinin yaygınlaştırılması ve bu sistemlerin etkin biçimde işletilmesini sağlamak amacıyla gerekli düzenlemelerin ve denetim mekanizmalarının hayata geçirilmesi büyük önem taşımaktadır (Yıldırım vd., 2025: 59).

4. Hayvan Yetiştiriciliğinde Yapay Zekâ Uygulamaları

Yapay zekâ kullanılarak hayvan hastalıklarının tespiti, uygun yem rasyonlarının hazırlanması, hayvan davranışlarının belirlenmesi gibi konularda araştırmacılar tarafından çok sayıda çalışma yapılmıştır (Turgut vd., 2020).

Sivamani ve çalışma arkadaşları (2017), hayvan sağlığının iyileştirilmesine yönelik beslenme yönetimi kararlarının analizinde, bulanık mantık kurallarını temel alan Bayesyen bir model önererek karar destek sistemlerine yeni bir yaklaşım sunmuşlardır. Bu modelde, özellikle besin tüketim miktarı, laktasyon dönemi ve canlı ağırlık gibi değişkenlere bağlı olarak beslenme olasılıkları değerlendirilmektedir. Bayes mantığı, koşullu olasılık ilkeleri çerçevesinde, hayvanların sağlık durumunun belirlenmesinde bulanık mantıkla birlikte kullanılmakta; böylece çoklu bağımlılıkların söz konusu olduğu durumlarda karar

verme süreçlerine katkı sağlamaktadır. Bu yaklaşım, belirsizlik içeren verilerle çalışırken daha esnek ve etkili sonuçlar elde edilmesine olanak tanımaktadır.

Gutierrez-Galan ve çalışma arkadaşları (2018), hayvan davranışlarının tanımlanması, sınıflandırılması ve izlenmesine yönelik bir sistem geliştirmişlerdir. Bu amaçla, kablosuz sensör ağına entegre edilmiş atalet sensörleri ile donatılmış ve gömülü çok katmanlı algılayıcı yapısına sahip ileri beslemeli yapay sinir ağı kullanan akıllı tasma cihazı tasarlanmıştır. Sistem, farklı yürüme biçimleri ve davranışsal verileri toplayarak bu bilgileri sınıflandırmakta ve hayvanların davranış örüntülerini analiz etmeye olanak tanımaktadır.

Memmedova (2012), klasik yöntemlerle tespiti güç olan subklinik mastitisin erken evrede belirlenmesine yönelik olarak yapay zekâ tekniklerinden yararlanmıştır. Çalışma, otomatik sağım sistemine sahip bir işletmede yetiştirilen Siyah Alaca sığırların verileri kullanılarak gerçekleştirilmiş ve bu doğrultuda hayvan sağlığının korunmasına katkı sağlayacak bir yaklaşım geliştirilmiştir.

Akıllı ve arkadaşları (2014), çiğ sütün kalite değerlendirmesine yönelik olarak bulanık mantık temelli bir karar destek sistemi geliştirmişlerdir. Söz konusu sistemde, somatik hücre sayısı, toplam bakteri düzeyi ve protein oranı temel giriş parametreleri olarak belirlenmiştir. Araştırma kapsamında, sistemin karar verme performansını değerlendirmek amacıyla, sistemin ürettiği sonuçlar

alanında uzman bir kişinin kararlarıyla karşılaştırılmış ve yaklaşık %80 oranında bir başarı elde edildiği rapor edilmiştir.

5. Gıda İşleme ve Muhafazasında Yapay Zekâ Uygulamaları

Gıda endüstrisinde Endüstri 4.0'ın sunduğu dijital dönüşüm olanakları, üretim aşamalarında hem verimliliği artırmakta hem de maliyetleri azaltma fırsatı sunmaktadır. Yapay zekâ, Nesnelerin İnterneti (IoT), robotik sistemler ve büyük veri analizi gibi teknolojik gelişmeler sayesinde üretim hatları daha hızlı işleyebilmekte, süreçler izlenebilir hâle gelmekte ve güvenlik seviyeleri yükselmektedir. Bu akıllı sistemler sayesinde ürünlerin kalitesi daha titizlikle izlenmekte, kontaminasyon gibi sağlık riskleri minimuma indirilmektedir. Özellikle sensörler ve IoT altyapısı, üretim esnasında gerçek zamanlı veri takibi sağlayarak olası risklerin erken safhada belirlenmesine yardımcı olmaktadır. Böylelikle önleyici çözümler devreye alınabilir. Ayrıca, tedarik zinciri boyunca sağlanan veri şeffaflığı ve operasyonel verimlilik, ürünlerin daha güvenli bir şekilde nihai tüketiciye ulaşmasını mümkün kılmaktadır (Türkoğlu ve Külçü, 2024 : 827)

Gıda ürünlerinin temel bileşenlerini genellikle bitkisel ya da hayvansal kaynaklı dokular oluşturmaktadır. Bu ürünler, tüketim öncesinde bozulmalarını önlemek amacıyla çeşitli işleme ve ambalajlama aşamalarından geçirilmektedir. Mikrobiyal kaynaklı bozulmalar, gıdalarda fiziksel ve kimyasal değişimlere yol açarak hem besin değerini düşürmekte hem de insan sağlığı açısından ciddi riskler oluşturabilmektedir. Ayrıca, üretimden tüketime kadar olan süreçte

hijyen ve sanitasyon kurallarına yeterince uyulmaması ile tüketici kaynaklı hataların da eklenmesi, gıda güvenliğini tehdit eden önemli risk faktörleri arasında yer almaktadır (Arıkbay, 2004).

Tarımsal ürünlerin gıda formuna dönüştürülmesi sürecinde, üretim hattında insan iş gücünün yerini otomasyon sistemlerinin alması yönünde önemli bir eğilim gözlemlenmektedir. Bu sistemler, ürün kabulünden başlayarak fabrikadaki tüm işlemleri, depolama süreçlerini ve nihayetinde tüketiciye ulaşana dek olan tüm aşamaları izleyerek otomatik biçimde kayıt altına almaktadır. Bu tür bir yapıda, hijyenik, güvenilir ve yüksek kaliteli gıda üretimi temel öncelik hâline gelmektedir. Hijyenik gıda; fiziksel, kimyasal ve mikrobiyolojik açıdan temiz ve bozulmamış ürün olarak tanımlanmaktadır. Tüketiciye güvenli gıdanın ulaştırılabilmesi için, üretim zinciri boyunca oluşabilecek kontaminasyonların önlenmesi büyük önem taşımaktadır. Bu doğrultuda, çeşitli sensör ve biyosensör teknolojileri ile birlikte süreç takibini mümkün kılan RFID sistemleri yaygın biçimde kullanılmaktadır (Özgüven vd., 2020: 304).

Gıda işleme tesislerinde, özellikle paketlenme, ambalaj açma ve paletleme gibi üretim hattı işlemlerinde yaygın olarak kullanılan endüstriyel robotların büyük çoğunluğu sert metal bileşenlerden oluşmaktadır. Günümüzde “sert robotlar” olarak adlandırılan bu sistemlerin üretim sürecinde; yüksek maliyet, karmaşık kontrol sistemleri ve ağırlık sınırlamaları gibi çeşitli teknik zorluklarla karşılaşmaktadır (Özgüven vd., 2020: 305).

Akıllı kontrol sistemleri; kontrol mühendisliği, uzman sistemler, otomasyon teknolojileri, bilgisayarla görme, sensör füzyonu, yöneylem araştırması ve yapay zekâ gibi çeşitli disiplinlerin kesişiminde yer alan çok alanlı bir çalışma sahasıdır. Son yıllarda, bu teknolojilerin tarımsal ürünlerin kurutulması süreçlerinde de uygulama alanı bulduğu görülmektedir. Kurutma işlemleri, ürünün fiziksel özelliklerine bağlı olarak kesikli (yığın) ya da sürekli sistemler şeklinde gerçekleştirilebilmektedir. Uygulama yöntemi ne olursa olsun, sistemin izlenebilirliği açısından sensör teknolojileri ve ölçüm cihazlarının doğru seçimi büyük önem taşımaktadır. Geleneksel kurutma sistemlerinde yalnızca çevresel parametreler (örneğin sıcaklık, nem, hava akışı) izlenip kontrol edilirken, modern sistemlerde ürün kalitesinin korunması temel hedef hâline gelmiştir. Bu doğrultuda, ürün merkezli izleme ve kontrol yaklaşımları kurutma teknolojilerinde ön plana çıkmaktadır (Martynenko ve Bück, 2019).

Geleneksel yöntemlerin ardından, patatesin uzun süre kalite kaybı olmadan muhafaza edilmesini sağlayan modern depolama sistemleri yaygınlık kazanmaya başlamıştır. Bu yeni nesil depolarda; sıcaklık, bağıl nem, hava akışı ve aydınlatma gibi çevresel koşullar hassas biçimde kontrol edilebilmekte, böylece hem kalite hem de ağırlık kayıpları en aza indirilmektedir. Modern patates depoları; havalandırma, ısıtma, soğutma ve otomatik kontrol sistemleriyle donatılmıştır. Tohumluk olarak değerlendirilecek yumruların +4 °C’de, tüketime yönelik olanların ise +5 ila +6 °C arasında saklanması gerekmektedir. Bu nedenle yumru iç sıcaklığının izlenmesi kritik

öneme sahiptir. Bu amaçla kullanılan proplar aracılığıyla elde edilen sıcaklık verileri kontrol panosuna iletilmekte; sistem, bu verilere göre ısıtıcı ya da soğutucuları devreye alarak sıcaklığı istenen düzeyde sabit tutmaktadır. Depo içi ve ürün bazlı sensörler sayesinde koşullar sürekli izlenmekte, böylece depolama ortamı dengede tutulmaktadır. Ayrıca, sistemler internet bağlantısı üzerinden uzaktan erişimle de yönetilebilmektedir. Kontrol altyapısında yer alan optimizasyon modülü, 10 günlük hava tahminlerine dayanarak havalandırma ve soğutma stratejileri geliştirmekte; bu sayede hem enerji maliyetleri düşürülmekte hem de ürünün hedeflenen sıcaklıkta daha ekonomik biçimde korunması sağlanmaktadır (Özgüven vd., 2020: 315–316).

6. Sonuç ve Öneriler

Teknolojinin sağladığı olanaklar ile kendi kendine hareket edebilen tarımsal robotlar, tarımsal üretimde ürün kalitesinin ve üretimde verimliliğin artırılması, insan gücüne dayalı tarımsal işlerdeki işgücünün ve üretim maliyetlerinin azaltılması ile çiftçi refahının geliştirilmesine katkı sağlayan önemli bir araçtır. Özel tasarlanan tarım robotu, tarımsal alanda bitki sıra aralarında bitkilere zarar vermeden kendi kendine hareket edebilmekte ve hareketi sırasında görüntü işleme teknolojisi ile haritalama yapabilmektedir (Özgüven vd., 2016: 116).

Tarımsal üretimde dijital teknolojilerin entegrasyonu; verimliliğin ve ürün kalitesinin artırılması, girdi kullanımının azaltılması yoluyla üretici gelirlerinin yükseltilmesi, tarımsal faaliyetlerin kolaylaştırılması ve çevresel sürdürülebilirliğin sağlanması açısından önemli fırsatlar sunmaktadır. Bu teknolojilerin

geliştirilmesine yönelik akademik ve endüstriyel çalışmalarda son yıllarda belirgin bir artış gözlemlenmektedir. Uluslararası raporlar, bazı ülkelerin büyük ölçekli firmaları aracılığıyla bu alanda yenilikçi ürünler geliştirerek dijital tarım teknolojilerinde öncü konuma geldiğini ortaya koymaktadır (Özgüven vd., 2024: 230).

Akıllı sulama sistemleri ve diğer yenilikçi tarım teknolojilerinin satışı, projelendirilmesi ve ithalat süreçlerinin ilgili kamu otoriteleri tarafından denetlenmesi büyük önem taşımaktadır. Bu kapsamda, gerekli görüldüğü takdirde yasal düzenlemelerin yapılması da gündeme gelmelidir. Ayrıca, bu teknolojilerin dışa bağımlı biçimde temin edilmesi yerine, yerli üretimin teşvik edilmesi gerekliliği ön plana çıkmaktadır. Savunma sanayisinde olduğu gibi, bu alanda da kamu kurumları arasında güçlü bir koordinasyon ve stratejik yaklaşım benimsenmelidir. Aksi takdirde, “yeni tarım teknolojileri” adı altında düşük kaliteli ve uygun olmayan ürünlerin ithalatı, hem ekonomik kaynakların israfına hem de sektörel verimsizliklere yol açabilecektir (Şahin, 2024: 52).

Drone teknolojisinin, gelecekte tarımsal üretim süreçlerinin ayrılmaz bir bileşeni hâline gelmesi öngörülmektedir. Ancak bu potansiyelin etkin biçimde değerlendirilebilmesi için ekonomik, teknik ve mevzuata ilişkin çeşitli engellerin aşılması gerekmektedir. Bu doğrultuda, çiftçiler, kamu kurumları, özel sektör temsilcileri ve araştırma kuruluşları arasında güçlü bir iş birliği tesis edilmesi, drone kullanımının yaygınlaştırılmasına katkı sağlayarak tarım sektöründe

daha verimli ve sürdürülebilir bir yapının oluşmasına olanak tanıyacaktır (Akat ve Ölmez Bayhan, 2025: 62).

Günümüzde tarımsal üretimin planlanması, yürütülmesi ve kârlılığın izlenmesine yönelik olarak geliştirilen çok sayıda mobil uygulama bulunmaktadır. Ancak bu uygulamaların büyük bir kısmı, farklı ülkelerin kullanıcı profillerine göre tasarlandığı için Türkiye'nin toprak yapısı, coğrafi özellikleri ve üretici kitlesinin sosyokültürel özellikleriyle yeterince örtüşmemektedir. Bu durum, söz konusu uygulamaların ya hiç kullanılmamasına ya da beklenen düzeyde etki yaratamamasına neden olmaktadır. Bu nedenle, yerel koşullara uygun mobil tarım uygulamalarının geliştirilmesi, yüksek doğrulukla çalışan sistemlerin oluşturulması ve bu uygulamaların tarımsal yayım faaliyetleriyle geniş üretici kitlelerine ulaştırılması büyük önem taşımaktadır (Altıkat, 2022: 169).

Gelişen akıllı tarım teknolojileri kapsamında, bulut tabanlı veri sistemlerine entegre edilen yüksek çözünürlüklü kameralara sahip insansız hava araçları aracılığıyla ekili alanların izlenmesi mümkün hâle gelmiştir. Ayrıca, dijital sensörler yardımıyla toprak ve hava koşullarına ilişkin nem, sıcaklık gibi çevresel parametreler takip edilerek, su ve enerji gibi sınırlı kaynakların daha verimli kullanılması sağlanmakta; böylece çevre ve su kirliliği gibi olumsuz etkiler azaltılmaktadır. Bu teknolojiler sayesinde çiftçiler, üretim süreçlerini daha ayrıntılı analiz edebilmekte ve performanslarını değerlendirme imkânı bulmaktadır. Tarımda nesnelerin interneti (IoT) uygulamalarının yaygınlaşması, verimliliği önemli ölçüde artırmıştır.

Geliştirilen ileri düzey bilişim sistemleri, toprakta bulunan ağır metaller ve zararlı kimyasalların analizini mümkün kılmakta ve uzaktan kontrol olanakları sunmaktadır. Akıllı tarım uygulamaları, doğal kaynakların korunmasına ve çevre dostu üretim anlayışının benimsenmesine katkı sağlamakta; ürünlerin zamanında hasat edilmesiyle kalite ve verim artışı elde edilmektedir. IoT tabanlı çözümlerin yaygın kullanımı, toprak verimliliğini artırarak çiftçilerin gelir düzeyini yükseltmekte ve kırsal kalkınmaya olumlu katkılar sunmaktadır. Tarım sektörü, bu teknolojiler sayesinde daha sağlıklı ve güvenilir ürünlerin üretildiği bir yapıya kavuşmakta; topraktaki zararlı maddelerin tespiti ve müdahalesi daha etkin biçimde gerçekleştirilebilmektedir. Türkiye’de de yapay zekâ destekli akıllı tarım uygulamalarının yaygınlaşmasıyla birlikte, kırsal alanlarda üretkenlik artmakta ve daha bilinçli bir çiftçi profili ortaya çıkmaktadır (Uzun, Bilban ve Arıkan, 2018: 5–6).

KAYNAKÇA

- Ağızan, K., Bayramoğlu, Z., & Ağızan, S. (2022). Akıllı tarım teknolojilerinin tarımsal işletme yöneticiliğine sunduğu avantajlar. *Turkish Journal of Agriculture-Food Science and Technology*, 10(9), 1697–1706.
- Akat, O., & Ölmez Bayhan, S. (2025). Tarımsal uygulamalarda drone kullanımı: Drone inovasyonu ile bitki koruma alanında ilerlemeler. In *Bitki Korumada Yeni Yaklaşımlar*. Paradigma Akademi Yayınları.
- Akıllı, A., Atıl, H., & Kesenkaş, H. (2014). Çiğ süt kalite değerlendirmesinde bulanık mantık yaklaşımı. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 20(2), 223–229.
- Altıkat, S. (2022). Tarımsal üretimde yapay zeka tabanlı akıllı cep telefonu uygulamaları. In *Proceedings Book/Tam Metin Bildiri Kitabı*, 17, 156.
- Amos, A., & Ruckelshausen, A. (2014). BoniRob – Autonomous mobile platform for phenotyping applications. *Phenodays 2014*, 29–31 October, Beaune, France.
- Aras, İ. (2006). Damla sulama yöntemi. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 15(1–2), 49–60.
- Arıkbay, C. (2004). Gıda sektöründe kalite yönetim sistemleri ve HACCP. *Milli Prodüktivite Merkezi Yayınları*, No: 660.

- Ayberkin, D. (2025). TarBloT KDS: Akıllı tarım uygulamaları için blokzincir ve IoT teknolojileri ile gerçek zamanlı karar destek sistemi tasarımı. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(1), 12–24.
- Aylak, B. L., Oral, O., & Yazıcı, K. (2021). Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezeri Journal of Science and Engineering*, 8(1), 74–93.
- Bajwa, I. S., Munir, M. S., & Cheema, S. M. (2019). An intelligent and secure smart watering system using fuzzy logic and blockchain. *Computers and Electrical Engineering*, 77, 109–119. <https://doi.org/10.1016/j.compeleceng.2019.05.006>
- Baltacı, A., Kushiyevev, R., Saruhan, Ö. Ü. İ., Toksöz, A. G. Ş., & Türk, E. (2018). Organik domates yetiştiriciliğinde zararlılar ile mücadele. *TÜRKTOB Dergisi*, 26, 32–37.
- Bilban, M., Uzun, Y., & Arıkan, H. (2018). Tarım ve kırsal kalkınmada yapay zekâ kullanımı. In *VI. KOP Bölgesel Kalkınma Sempozyumu*, 26–28 Ekim, Konya.
- Borgelt, C., & Kruse, R. (2006). Artificial intelligence methodologies. In CIGR (Ed.), *CIGR Handbook of Agricultural Engineering Volume VI: Information Technology* (pp. 153–168). ASABE.
- Campos, J., Gallart, M., Gil, E., Llop, J., Ortega, P., & Salcedo, R. (2020). On-farm evaluation of prescription map-based variable

rate application of pesticides in vineyards. *Agronomy*, 10(1), 102.
<https://doi.org/10.3390/agronomy10010102>

Çelik, B., & Öztürk, Y. K. (2024). Tarih ve teknoloji kesişiminde tarım: Antik çağdan yapay zekâ destekli geleceğe. *Atlas Journal*, 10(55), 149–163.

Delavarpour, N., Koparan, C., Nowatzki, J., Bajwa, S., & Sun, X. (2021). A technical study on UAV characteristics for precision agriculture applications and associated practical challenges. *Remote Sensing*, 13(6), 1204.

Demir, Ü., Kula, N., & Uğurlu, B. (2021). Tarımda yapay zekâ kullanımına yönelik karar destek modeli önerisi: Domates zararlısı tespiti örneği. *Lapseki Meslek Yüksekokulu Uygulamalı Araştırmalar Dergisi*, 2(4), 91–108.

Dulkadir, S., & Gültekin, G. K. (2023). Tarımsal otomasyon sistemleri için muz olgunluk seviyelerinin derin öğrenme yöntemleri ile sınıflandırılması. *EMO Bilimsel Dergi*, 13(3), 27–34.

Finger, R., Swinton, S. M., El Benni, N., & Walter, A. (2019). Precision farming at the nexus of agricultural production and the environment. *Annual Review of Resource Economics*, 11(1), 313–335. <https://doi.org/10.1146/annurev-resource-100518-093929>

Gutierrez-Galan, D., Morales, J. P. D., Escudero, E. C., Navarro, A. R., Morales, R. T., Perez, M. R., Morales, M. D., Fernandez, A. J., &

- Barranco, A. L. (2018). Embedded neural network for real-time animal behavior classification. *Neurocomputing*, 272, 17–26.
- Huong, T. T., Huu Thanh, N., Long, N. Van, Marshall, A., Tien Dat, N., & Van, N. T. (2018). Water and energy-efficient irrigation based on Markov decision model for precision agriculture. In *2018 IEEE 7th International Conference on Communications and Electronics (ICCE)* (pp. 51–56). <https://doi.org/10.1109/CCE.2018.8465723>
- Kutlugün, M. A. (2017). Gözetimli makine öğrenmesi yoluyla türe göre metinden ses sentezleme [Yüksek lisans tezi, İstanbul Sabahattin Zaim Üniversitesi]. Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği.
- Martynenko, A., & Bück, A. (2019). *Advances in drying science and technology: Intelligent control in drying*. CRC Press. ISBN: 978-1-4987-3275-8
- Memmedova, N. (2012). Süt sığırlarında mastitisin bazı yapay zekâ yöntemleri kullanılarak erken dönemde tespiti [Doktora tezi, Selçuk Üniversitesi]. Fen Bilimleri Enstitüsü, Zootekni Anabilim Dalı.
- Negus, K. L., Li, X., Welch, S. M., & Yu, J. (2023). The role of artificial intelligence in crop improvement. *Advances in Agronomy*, 184. <https://doi.org/10.1016/bs.agron.2023.11.001>

- Nie, J., Wang, Y., Li, Y., & Chao, X. (2022). Artificial intelligence and digital twins in sustainable agriculture and forestry: A survey. *Turkish Journal of Agriculture and Forestry*, 46(5), Article 5. <https://doi.org/10.55730/1300-011X.3033>
- Özgüven, M. M., Tan, M., Közkurt, C., Yardım, M. H., Özsoy, M., & Sabancı, E. (2016). Çok amaçlı tarım robotunun geliştirilmesi. *Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi*, 33(Ek sayı), 108–116.
- Özgüven, M. M. (2018). *Hassas tarım*. Akfon Yayınları.
- Özgüven, M. M. (2019). Teknoloji kavramları ve farkları. In *International Erciyes Agriculture, Animal & Food Sciences Conference*, 24–27 April, Erciyes University, Kayseri, Türkiye.
- Özgüven, M. M., & Yanar, Y. (2022). The technology uses in the determination of sugar beet diseases. In V. Misra, S. Srivastava, & A. K. Mall (Eds.), *Sugar beet cultivation, management and processing* (pp. [belirtilmemiş]). Springer. https://doi.org/10.1007/978-981-19-2730-0_30
- Özgüven, M. M. (2023). Bahçe bitkileri yetiştiriciliğinde kullanılan dijital tarım teknolojileri. *Tarım Makinaları Bilimi Dergisi*, 19(3), 174–193.

- Özgüven, M. M., Eminoğlu, M. B., & Çolak, A. (2024). Tarımda otonom araçların kullanımı. *Tarım Makinaları Bilimi Dergisi*, 20(3), 217–233.
- Pakdemirli, B., Birişik, N., Aslan, İ., Sönmez, B., & Gezici, M. (2021). Türk tarımında dijital teknolojilerin kullanımı ve tarım-gıda zincirinde Tarım 4.0. *Toprak Su Dergisi*, 10(1), 78–87.
- Sun, L., Lai, M., Ghouri, F., Nawaz, M. A., Ali, F., Baloch, F. S., & Shahid, M. Q. (2024). Modern plant breeding techniques in crop improvement and genetic diversity: From molecular markers and gene editing to artificial intelligence—A critical review. *Plants*, 13(2676). <https://doi.org/10.3390/plants13192676>
- Şahin, H. (2024). Tarımsal akıllı sulama sistemlerinde yapay zekâ, derin öğrenme ve nesnelerin interneti uygulamaları. *Tarım Makinaları Bilimi Dergisi*, 20(1), 41–60.
- Terzi, İ., Özgüven, M. M., Altaş, Z., ve Uygun, T. (2019). Tarımda Yapay Zeka Kullanımı. International Erciyes Agriculture, Animal & Food Sciences Conference 24-27 April 2019 - Erciyes University – Kayseri,Türkiye.
- T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı. (2023). *On ikinci kalkınma planı (2024–2028): Tarımda teknoloji kullanımı, özel ihtisas komisyon raporu*. Ankara.

- Toksöz, A. G. Ş., Kushiyeu, R., Baltacı, A., Türk, E., Saruhan, Ö. Ü. İ. (2018). Organik Domates Yetiştiriciliğinde Zararlılar ile Mücadele. *TÜRKTOB Dergisi*, 26, 32-37.
- Turgut, A., Temir, A., Aksoy, B., & Özsoy, K. (2020). Yapay zekâ yöntemleri ile hava sıcaklığı tahmini için sistem tasarımı ve uygulaması. *International Journal of 3D Printing Technologies and Digital Industry*, 3(3), 244–253.
- Türkoğlu, H., & Külcü, D. B. (2025). Gıda sektöründe Endüstri 4.0 ve gıda güvenliği. *Turkish Journal of Agriculture-Food Science and Technology*, 13(3), 821–830.
- Tzounis, A., Katsoulas, N., Bartzanas, T., & Kittas, C. (2017). Internet of Things in agriculture, recent advances, and future challenges. *Biosystems Engineering*, 164, 31–48. <https://doi.org/10.1016/j.biosystemseng.2017.09.007>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming: A review. *Agricultural Systems*, 153, 69–80. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Yıldırım, Y. E., Köksal, E. S., Çetin, Ö., Büyüktaş, D., Aydınşakir, K., Taş, İ., Can, G., Boyacıoğlu, A., Tüzün, A. M., Göktepe, N., Temel, M., Aral, G., & Süllü, G. (2025). Tarımsal su yönetimi. In *Türkiye Ziraat Mühendisliği X. Teknik Kongresi Bildiriler Kitabı-1*, 13–17 Ocak, Ankara.

- Yılmaz, M., Kavak, S., & Baysal, Ö. (2014). Bazı ticari sabit ve uçucu yağların domates bakteriyel kanser ve solgunluk etmeni üzerine antibakteriyel etkileri. *Derim*, 31(1), 50–60.
- Yurtoğlu, N. (2017). Cumhuriyet dönemi ziratte makineleşme sürecinde Türkiye Zirai Donatım Kurumu (TZDK) yeri ve önemi (1943–1960). *Tarih Okulu Dergisi*, 10(29), 277–312.
- Zhai, Z., Martínez, J. F., Beltran, V., ve Martínez, N. L. (2020). Decision support systems for agriculture 4.0: Survey and challenges. *Computers and Electronics in Agriculture*, 170, 105256.<https://doi.org/10.1016/J.COMPAG.2020.105256>

BÖLÜM 2

ELEKTRONİK SİSTEM TASARIMINDA, SİMÜLASYONUNDA VE EĞİTİMİNDE KULLANILAN YAPAY ZEKÂ ARAÇLARININ TANITILMASI¹

Doç. Dr. Gürcan UZAL

Dr. Öğr. Üyesi Hasan METE

Doç. Dr. Aytekin ERDEM

Dr. Öğr. Üyesi Erdal KILIÇ

GİRİŞ

Dijital çağın hızla gelişen dinamikleri, elektronik sistem tasarımı ve mühendisliğini derin bir dönüşüme uğratmaktadır. Bu dönüşümün merkezinde ise yapay zekâ (YZ) teknolojileri yer almaktadır. Geleneksel elektronik devre tasarımı süreçleri; yüksek teknik bilgi, uzun geliştirme süreleri ve simülasyon doğruluğu gibi zorluklarla karşı karşıya kalırken, yapay zeka destekli yöntemler bu süreçlerde radikal iyileştirmeler sunmaktadır (Leite et al., 2020). Özellikle derin öğrenme ve evrimsel algoritmalar gibi modern YZ yaklaşımları; otomatikleştirilmiş tasarım önerileri, hata tahmini ve optimizasyon gibi birçok alanda yeni imkanlar sağlamaktadır (Zhang et al., 2021).

¹ UBAK, IV. INTERNATIONAL SCIENTIFIC COMPILATION RESEARCH CONGRESS, 02-03 Eylül 2025 tarihinde sözlü bildiri olarak sunulmuştur.

YZ tabanlı sistemlerin elektronik tasarımlarda kullanılmaya başlanması, yalnızca mühendislik pratiklerini değil, aynı zamanda mühendislik eğitimi paradigmalarını da yeniden şekillendirmiştir. Simülasyon tabanlı eğitim platformlarına entegre edilen YZ algoritmaları sayesinde öğrenciler, geleneksel deney düzeneklerinin ötesine geçerek daha dinamik, etkileşimli ve kişiselleştirilmiş öğrenme deneyimleri yaşamaktadır (Aydin & Ince, 2022). Böylece mühendislik öğrencileri, hem tasarım hem de analiz süreçlerinde daha erken aşamalarda karar verme becerisi kazanmakta ve olası sistem hatalarını erken teşhis edebilmektedir.

YZ'nin bu kapsamlı etkisi, elektronik sistemlerin donanımsal ve yazılımsal bileşenlerini daha bütünsel bir yaklaşımla ele alma zorunluluğunu da doğurmuştur. Artık yalnızca fiziksel bileşenlerin değil, aynı zamanda veriye dayalı karar alma süreçlerinin de sistemin ayrılmaz bir parçası olduğu bir çağda yaşıyoruz. Bu bağlamda, elektronik sistem tasarımı ve simülasyon süreçlerine YZ entegrasyonu, performans iyileştirmesi kadar sürdürülebilirlik ve enerji verimliliği gibi kritik hedeflere ulaşmada da önemli bir rol oynamaktadır (Khan & Singh, 2019).

Bu çalışma, elektronik sistem tasarımı ve simülasyon süreçlerinde yapay zekanın sunduğu yenilikçi yaklaşımları ele almakta; aynı zamanda YZ'nin mühendislik eğitimi üzerindeki dönüştürücü etkisini kuramsal ve uygulamalı açıdan incelemektedir. Böylece hem mevcut uygulamaların analizi hem de geleceğe yönelik vizyoner bir çerçeve sunulması amaçlanmaktadır.

1. Yapay Zekâ ve Devre Tasarımı

1.1 Kullanılan Yöntemler

1.1.1 Makine Öğrenmesi (Machine Learning ML)

Devre performans tahmini, parametre analizi ve arıza teşhisi gibi görevlerde kullanılır. Örneğin, bir ML modeli, farklı direnç ve kapasitör değerlerine göre bir filtre devresinin çıkışını tahmin edebilir.

1.1.2 Derin Öğrenme (Deep Learning DL)

Katmanlı yapısı sayesinde karmaşık devre topolojilerini öğrenebilir. Görsel analiz (ör. PCB üzerinde hatalı bağlantı tespiti) gibi görevlerde CNN (Convolutional Neural Network) modelleri kullanılır.

1.1.3 Evrimsel Algoritmalar (Evolutionary Algorithms)

Genetik algoritmalar gibi evrimsel tekniklerle en uygun devre bileşenleri ve topolojileri otomatik olarak seçilir. Optimum devre parametreleri, tasarım alanı içinde aranır.

1.1.4 Takviye Öğrenmesi (Reinforcement Learning RL):

Adım adım ilerleyen tasarım süreçlerinde kullanılır. Özellikle otomatik yönlendirme (routing) gibi tekrarlı (iterative) süreçlerde etkili olur.

1.1.5 Doğal Dil İşleme (Natural Language Processing NLP):

Doğal dilde verilen devre isteklerini şemaya dönüştürme. Örneğin: “3.3V ile çalışan bir düşük geçiren filtre” ifadesini devre şemasına dönüştürebilir.

1.2 Uygulama Alanları

- Analog ve sayısal devre tasarımı,
- PCB (Printed Circuit Board) otomasyonu ve termal analiz,
- Simülasyon destekli devre optimizasyonu,
- Elektronik Tasarım Otomasyonu (Electronic Design Automation EDA) yazılımlarında entegre yapay zeka (Artificial Intelligence AI) modülleri (Cadence, Synopsys, Xilinx vb.).

1.3 Örnek Araçlar

1.3.1 Cadence Cerebrus AI Studio: Yonga Tasarımında Yapay Zekâ Destekli Yeni Bir Dönem

Günümüzün hızla gelişen yarı iletken endüstrisinde, sistem-çip SoC (System on Chip) tasarımlarının karmaşıklığı ve ölçeği mühendislik ekiplerinin üretkenliğini zorlamaktadır. Bu bağlamda, **Cadence Cerebrus AI Studio**, yapay zekâ destekli tasarım otomasyonu alanında çığır açan bir platform olarak öne çıkmaktadır. Cadence tarafından geliştirilen bu araç, çok bloklu ve çok kullanıcılu SoC tasarımlarını optimize etmek amacıyla **ajan tabanlı yapay zekâ (Agentic AI)** teknolojisini kullanmaktadır (Cadence, 2025a).

Cadence Cerebrus AI Studio, geleneksel dijital tasarım akışlarını dönüştürerek mühendislerin aynı anda birden fazla blok üzerinde çalışmasına olanak tanımakta ve bu sayede mühendis başına düşen tasarım alanını önemli ölçüde artırmaktadır. Platform, tasarım

döngüsünü 5 ila 10 kat hızlandırırken, performans, güç tüketimi ve alan PPA (Performance, Power consumption and Area) metriklerinde %20'ye varan iyileştirmeler sağlamaktadır (Cadence, 2025b).

Bu platformun en dikkat çekici özelliklerinden biri, **canlı özelleştirilebilir tasarım panosu** aracılığıyla ekip içi iş birliğini artırmasıdır. Ayrıca, **transfer öğrenme** ve **akıllı model tekrar kullanımı** gibi yapay zeka teknikleri sayesinde, önceki tasarımlardan elde edilen veriler yeni projelere entegre edilerek tasarım süreci daha verimli hale getirilmektedir (Digital Engineering 24/7, 2025).

Samsung ve STMicroelectronics gibi sektör liderleri, Cadence Cerebrus AI Studio'yu kullanarak üretkenlikte 4 kata kadar artış ve SoC alt sistemlerinde %8–11 arasında PPA iyileştirmesi elde ettiklerini bildirmiştir (Cadence, 2025a).

Sonuç olarak, Cadence Cerebrus AI Studio, yapay zekânın elektronik tasarım otomasyonuna entegrasyonunda önemli bir adımı temsil etmekte ve mühendislik ekiplerinin karmaşık SoC tasarımlarını daha hızlı, daha verimli ve daha optimize bir şekilde gerçekleştirmelerine olanak tanımaktadır.

1.3.2 Synopsys DSO.ai: Yapay Zeka Destekli Çip Tasarımında Yeni Bir Dönem

Yarı iletken endüstrisinde artan karmaşıklık ve daha kısa ürün geliştirme döngüleri, elektronik tasarım otomasyonu (EDA) alanında

yenilikçi çözümleri zorunlu kılmıştır. Bu bağlamda, **Synopsys DSO.ai (Design Space Optimization AI)**, çip tasarım süreçlerinde yapay zekâ tabanlı otomasyonu mümkün kılan öncü bir platform olarak öne çıkmaktadır (Synopsys, 2025a).

DSO.ai, çip tasarımı sırasında **güç (power)**, **performans (performance)** ve **alan (area)** gibi çoklu hedefleri optimize etmek amacıyla **takviyeli öğrenme (Reinforcement Learning)** tekniklerini kullanır. Bu sayede, geleneksel yöntemlerle haftalar sürebilecek tasarım döngüleri, otonom karar alma mekanizmaları sayesinde önemli ölçüde kısaltılabilir (Technopat, 2023). Platform, Register Transfer Level (RTL)'dan Graphic Design System II (GDSII)'ye kadar olan tüm tasarım akışını kapsayan otonom bir optimizasyon süreci sunar ve mühendislerin manuel müdahalesini en aza indirerek üretkenliği artırır (Synopsys, 2025b).

DSO.ai'nin başarısı, yalnızca teorik değil, aynı zamanda pratik uygulamalarla da kanıtlanmıştır. Örneğin, Samsung, bu platformu kullanarak gelişmiş üretim süreçlerinde önemli performans kazanımları elde etmiş ve güç tüketimini azaltmıştır (Shunlongwei, 2021). Ayrıca, STMicroelectronics ve SK hynix gibi firmalar, DSO.ai sayesinde %25'e varan güç tasarrufu ve %3'e kadar alan küçülmesi raporlamıştır (Technopat, 2023).

DSO.ai'nin bir diğer önemli özelliği, çoklu kalıp (multi-die) sistemler için geliştirilen **3DSO.ai** modülüdür. Bu modül, termal bütünlük, sinyal bütünlüğü ve güç dağıtımı gibi sistem düzeyindeki

parametreleri optimize ederek, karmaşık 2.5D ve 3D tasarımlarda yüksek kaliteli sonuçlar elde edilmesini sağlar (Synopsys, 2025a).

Sonuç olarak, Synopsys DSO.ai, yapay zekânın EDA alanındaki potansiyelini somutlaştıran ve çip tasarımında verimlilik, kalite ve hız açısından devrim yaratan bir platformdur. Bu teknoloji, mühendislerin daha az kaynakla daha fazla inovasyon üretmesine olanak tanımaktadır.

1.3.3 Xilinx Vitis AI: Uçtan Buluta Gerçek Zamanlı Yapay Zekâ Hızlandırması

Yapay zekâ (YZ) uygulamalarının artan hesaplama gereksinimleri, donanım hızlandırılmalı çözümlerin önemini artırmıştır. Bu bağlamda, **Xilinx Vitis AI**, AMD tarafından geliştirilen ve **Field Programmable Gate Array (FPGA)**: Üretildikten sonra kullanıcı tarafından yeniden programlanabilen bir entegre devre ile **adaptif SoC** platformlarında gerçek zamanlı YZ çıkarımı (inference) gerçekleştirmek üzere optimize edilmiş bir geliştirme ortamıdır (AMD, 2024a).

Vitis AI, kullanıcıların **FPGA donanımı hakkında derin bilgi sahibi olmadan** derin öğrenme modellerini kolayca dağıtabilmelerini sağlar. Platform; **önceden eğitilmiş modeller (Model Zoo)**, **optimize edilmiş IP çekirdekleri**, **derleyiciler**, **kuantizasyon araçları**, **kütüphaneler** ve **örnek uygulamalar** gibi bileşenlerden oluşur (Xilinx, 2023). Bu yapı, hem uç cihazlarda hem de veri merkezlerinde

yüksek verimlilikle çalışan YZ uygulamalarının geliştirilmesini mümkün kılar.

Vitis AI, TensorFlow, PyTorch ve Caffe gibi yaygın derin öğrenme çerçevelerini destekler. Eğitimli modeller, platformun sunduğu **Vitis AI Quantizer** ve **Compiler** araçlarıyla FPGA'ye uygun hale getirilir. Ardından, **Deep Learning Processing Unit (DPU)** adı verilen özel donanım hızlandırıcıları üzerinde çalıştırılır (AMD, 2024b).

Platformun dikkat çeken bir diğer özelliği, **Vitis AI Library** aracılığıyla görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi görevler için yüksek seviyeli API'ler sunmasıdır. Bu sayede geliştiriciler, karmaşık algoritmaları hızlıca prototipleme ve dağıtma imkânı bulur (Xilinx, 2023).

Vitis AI, özellikle **akıllı şehirler, otonom araçlar, sağlık teknolojileri** ve **veri merkezi hızlandırma** gibi alanlarda yaygın olarak kullanılmaktadır. Platformun sunduğu **esneklik, düşük gecikme süresi** ve **güç verimliliği**, onu gömülü sistemlerde YZ uygulamaları için cazip bir seçenek haline getirmektedir (eeNews Europe, 2019).

1.3.4 AI-Circuit-Design (Açık kaynak)

Tanım ve Amacı

AI-Circuit, analog ve RF (radyo frekansı) entegre devre tasarımı için geliştirilmiş, açık kaynaklı bir **benchmark ve veri kümesi**

platformudur. Bu platform, makine öğrenimi algoritmalarının devre tasarımında kullanılabilirliğini sistematik biçimde değerlendirmek amacıyla oluşturulmuştur (Mehradfar et al., 2024). AI-Circuit, tasarım spesifikasyonlarından devre parametrelerine olan karmaşık eşlemeyi öğrenebilen modellerin geliştirilmesini ve karşılaştırılmasını hedefler.

Temel Teknolojik Bileşenler

Çok Katmanlı Devre Veri Kümesi: 7 temel analog devre (ör. common-source, cascode, two-stage amplifiers) ve 2 karmaşık RF sistem (verici ve alıcı) içerir (Mehradfar et al., 2024).

Makine Öğrenimi Modelleri: KNN, SVR, Random Forest, MLP ve Transformer gibi algoritmalarla test edilmiştir (Mehradfar et al., 2025).

Simülasyon Altyapısı: Python tabanlı bir simülasyon pipeline'ı ve Docker desteği ile kolay kurulum sağlar.

K-Fold Çapraz Doğrulama: Model karşılaştırmaları için sistematik deney tasarımı sunar.

Akademik Katkıları

AI-Circuit, analog/RF devre tasarımında veri odaklı yaklaşımların uygulanabilirliğini göstererek şu katkıları sunar:

Benchmark Standardizasyonu: Farklı ML modellerinin aynı veri kümesi üzerinde karşılaştırılmasına olanak tanır.

Tasarım Spesifikasyonlarından Parametre Öğrenimi: Geleneksel sezgisel yöntemlerin yerine öğrenmeye dayalı modelleme önerir.

Açık Kaynak Genişletilebilirlik: Araştırmacılar kendi modellerini entegre edebilir ve yeni devreler ekleyebilir (Avestimehr Research Group, 2024).

Uygulama Alanları

- Analog/RF devre tasarımı üzerine çalışan araştırma grupları için deneysel test ortamı,
- Otomatikleştirilmiş devre sentezi ve optimizasyon çalışmaları,
- Makine öğrenimi algoritmalarının mühendislik uygulamalarındaki etkinliğini değerlendirme.

2. Elektronik Eğitiminde Yapay Zekâ Tabanlı Simülasyonlar

2.1 Neden Simülasyon?

- Gerçek donanıma gerek kalmadan pratik yapma,
- Tehlikesiz hata deneyimi,
- Uygun maliyetli, erişilebilir laboratuvar.

2.2 YZ Entegrasyonunun Katkıları

- Kişiselleştirilmiş Öğrenme: Öğrencinin gelişimine uygun görevler,
- Otomatik Geri Bildirim: Gerçek zamanlı hata tespiti,
- Dilsel Asistanlar: NLP tabanlı devre danışmanları,
- Öğrenme Takibi: Performans analizi ve ilerleme takibi.

2.3 Uygulama Örnekleri

2.3.1 Tinkercad ve Yapay Zekâ Destekli Öneri Sistemleri: Eğitimde Kişiselleştirilmiş Üç Boyutlu (3B) Tasarım Deneyimi

Tinkercad, Autodesk tarafından geliştirilen, kullanıcı dostu bir **3B modelleme, elektronik devre tasarımı ve kodlama** platformudur. Özellikle STEM eğitimi bağlamında, öğrencilerin yaratıcı düşünme ve problem çözme becerilerini geliştirmelerine olanak tanıyan bu araç, hem başlangıç seviyesindeki kullanıcılar hem de eğitimciler için erişilebilir bir çözüm sunmaktadır (Autodesk, 2023).

Son yıllarda, **yapay zekâ (YZ) destekli öneri sistemlerinin** Tinkercad gibi yaratıcı platformlara entegrasyonu, kullanıcı deneyimini daha da kişiselleştirme potansiyeli taşımaktadır. Öneri sistemleri, kullanıcıların geçmiş etkileşimlerine, tasarım tercihlerine ve öğrenme hedeflerine dayalı olarak **kişiselleştirilmiş içerik, araç ve eğitim önerileri** sunabilir (Ultralytics, 2024). Bu sistemler, özellikle eğitim

ortamlarında öğrencilerin motivasyonunu artırmak ve öğrenme sürecini hızlandırmak açısından önemlidir.

Tinkercad’ın mevcut yapısı, kullanıcıların 3B nesneleri sürükleyip bırak yöntemiyle birleştirmesine, elektronik devreler oluşturmaya ve kodlama yapmasına olanak tanır (Tamindir, 2022). Ancak bu süreçte kullanıcıların karşılaştığı zorluklar, özellikle yeni başlayanlar için rehberlik ihtiyacını ortaya koymaktadır. Bu noktada, **YZ tabanlı öneri sistemleri**, kullanıcının tasarım geçmişini analiz ederek örnek projeler, uygun araçlar veya eğitim modülleri önerebilir. Böylece öğrenme süreci daha verimli ve etkileşimli hale gelir (Ultralytics, 2024).

Örneğin, bir kullanıcı Tinkercad üzerinde bir LED devresi tasarlarken, sistem benzer projeleri önererek hem ilham kaynağı sunabilir hem de teknik doğruluk açısından rehberlik edebilir. Ayrıca, **doğal dil işleme (NLP)** teknikleriyle desteklenen sohbet tabanlı yardımcılar, kullanıcıların sorularına anlık yanıtlar vererek öğrenme sürecini destekleyebilir (AskSia, 2025a).

Bu tür bir entegrasyonun başarılı olabilmesi için öneri sistemlerinin **içerik tabanlı filtreleme**, **işbirlikçi filtreleme** ve **hibrit yaklaşımlar** gibi yöntemleri kullanarak kullanıcı profillerini doğru şekilde modellemesi gerekmektedir (Ricci et al., 2022). Ayrıca, **simülasyon tabanlı test ortamları**, öneri algoritmalarının güvenli ve etkili bir şekilde değerlendirilmesini sağlar (Unite.AI, 2025).

Sonuç olarak, Tinkercad gibi yaratıcı öğrenme platformlarının yapay zekâ destekli öneri sistemleriyle entegrasyonu, **kişiselleştirilmiş öğrenme, daha hızlı tasarım süreci ve daha yüksek kullanıcı memnuniyeti** gibi avantajlar sunmaktadır. Bu yaklaşım, özellikle dijital eğitim teknolojilerinin geleceğinde önemli bir rol oynamaya adaydır.

2.3.2 Falstad + GPT Asistan Entegrasyonu: Elektronik Eğitiminde Yapay Zekâ Destekli Simülasyon Yaklaşımı

Falstad Circuit Simulator, Paul Falstad tarafından geliştirilen, tarayıcı tabanlı ve açık kaynaklı bir **elektronik devre simülasyon** aracıdır. Kullanıcıların direnç, kondansatör, transistör gibi temel bileşenleri kullanarak analog ve dijital devreleri görsel olarak modellemelerine olanak tanır (Falstad, 2023). Özellikle mühendislik eğitimi ve kendi kendine öğrenme süreçlerinde, gerçek zamanlı simülasyon yetenekleri sayesinde etkili bir öğrenme ortamı sunar.

Son yıllarda, **GPT tabanlı yapay zekâ asistanlarının** bu tür simülasyon platformlarıyla entegrasyonu, kullanıcı deneyimini dönüştürme potansiyeli taşımaktadır. GPT modelleri, doğal dil işleme (NLP) yetenekleri sayesinde kullanıcıların teknik sorularını yanıtlayabilir, devre tasarımı önerileri sunabilir ve hata ayıklama süreçlerinde rehberlik edebilir (OpenAI, 2024). Bu tür bir entegrasyon, özellikle yeni başlayanlar için öğrenme sürecini kolaylaştırırken, ileri düzey kullanıcılar için de üretkenliği artırabilir.

Örneğin, bir öğrenci Falstad üzerinde bir **astable multivibratör** devresi oluşturmak istediğinde, GPT destekli bir asistan, devre şeması, bileşen değerleri ve çalışma prensibi hakkında açıklamalar sunabilir. Ayrıca, kullanıcıdan gelen doğal dil girdilerini (örneğin: “bir LED yanıp sönsün istiyorum”) devre şemalarına dönüştürerek **koddan tasarıma geçişi** kolaylaştırabilir (AskSia, 2025b).

Bu tür bir sistemin başarısı, GPT modelinin **teknik bağlamı anlama, devre davranışlarını yorumlama ve öğretici açıklamalar sunma** becerisine bağlıdır. Ayrıca, kullanıcıların geçmiş etkileşimlerine dayalı olarak kişiselleştirilmiş öneriler sunan **öneri sistemleri** ile desteklenmesi, öğrenme sürecini daha etkili hale getirebilir (Ricci et al., 2022).

Sonuç olarak, Falstad gibi görsel simülasyon araçlarının GPT tabanlı yapay zekâ asistanlarıyla entegrasyonu, **etkileşimli, kişiselleştirilmiş ve erişilebilir** bir elektronik eğitimi deneyimi sunmaktadır. Bu yaklaşım, hem bireysel öğrenciler hem de eğitim kurumları için dijital öğrenme ortamlarının geleceğini şekillendirme potansiyeline sahiptir.

2.3.3 Oyunlaştırılmış Senaryolarda Yapay Öğrenci Modeli: Kişiselleştirilmiş Öğrenme için Bütüncül Bir Yaklaşım

Geleneksel eğitim yaklaşımlarının ötesine geçerek öğrencilerin bireysel farklılıklarını dikkate alan öğrenme ortamları oluşturmak, çağdaş eğitim teknolojilerinin temel hedeflerinden biridir. Bu bağlamda, oyunlaştırılmış senaryolarla entegre edilmiş yapay öğrenci

modelleri, öğrenme süreçlerini hem daha etkileşimli hem de kişiselleştirilmiş hale getirme potansiyeline sahiptir (Çöpgeven, Özkaya & Aydın, 2023).

Yapay Öğrenci Modeli (YÖM), öğrencinin bilgi düzeyi, öğrenme hızı, ilgi alanları ve bilişsel özellikleri gibi parametreleri analiz ederek, öğrenme sürecini bireysel ihtiyaçlara göre uyarlayan bir yapay zekâ bileşenidir (Barata et al., 2015). Bu model, oyunlaştırılmış öğrenme senaryoları ile birleştirildiğinde, öğrencinin motivasyonunu artırmakta ve öğrenme sürecine aktif katılımını teşvik etmektedir (Khakpour & Colomo-Palacios, 2021).

Oyunlaştırma, öğrenme ortamına puanlar, rozetler, seviye atlama, görevler ve liderlik tabloları gibi oyun unsurlarını entegre ederek, öğrencilerin içsel motivasyonlarını harekete geçirmeyi amaçlar (Werbach & Hunter, 2012). Yapay öğrenci modeli, bu unsurların hangi öğrenci profili için daha etkili olduğunu analiz ederek, dinamik ve kişiselleştirilmiş oyunlaştırma stratejileri geliştirebilir (González-Fernández, Revuelta-Domínguez & Fernández-Sánchez, 2022).

Örneğin, bir öğrenci tarih dersinde düşük performans gösterdiğinde, sistem bu öğrenciye özel olarak tasarlanmış bir macera senaryosu sunabilir. Bu senaryoda öğrenci, tarihsel olayları çözerek ilerlerken hem bilgi edinir hem de başarı hissi yaşar. Yapay öğrenci modeli, öğrencinin ilerleme verilerini analiz ederek zorluk seviyesini ayarlayabilir ve anlık geri bildirim sağlayabilir (Çöpgeven et al., 2023).

Bu tür sistemlerin geliştirilmesinde makine öğrenmesi, doğal dil işleme ve öneri sistemleri gibi yapay zekâ teknikleri kullanılmaktadır. Ayrıca, etik veri kullanımı, öğrenci gizliliği ve şeffaf algoritmalar gibi konular da bu sistemlerin güvenilirliği açısından kritik öneme sahiptir (Popenici & Kerr, 2017).

Sonuç olarak, oyunlaştırılmış senaryolarla desteklenen yapay öğrenci modeli platformları, öğrenme sürecini bireyselleştirme, motivasyonu artırma ve öğrenme çıktılarında iyileşme sağlama açısından yenilikçi ve etkili bir çözüm sunmaktadır. Bu yaklaşım, özellikle açık ve uzaktan öğrenme ortamlarında öğrencilerin bağlılığını artırmak için güçlü bir araç olarak değerlendirilmektedir.

3. Devre Hatalarının Yapay Zekâ ile Tespiti

3.1 Hata Türleri

- Açık/kısa devre,
- Lehimleme sorunları,
- Yanlış bileşen/konum,
- Üretim kaynaklı PCB sorunları.

3.2 Yöntemler

- Görüntü İşleme + CNN: Iot sistemlerinde optik denetim,
- Zaman Serisi Analizi + LSTM: Güç devrelerinde ses/titreşim bazlı analiz,
- Simülasyon Verisi + ML: Sapma analizi ve arıza tahmini,

- Unsupervised Learning: Anomali tespiti,
- Takviye Öğrenmesi: FPGA test süreçleri.

3.3 Uygulama Platformları

3.3.1 NVIDIA Clara Inspect: Tıbbi Görüntüleme İçin Yapay Zekâ Destekli Bir Platform

NVIDIA Clara Inspect, NVIDIA tarafından geliştirilen ve özellikle tıbbi görüntüleme alanında yapay zekâ (YZ) uygulamalarını desteklemek amacıyla tasarlanmış bir platformdur. Bu platform, derin öğrenme modellerinin geliştirilmesi, eğitilmesi ve dağıtılması süreçlerini hızlandırmak için optimize edilmiş donanım ve yazılım bileşenlerinden oluşur (NVIDIA, 2025a).

Clara Inspect, **Clara Imaging** çatısı altında yer almakta olup, radyolojik görüntülerin otomatik analizi, segmentasyonu ve sınıflandırılması gibi görevlerde kullanılmak üzere önceden eğitilmiş modeller ve geliştirici araçları sunar. Bu sayede araştırmacılar, klinik karar destek sistemleri geliştirme sürecinde zaman ve kaynak tasarrufu sağlayabilirler (NVIDIA, 2025b).

Platformun temel bileşenleri arasında şunlar yer alır:

Clara Train: Derin öğrenme modellerinin eğitimi için özelleştirilebilir bir çerçeve.

Clara Deploy: Eğitilen modellerin klinik ortamlarda dağıtımı için bir orkestrasyon altyapısı.

MONAI (Medical Open Network for AI): Açık kaynaklı tıbbi görüntüleme projeleri için optimize edilmiş bir PyTorch çerçevesi ile entegrasyon (NVIDIA, 2025a).

Clara Inspect, aynı zamanda **federated learning** (dağıtık öğrenme) ve **differential privacy** (farklı gizlilik) gibi modern veri gizliliği yaklaşımlarını destekleyerek, hasta verilerinin güvenliğini ön planda tutar (NVIDIA, 2025b).

Bu platform, akademik araştırmalarda ve endüstriyel uygulamalarda tıbbi görüntüleme süreçlerinin otomasyonu ve doğruluğunun artırılması açısından önemli bir rol oynamaktadır.

3.3.2 Siemens Valor AOI (Automated Optical Inspection): Elektronik Üretimde Yapay Zekâ Destekli Otomatik Optik Denetim Platformu

Siemens Valor AOI, elektronik üretim süreçlerinde kalite kontrolünü optimize etmek amacıyla geliştirilen, yapay zekâ destekli bir otomatik optik denetim (AOI) çözümüdür. Siemens'in Valor Process Preparation yazılımı ile entegre çalışan bu platform, üretim hattındaki denetim cihazlarının programlanmasını otomatikleştirerek, hata oranlarını azaltmayı ve üretim verimliliğini artırmayı hedefler (Siemens, 2024a).

Yüksek karışımli üretim ortamlarında, farklı tasarım formatları ve veri kaynakları (örneğin Gerber, ODB++) ile çalışmak, AOI

sistemlerinin manuel programlanmasını karmaşık ve zaman alıcı hale getirmektedir. Siemens, bu sorunu çözmek için Valor Process Preparation yazılımını geliştirmiştir. Bu yazılım, tasarım verilerinden doğrudan denetim programları oluşturarak, fiziksel kartlara ihtiyaç duymadan denetim cihazlarının yapılandırılmasını mümkün kılar (Siemens, 2024b).

Platformun öne çıkan özellikleri şunlardır:

Tasarımdan üretime geçişin dijitalleştirilmesi: AOI/SPI cihazları için denetim programları doğrudan CAD verilerinden oluşturulur.

Yapay zekâ destekli öğrenme kütüphaneleri: Makine şekilleri, bileşen rotasyonları gibi parametreler otomatik olarak tanımlanır ve yeniden kullanılabilir hale getirilir.

Hata oranlarının azaltılması ve kalite artışı: Manuel programlama hataları minimize edilir, üretim kalitesi artırılır (Siemens, 2024a).

Ayrıca, Siemens'in bu platformu, Yeni Ürün Giriş (NPI) süreçlerini hızlandırmakta ve üretim mühendislerinin iş yükünü azaltmaktadır. Yapay zekâ destekli otomasyon sayesinde, denetim sistemlerinin kurulumu daha kısa sürede ve daha az kaynakla gerçekleştirilebilmektedir (Siemens, 2024b).

3.3.3 DeepPCB: Baskılı Devre Kartı Tasarımında Yapay Zekâ Destekli Otomasyon Platformu

DeepPCB, InstaDeep tarafından geliştirilen ve baskılı devre kartı (PCB) tasarım süreçlerini otomatikleştirmek amacıyla tasarlanmış, yapay zekâ destekli bir açık kaynak platformudur. Platform, özellikle karmaşık yönlendirme (routing) problemlerini çözmek için pekiştirmeli öğrenme (reinforcement learning) algoritmalarını kullanır ve geleneksel otomatik yönlendiricilerin sınırlamalarını aşmayı hedefler (InstaDeep, 2025a).

DeepPCB, klasik yönlendirme algoritmalarının karşılaştığı **NP-zor** optimizasyon problemlerine karşı, geçmiş deneyimlerden öğrenme yeteneği sayesinde daha verimli çözümler sunar. Platform, kullanıcıların kendi PCB tasarımlarını yükleyerek, bileşen yerleşimi ve yönlendirme işlemlerini tamamen otomatikleştirmelerine olanak tanır (InstaDeep, 2025b).

Platformun Temel Özellikleri

Tam Otomatik Yönlendirme: DeepPCB, iki katmanlı PCB’lerde 150’ye kadar bağlantı çiftini otomatik olarak yönlendirebilir ve KiCad ile tam uyumludur (InstaDeep, 2025b).

Bulut Tabanlı Mimari: Google Cloud Platform üzerinde çalışan DeepPCB, yüksek ölçeklenebilirlik ve düşük gecikme süresi sunar.

Eğitim süreçlerinde **Cloud TPU** altyapısı kullanılarak %90'a varan maliyet tasarrufu sağlanmıştır (Google Cloud, 2023).

Açık Kaynak ve API Entegrasyonu: Platform, mevcut tasarım araçlarıyla kolayca entegre edilebilecek şekilde API desteği sunar ve geliştiricilere esnek bir çalışma ortamı sağlar (InstaDeep, 2025a).

DeepPCB, yalnızca mühendislik süreçlerini hızlandırmakla kalmaz, aynı zamanda donanım geliştirme döngüsünü kısaltarak yeni nesil ürünlerin pazara daha hızlı sunulmasına katkı sağlar. Bu yönüyle, yapay zekânın elektronik tasarım otomasyonu (EDA) alanındaki dönüştürücü etkisinin somut bir örneğidir.

3.3.4 Keysight PathWave AI: Elektronik Tasarım ve Test Süreçlerinde Yapay Zekâ Destekli Otomasyon Platformu

Keysight PathWave AI, elektronik tasarım otomasyonu (EDA) ve test süreçlerinde yapay zekâ tabanlı analiz, modelleme ve otomasyon yetenekleri sunan entegre bir yazılım platformudur. Keysight Technologies tarafından geliştirilen bu platform, özellikle yüksek frekanslı devreler, RF sistemleri ve güç elektroniği gibi karmaşık mühendislik alanlarında tasarım doğruluğunu artırmak ve ürün geliştirme süresini kısaltmak amacıyla kullanılmaktadır (Keysight, 2024a).

PathWave AI, geleneksel mühendislik yaklaşımlarının ötesine geçerek, **veri odaklı karar destek sistemleri** ve **öngörücü analiz**

yetenekleriyle tasarım döngüsünü dijitalleştirir. Platform, kullanıcıların test verilerini gerçek zamanlı olarak analiz etmelerine, anormallikleri tespit etmelerine ve üretim süreçlerini optimize etmelerine olanak tanır (Keysight, 2024b).

Temel Özellikler

PathWave System Design (SystemVue): RF sistemleri için çok alanlı modelleme ve simülasyon ortamı sunar. MATLAB®, STK ve HFSS gibi araçlarla entegrasyon sağlar (Keysight, 2024c).

PathWave Test Automation: Açık kaynaklı OpenTAP motoru üzerine kurulu test otomasyon altyapısı ile test planlarının hızlı geliştirilmesini ve tekrarlanabilirliğini sağlar (Keysight, 2024d).

Yapay Zekâ Destekli Analiz: Test verilerinden öğrenerek, hata örüntülerini tanımlayan ve gelecekteki arızaları öngören algoritmalar içerir.

Bulut Tabanlı Mimari: PathWave, bulut destekli veri işleme ve uzaktan erişim özellikleriyle ölçeklenebilirlik sunar.

PathWave AI, özellikle **dijital ikiz (digital twin)** teknolojileriyle birlikte kullanıldığında, fiziksel prototipleme ihtiyacını azaltarak mühendislik ekiplerinin daha hızlı ve düşük maliyetli ürün geliştirmesine olanak tanır. Bu yönüyle, savunma sanayi, otomotiv ve haberleşme gibi yüksek doğruluk gerektiren sektörlerde yaygın olarak benimsenmektedir (Keysight, 2024a).

4. Yapay Zekâ Eğitimi ve Elektronik Entegrasyonu

4.1 Eğitim Boyutu

- AI temelleri: ML, DL, RL, NLP,
- Donanım-yazılım entegrasyonu: Python, TensorFlow, MATLAB,
- Simülasyon destekli uygulamalı öğrenme: Tinkercad, Simulink.

4.2 Elektronik Sistemlerde AI Kullanımı

- Gömülü AI: Mikrodenetleyiciler ve FPGA’larda model çalıştırma,
- Sensör Füzyonu: Veri birleştirme ve anlamlandırma,
- Devre Otomasyonu: Otomatik yerleşim, yönlendirme ve hata önleme,
- Haberleşme Sistemleri: Kanal ve trafik optimizasyonu.

4.3 Araçlar

4.3.1 TensorFlow Lite: Gömülü Sistemler İçin Hafif Yapay Zekâ Platformu

TensorFlow Lite (TFLite), Google tarafından geliştirilen açık kaynaklı bir makine öğrenimi çerçevesi olup, mobil cihazlar ve gömülü sistemler gibi kaynak kısıtlı ortamlarda çalışmak üzere optimize edilmiştir. Bu platform, düşük gecikmeli çıkarım (inference), küçük

model boyutu ve donanım hızlandırma desteği gibi özellikleriyle, yapay zekâ uygulamalarının uç cihazlarda çalıştırılmasını mümkün kılar (TensorFlow, 2024a).

TFLite, geleneksel TensorFlow modellerinin daha küçük ve verimli bir biçime dönüştürülmesini sağlayan bir **model dönüştürücü** içerir. Bu dönüştürme işlemi sonucunda elde edilen .tflite uzantılı modeller, Android, iOS, Raspberry Pi ve mikrodenetleyiciler gibi çeşitli platformlarda çalıştırılabilir (TensorFlow, 2024b).

Temel Özellikler

Donanım Hızlandırma: GPU, DSP ve NPU gibi özel donanımlar üzerinden çıkarım sürecini hızlandırmak için NNAPI, Core ML ve GPU Delegate gibi ara yüzleri destekler.

Küçük Model Boyutu: Model sıkıştırma ve **nicemleme (quantization)** teknikleri sayesinde bellek kullanımı ve enerji tüketimi azaltılır.

Çoklu Dil Desteği: Python, C++, Java, Swift gibi dillerde SDK'lar sunarak geliştiricilere esneklik sağlar.

Gizlilik ve Bağımsızlık: Verilerin cihazda işlenmesi sayesinde kullanıcı gizliliği korunur ve internet bağlantısına ihtiyaç duyulmaz (Google AI, 2024).

TFLite, özellikle **nesne tanıma**, **sesli komut algılama**, **metin sınıflandırma** ve **anomalilik tespiti** gibi görevlerde yaygın olarak kullanılmaktadır. Ayrıca, **MediaPipe** ve **LiteRT** gibi Google AI Edge çözümleriyle entegre çalışarak, geliştiricilere uçtan uca bir yapay zekâ geliştirme ortamı sunar (Google AI, 2024).

4.3.2 Python ile Donanım ve Yazılım Entegrasyonu: Gömülü Sistemlerde Otomasyonun Yeni Paradigması

Python, yüksek seviyeli, dinamik ve çok amaçlı bir programlama dili olup, geleneksel olarak yazılım geliştirme alanında yaygın şekilde kullanılmakla birlikte, son yıllarda donanım-yazılım entegrasyonu ve gömülü sistemler alanında da önemli bir rol üstlenmeye başlamıştır. Python'un bu alandaki başarısı, geniş kütüphane ekosistemi, platformlar arası taşınabilirliği ve diğer dillerle (örneğin C/C++) kolay entegrasyon yeteneğinden kaynaklanmaktadır (Annapareddy, 2023).

Python, donanım ile etkileşim kurmak için çeşitli ara yüzler ve kütüphaneler sunar. Örneğin, PySerial, RPi.GPIO, Adafruit CircuitPython, MicroPython ve pyFirmata gibi kütüphaneler, mikrodenetleyiciler, sensörler ve aktüatörlerle doğrudan iletişim kurulmasına olanak tanır. Bu sayede Python, otomasyon, test sistemleri, prototipleme ve donanım doğrulama gibi mühendislik süreçlerinde yaygın olarak kullanılmaktadır (Kerr, 2024).

Temel Uygulama Alanları

Gömülü Sistem Geliştirme: Python, firmware yükleme, hata ayıklama ve test otomasyonu gibi görevlerde kullanılarak geliştirme sürecini hızlandırır (Annapareddy, 2023).

Donanım Tanımlama ve Simülasyon: PyHGL gibi Python tabanlı donanım tanımlama dilleri, yeniden kullanılabilir modüllerle donanım üretimini kolaylaştırır (Sun et al., 2023).

Donanım Prototipleme: Raspberry Pi ve Arduino gibi platformlarla Python kullanılarak hızlı prototipleme yapılabilir.

Veri Toplama ve Görselleştirme: Python'un veri analizi kütüphaneleri (NumPy, Pandas, Matplotlib) ile donanımdan gelen veriler işlenebilir ve görselleştirilebilir.

Python'un donanım entegrasyonundaki başarısı, yalnızca teknik kolaylıklarla sınırlı değildir; aynı zamanda açık kaynak topluluğunun desteğiyle sürekli gelişen bir ekosistem sunar. Bu yönüyle Python, hem akademik araştırmalarda hem de endüstriyel uygulamalarda donanım-yazılım bütünleşik sistemlerinin geliştirilmesinde stratejik bir araç haline gelmiştir.

4.3.3 Jupyter: Donanım ve Yazılım Entegrasyonu İçin Etkileşimli Hesaplama Platformu

Jupyter, bilimsel hesaplama, veri analizi ve makine öğrenimi gibi alanlarda yaygın olarak kullanılan, açık kaynaklı ve etkileşimli bir hesaplama platformudur. Başlangıçta IPython projesinden türeyen

Jupyter, çok sayıda programlama dilini desteklemesi ve kod, metin, görselleştirme ve çıktıların aynı belgede birleştirilebilmesi sayesinde, donanım ve yazılım entegrasyonu süreçlerinde önemli bir rol oynamaktadır (Kluyver et al., 2016).

Jupyter platformu, özellikle **gömülü sistemler**, **robotik**, **(Internet of Things) IoT** ve **yüksek performanslı hesaplama (HPC)** gibi alanlarda, donanım bileşenlerinin yazılım ile etkileşimli olarak test edilmesi, izlenmesi ve kontrol edilmesi için kullanılmaktadır. Bu bağlamda, **Jupyter Notebook** ve **JupyterLab**, kullanıcıların donanım sürücülerini, sensör verilerini ve kontrol algoritmalarını gerçek zamanlı olarak analiz etmelerine olanak tanır (Stubbs et al., 2020).

Temel Özellikler

Çoklu Dil Desteği: Python, R, Julia gibi 40'tan fazla dili destekleyerek farklı donanım platformlarıyla entegrasyonu kolaylaştırır (Project Jupyter, 2024).

Donanım Tabanlı Uygulamalar: Raspberry Pi, Arduino ve FPGA gibi platformlarla birlikte kullanılarak, sensör verilerinin toplanması ve işlenmesi için etkileşimli bir ortam sunar.

JupyterHub ve Bulut Entegrasyonu: JupyterHub, çok kullanıcıli sistemlerde donanım kaynaklarının paylaşılmasını ve merkezi yönetimini sağlar. Bu yapı, araştırma altyapılarında donanım kümeleriyle entegrasyonu mümkün kılar (Stubbs et al., 2020).

Yeniden Üretilirlik ve Açıklanabilirlik: Kod, veri ve sonuçların aynı belgede yer alması, deneylerin yeniden üretilirliğini ve açıklanabilirliğini artırır (Kluyver et al., 2016).

Jupyter, ayrıca **Docker**, **Kubernetes** ve **GPU hızlandırma altyapıları** ile entegre edilerek, yapay zekâ modellerinin eğitimi ve test edilmesi gibi yüksek işlem gücü gerektiren görevlerde de kullanılmaktadır (Kumar et al., 2023). Bu yönüyle Jupyter, yalnızca yazılım geliştirme değil, aynı zamanda donanım test ve doğrulama süreçlerinde de stratejik bir araç haline gelmiştir.

4.3.4 PyTorch: Dinamik Hesaplama Grafikleriyle Derin Öğrenme Araştırmalarında Esnek Bir Platform

PyTorch, Facebook AI Research (FAIR) tarafından geliştirilen açık kaynaklı bir derin öğrenme kütüphanesidir. Platform, özellikle araştırma ve prototipleme süreçlerinde esneklik ve hız sağlamak amacıyla tasarlanmıştır. PyTorch'un en ayırt edici özelliği, **dinamik hesaplama grafikleri (define-by-run)** yaklaşımını benimsemesidir. Bu sayede kullanıcılar, model mimarilerini çalışma zamanında tanımlayabilir ve değiştirebilirler (Paszke et al., 2019).

PyTorch, Python diliyle derin entegrasyona sahiptir ve NumPy gibi bilimsel hesaplama kütüphaneleriyle uyumlu çalışır. Bu özellik, araştırmacıların ve geliştiricilerin karmaşık modelleri daha sezgisel bir şekilde oluşturmaya olanak tanır (PyTorch, 2025a). Ayrıca, GPU hızlandırması, otomatik türev hesaplama (autograd), modüler sinir ağı

bileşenleri (torch.nn) ve geniş bir ekosistem (örneğin TorchVision, TorchText) gibi güçlü araçlar sunar.

Temel Özellikler

Dinamik Hesaplama Grafikleri: Model yapısı çalışma zamanında oluşturulur, bu da esnekliği artırır.

Autograd Modülü: Geri yayılım algoritması için otomatik türev hesaplaması sağlar.

TorchScript: Araştırma ortamında geliştirilen modellerin üretime aktarılmasını kolaylaştırır.

TorchServe: Modellerin REST API üzerinden dağıtımını ve versiyonlamasını destekler.

Dağıtık Eğitim: torch.distributed modülü ile büyük ölçekli modellerin paralel eğitimi mümkündür (PyTorch, 2025b).

PyTorch, günümüzde **doğal dil işleme, bilgisayarla görme, pekiştirmeli öğrenme ve üretici yapay zekâ** gibi birçok alanda hem akademik hem de endüstriyel uygulamalarda yaygın olarak kullanılmaktadır. Ayrıca, AWS, Google Cloud ve Microsoft Azure gibi bulut platformlarıyla entegre çalışarak ölçeklenebilir yapay zeka çözümleri geliştirilmesine olanak tanır (PyTorch, 2025a).

4.3.5 Tinkercad Circuits: Etkileşimli Elektronik Tasarım ve Simülasyon Platformu

Tinkercad Circuits, Autodesk tarafından geliştirilen ve elektronik devre tasarımı, simülasyonu ve kodlama süreçlerini destekleyen bulut tabanlı bir platformdur. Özellikle (Science Technology Engineering Mathematics) STEM eğitimi, prototipleme ve uzaktan öğrenme ortamlarında yaygın olarak kullanılan bu platform, kullanıcıların Arduino, breadboard, sensörler ve diğer elektronik bileşenlerle etkileşimli devreler oluşturmaya olanak tanır (Autodesk, 2025a).

Tinkercad Circuits, yapay zekâ destekli otomasyon özellikleri içermese de, **algoritmik düşünme**, **gömülü sistem programlama** ve **donanım-yazılım entegrasyonu** gibi becerilerin geliştirilmesine katkı sağlayarak, yapay zekâ sistemlerinin temel bileşenlerinin eğitimi için bir altyapı sunar. Platform, özellikle **blok tabanlı ve metin tabanlı kodlama** seçenekleriyle, farklı yaş ve yetkinlik düzeyindeki kullanıcıların elektronik sistemleri deneyimlemesine olanak tanır (Tüysüz et al., 2024).

Temel Özellikler

Gerçek Zamanlı Simülasyon: Arduino tabanlı devrelerin davranışı, kod yüklemeyen önce simüle edilerek test edilebilir.

Kodlama Desteği: Blok tabanlı (Blockly) ve metin tabanlı (C/C++) kodlama seçenekleri sunar.

Donanım Entegrasyonu: Breadboard, direnç, LED, sensör gibi bileşenlerle fiziksel sistemlerin dijital prototipleri oluşturulabilir.

Eğitim Odaklı Tasarım: Öğrencilerin problem çözme, tasarım düşüncesi ve mühendislik becerilerini geliştirmeye yönelik yapılandırılmış içerikler sunar (Autodesk, 2025b).

Tinkercad Circuits, özellikle pandemi döneminde uzaktan eğitim süreçlerinde **üstün yetenekli öğrenciler** için etkili bir öğrenme ortamı olarak değerlendirilmiştir. Yapılan çalışmalar, platformun öğrencilerin bilimsel yazma, problem çözme ve tasarım becerilerini geliştirdiğini göstermektedir (Tüysüz et al., 2024).

4.3.6 MATLAB: Yapay Zekâ Uygulamaları İçin Entegre Bir Hesaplama Platformu

MATLAB (Matrix Laboratory), MathWorks tarafından geliştirilen ve mühendislik, bilimsel hesaplama ile veri analitiği alanlarında yaygın olarak kullanılan yüksek seviyeli bir programlama ve hesaplama ortamıdır. Son yıllarda, MATLAB'ın yapay zekâ (YZ) yetenekleri, özellikle **makine öğrenmesi**, **derin öğrenme**, **doğal dil işleme** ve **pekiştirmeli öğrenme** gibi alanlarda önemli ölçüde genişletilmiştir (The MathWorks Inc., 2024a).

MATLAB'ın YZ yetenekleri, kullanıcıların veri hazırlama, model geliştirme, eğitim, değerlendirme ve dağıtım süreçlerini tek bir platformda gerçekleştirmesine olanak tanır. Bu süreçler, **Deep Learning Toolbox**, **Statistics and Machine Learning Toolbox** ve

Reinforcement Learning Toolbox gibi özel araç kutuları aracılığıyla desteklenmektedir (The MathWorks Inc., 2024b).

Temel Özellikler

Uçtan Uca Yapay Zekâ İş Akışı: MATLAB, veri hazırlama, modelleme, görselleştirme ve dağıtım süreçlerini entegre bir şekilde sunar (Academic Block, 2024).

Model Görselleştirme ve Açıklanabilirlik: Eğitim süreci, karar sınırları ve model çıktıları grafiksel olarak analiz edilebilir.

Donanım Hızlandırma: GPU ve FPGA gibi donanımlar üzerinden model eğitimi ve çıkarımı desteklenir.

Kod Üretimi ve Dağıtım: MATLAB modelleri, C/C++ veya CUDA koduna dönüştürülerek gömülü sistemlerde kullanılabilir (The MathWorks Inc., 2024c).

MATLAB, ayrıca **Simulink** ile birlikte kullanıldığında, fiziksel sistemlerin dijital ikizlerinin oluşturulmasına ve kontrol algoritmalarının YZ ile optimize edilmesine olanak tanır. Bu yönüyle MATLAB, savunma, otomotiv, biyomedikal ve enerji gibi yüksek doğruluk gerektiren sektörlerde yaygın olarak tercih edilmektedir (The MathWorks Inc., 2024a).

5. Sonuç ve Öneriler

5.1 Sonuç

Yapay zekâ, elektronik mühendisliğinin her aşamasına dokunarak süreci daha hızlı, doğru ve verimli hale getirmektedir. Devre tasarımından hata tespitine, eğitim simülasyonlarından üretim otomasyonuna kadar geniş bir yelpazede uygulama alanı bulmakta; hem insan hatalarını azaltmakta hem de mühendislik yeteneklerini artırmaktadır.

Gelişmiş yapay zekâ algoritmaları, artık sadece analiz değil, aynı zamanda öneri ve karar destek sistemleri olarak da mühendislerin yanında yer almaktadır. Eğitim tarafında ise, kişiselleştirilmiş öğrenme ve geri bildirim mekanizmaları, klasik mühendislik eğitiminin ötesinde bir etkileşim sunmaktadır.

5.2 Öneriler

- 1. Disiplinlerarası Eğitim Programları Oluşturulmalı:**
Elektronik mühendisliği öğrencilerine yapay zekâ temelleri öğretilmeli; proje tabanlı uygulamalarla pekiştirilmelidir.
- 2. AI Destekli Simülasyon Laboratuvarları Yaygınlaştırılmalı:**
Özellikle altyapısı yetersiz okullarda, AI destekli sanal simülasyon ortamları büyük fırsat sunmaktadır.
- 3. Açık Kaynak AI Devre Kütüphaneleri Teşvik Edilmeli:**
Topluluk katkısıyla gelişen AI modelleri, tasarım süreçlerini demokratikleştirebilir.

4. **Endüstri-Akademi İşbirliği Artırılmalı:** Yapay zekâ ile donatılmış Elektronik Tasarım Otomasyonu (EDA) araçlarının geliştirilmesi için üniversiteler ve firmalar birlikte çalışmalıdır.
5. **Donanım Desteği ve Edge AI Yatırımları Teşvik Edilmeli:** Yapay zekânın gömülü sistemlerde daha verimli kullanılabilmesi için düşük güç tüketimli AI donanımları yaygınlaştırılmalıdır.

KAYNAKÇA

- Academic Block. (2024). Artificial intelligence (AI) using MATLAB.
<https://www.academicblock.net/matlab-tutorial/artificial-intelligence-ai-using-matlab>
- AMD. (2024a). Vitis AI Software.
<https://www.amd.com/en/products/software/vitis-ai.html>
- AMD. (2024b). Experience Faster AI Acceleration with Vitis AI 2.5.
<https://community.amd.com/t5/ai/experience-faster-ai-acceleration-with-vitis-ai-2-5/ba-p/561691>
- Annapareddy, S. R. (2023). Using Python for automation in embedded systems development. *ESP International Journal of Advancements in Computational Technology*, 1(3), 131–134.
<https://www.espjournals.org/IJACT/2023/Volume1-Issue3/IJACT-V1I3P114.pdf>
- AskSia. (2025a). *Free Online Tinkercad Helper*.
<https://www.asksia.ai/tool/tinkercad-helper/>
- AskSia. (2025b). Free Online Tinkercad & Circuit Helper.
<https://www.asksia.ai/tool/tinkercad-helper/>
- Autodesk. (2023). *Tinkercad*. <https://www.tinkercad.com/>
- Autodesk. (2025a). Tinkercad Circuits overview.
<https://www.tinkercad.com/circuits>
- Autodesk. (2025b). Official guide to Tinkercad Circuits.
<https://www.tinkercad.com/blog/official-guide-to-tinkercad-circuits>
- Avestimehr Research Group. (2024). AI-Circuit: A Multi-Level Dataset and Benchmark for AI-Driven Analog Integrated Circuit

Design.

GitHub.

<https://github.com/AvestimehrResearchGroup/AICircuit>

Avestimehr Research Group. (2024). SIM_GUIDE.md: Simulation and evaluation guide for AI-Circuit [Documentation]. GitHub. https://github.com/AvestimehrResearchGroup/AICircuit/blob/main/SIM_GUIDE.md

Aydın, M., & İnce, T. (2022). Artificial Intelligence Enhanced Engineering Education: A Simulation-Based Framework. *Journal of Engineering Education Research*, 15(2), 85–102.

Barata, G., Gama, S., Jorge, J., & Gonçalves, D. (2015). Gamification for smarter learning: Tales from the trenches. *Smart Learning Environments*, 2(1), 1–23. <https://doi.org/10.1186/s40561-015-0017-8>

Cadence. (2025a, 11 Haziran). Transforming chip design with Cadence Cerebrus AI Studio. Cadence Community. https://community.cadence.com/cadence_blogs_8/b/di/posts/transforming-chip-design-with-cadence-cerebrus-ai-studio

Cadence. (2025b). Cadence Cerebrus AI Studio Digital Design and Signoff. https://www.cadence.com/en_US/home/tools/digital-design-and-signoff/soc-implementation-and-floorplanning/cadence-cerebrus-ai-studio.html

Cadence Design Systems. (2022). Cadence Cerebrus Intelligent Chip https://www.cadence.com/en_US/home/tools/digital-design-and-signoff/soc-implementation-and-floorplanning/cerebrus-intelligent-chip-explorer.html

- Chen, Z., Zhang, X., Lin, Y., & Li, D. (2021). DeepPCB: A Deep Learning Dataset for PCB Defect Detection. *IEEE Access*, 9, 30355–30363. <https://doi.org/10.1109/ACCESS.2021.3060103>
- Çöpgeven, N. S., Özkaya, H., & Aydın, S. (2023). Açık ve uzaktan öğrenmede yapay zeka destekli oyunlaştırma. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 9(1), 386–407. <https://doi.org/10.51948/auad.1203700>
- Digital Engineering 24/7. (2025, 8 Mayıs). Introducing Cadence Cerebrus AI Studio. <https://www.digitalengineering247.com/article/introducing-cadence-cerebrus-ai-studio>
- eeNews Europe. (2019, Aralık 4). Xilinx Vitis AI inference platform ready for free download. <https://www.eenewseurope.com/en/xilinx-vitis-ai-inference-platform-ready-for-free-download/>
- Falstad. (2023). Circuit Simulator Applet. <https://www.falstad.com/circuit/>
- González-Fernández, A., Revuelta-Domínguez, F. I., & Fernández-Sánchez, M. R. (2022). Models of instructional design in gamification: A systematic review of the literature. *Education Sciences*, 12(1), 44. <https://doi.org/10.3390/educsci12010044>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Google AI. (2024). LiteRT overview Google AI Edge. <https://ai.google.dev/edge/litert>

- Google Cloud. (2023, October 20). InstaDeep's scalable reinforcement learning on Cloud TPUs. <https://cloud.google.com/blog/products/compute/instadeep-performs-reinforcement-learning-on-cloud-tpus/>
- InstaDeep. (2025a). DeepPCB: Pure AI-powered, cloud-native PCB routing. <https://deeppcb.ai/>
- InstaDeep. (2025b, Mar 25). Bringing AI and cloud to PCB routing. <https://deeppcb.ai/2025/03/25/bringing-ai-and-cloud-to-pcb-routing/>
- Kerr, A. (2024). How to use Python to program hardware. The Python Code. <https://thepythoncode.com/article/use-python-to-program-hardware>
- Keysight. (2024a). PathWave Design 2024: Transforming the design lifecycle with AI. <https://ai-techpark.com/keysight-introduces-pathwave-design-2024/>
- Keysight. (2024b). PathWave BenchVue software overview. <https://www.keysight.com/us/en/products/software/pathwave-test-software/benchvue-software.html>
- Keysight. (2024c). PathWave System Design (SystemVue) technical overview [PDF]. <https://www.keysight.com/us/en/assets/3121-1074/technical-overviews/PathWave-System-Design.pdf>
- Keysight. (2024d). PathWave Test Automation software platform. <https://www.keysight.com/in/en/products/software/pathwave-test-software/pathwave-test-automation-software.html>
- Keysight Technologies. (2023). *PathWave Design Software with AI Capabilities*. <https://www.keysight.com>

- Khakpour, A., & Colomo-Palacios, R. (2021). Convergence of gamification and machine learning: A systematic literature review. *Technology, Knowledge and Learning*, 26(3), 597–636. <https://doi.org/10.1007/s10758-020-09461-9>
- Khan, R., & Singh, A. (2019). Energy-Aware AI Techniques in Electronic Circuit Design. *IEEE Transactions on Sustainable Computing*, 4(3), 201–210.
- Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B., Bussonnier, M., Frederic, J., ... & Willing, C. (2016). Jupyter Notebooks – a publishing format for reproducible computational workflows. In F. Loizides & B. Schmidt (Eds.), *Positioning and Power in Academic Publishing: Players, Agents and Agendas* (pp. 87–90). IOS Press.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, 60(6), 84–90. <https://dl.acm.org/doi/10.1145/3065386>
- Kumar, A., Cuccuru, G., Grüning, B., & Backofen, R. (2023). An accessible infrastructure for artificial intelligence using a Docker-based JupyterLab in Galaxy. *GigaScience*, 12, giad028. <https://doi.org/10.1093/gigascience/giad028>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Leite, J., Makarov, A., & Silva, F. (2020). Machine Learning Approaches for Analog Circuit Design Automation. *Microelectronics Journal*, 104, 104846.

- Li, X., Yu, H., & Wang, Y. (2020). AI for EDA: Challenges and Opportunities. *Proceedings of the Design Automation Conference (DAC)*. <https://doi.org/10.1145/3380747.3406262>
- MathWorks. (2022). *MATLAB and Simulink for AI and Deep Learning*. <https://www.mathworks.com>
- Mehradfar, A., Zhao, X, Niu, Y., Babakniya, S., Alesheikh, M., Aghasi, H. & Avestimehr, S. (2025). Supervised learning for analog and RF circuit design: Benchmarks and Comparative Insights. arXiv. <https://arxiv.org/abs/2501.11839>
- Mehradfar, A., Zhang, Y., & Avestimehr, A. (2024). AI-Circuit: A multi-layer dataset and benchmark for analog and RF circuit design. arXiv. <https://arxiv.org/abs/2407.18272>
- NVIDIA. (2025a). NVIDIA Clara: AI-powered solutions for healthcare. <https://www.nvidia.com/en-us/clara/>
- NVIDIA. (2025b). NVIDIA Clara documentation hub. <https://docs.nvidia.com/clara/index.html>
- OpenAI. (2023). *GPT Models for Technical Assistance in Education*. <https://openai.com>
- OpenAI. (2024). ChatGPT Technical Overview. <https://openai.com/chatgpt>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... & Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32. https://papers.nips.cc/paper_files/paper/2019/hash/bdbca288fee7f92f2bfa9f7012727740-Abstract.html

- Popenici, S. A. D., & Kerr, S. (2017). Exploring the impact of artificial intelligence on teaching and learning in higher education. *Research and Practice in Technology Enhanced Learning*, 12(1), 1–13. <https://doi.org/10.1186/s41039-017-0062-8>
- Project Jupyter. (2024). Project Jupyter Home. <https://jupyter.org/>
- PyTorch. (2025a). PyTorch – Open source deep learning platform. <https://pytorch.org/>
- PyTorch. (2025b). PyTorch documentation. <https://pytorch.org/docs/stable/index.html>
- Ricci, F., Rokach, L., & Shapira, B. (2022). *Recommender Systems Handbook* (3rd ed.). Springer.
- Shunlongwei. (2021, Aralık 1). Synopsys yapay zeka kullanımını genişletiyor. <https://www.shunlongwei.com/tr/synopsys-expands-use-of-ai/>
- Siemens. (2024a, Haziran 27). Enhancing automated optical inspection with Siemens' Valor Process Preparation. <https://blogs.sw.siemens.com/valor/2024/06/27/enhancing-automated-optical-inspection-with-siemens-valor-process-preparation/>
- Siemens. (2024b). Valor Process Preparation overview [PDF]. https://www.plm.automation.siemens.com/media/global/en/valor-process-preparation-overview_tcm27-68922.pdf
- Sun, J., Wang, Z., Lu, T., & Chen, W. (2023). PyHGL: A Python-based hardware generation language framework [arXiv preprint]. <https://arxiv.org/pdf/2309.04859>

- Stubbs, J., Looney, J., Poindexter, M., Chalhoub, E., Zynda, G. J., Ferlanti, E. S., ... & Dahan, M. (2020). Integrating Jupyter into research computing ecosystems: Challenges and successes in architecting JupyterHub for collaborative research computing ecosystems. *PEARC '20: Practice and Experience in Advanced Research Computing*, 91–98. <https://doi.org/10.1145/3311790.3396648>
- Synopsys. (2022). *DSO.ai: AI-Driven Design Space Optimization*. <https://www.synopsys.com>
- Synopsys. (2025a). DSO.ai: AI-Driven Design Applications. <https://www.synopsys.com/ai/ai-powered-eda/dso-ai.html>
- Synopsys. (2025b). Scaling Synopsys DSO.ai on the Microsoft Azure Cloud to deliver superior PPA results. SNUG Presentation.
- Tamindir. (2022, Kasım 10). *Tinkercad Nedir? Tinkercad Nasıl Kullanılır?* https://www.tamindir.com/blog/tinkercad-nedir-tinkercad-nasil-kullanilir_76868/
- Technopat. (2023, Şubat 12). Yapay Zeka, Çip Tasarım Süreçlerinde Daha Önemli Hale Geliyor. <https://www.technopat.net/2023/02/12/yapay-zeka-cip-tasarim-sureclerinde-daha-onemli-hale-geliyor/>
- TensorFlow. (2024a). TensorFlow Lite documentation. <https://www.tensorflow.org/lite>
- TensorFlow. (2024b). tensorflow/tensorflow/lite/README.md at master - GitHub. <https://github.com/tensorflow/tensorflow/blob/master/tensorflow/lite/README.md>

- The MathWorks Inc. (2024a). AI research with MATLAB and Simulink. <https://www.mathworks.com/academia/research/artificial-intelligence.html>
- The MathWorks Inc. (2024b). Deep Learning Toolbox documentation. <https://www.mathworks.com/help/deeplearning/>
- The MathWorks Inc. (2024c). MATLAB documentation. <https://www.mathworks.com/help/matlab/>
- Tinkercad. (2023). *Tinkercad Circuits*. Autodesk. <https://www.tinkercad.com/circuits>
- Tüysüz, C., Bodur, N. C., & Uğulu, İ. (2024). Tinkercad Circuits platform-based learning experiences of gifted students in the emergency distance education process. *Journal of Advanced Academics*, 35(2), 329–356. <https://doi.org/10.1177/1932202x241230589>
- Ultralytics. (2024). *Öneri Sistemi AI, ML*. <https://www.ultralytics.com/tr/glossary/recommendation-system>
- Unite.AI. (2025, Şubat 5). Maç Öneri Sistemleri için *Yüksek Hassasiyetli AI Simülasyon Platformları Oluşturma*. <https://www.unite.ai/tr/Maç-önerisi-sistemleri-için-yüksek-hassasiyetli-yapay-zeka-simülasyon-platformlar%C4%B1-olu%C5%9Fturma/>
- Wang, J., Yang, Z., & Shi, Y. (2019). A Review of Reinforcement Learning Methods for Electronics and Embedded Systems Design. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 38(7), 1226–1238. <https://doi.org/10.1109/TCAD.2018.2879039>

- Werbach, K., & Hunter, D. (2012). For the win: How game thinking can revolutionize your business. Wharton Digital Press.
- Xilinx. (2021). *Vitis AI Development Environment*.
<https://www.xilinx.com>
- Xilinx. (2023). Vitis AI GitHub Repository.
<https://github.com/Xilinx/Vitis-AI>
- Zhang, Y., Liu, H., & Chen, Y. (2021). Deep Neural Networks for Performance Prediction in Electronic System Design, *ACM Transactions on Design Automation of Electronic Systems*, 26(6), 1–23.
- Zhou, Y., Pan, Z., & Chen, C. (2021). Artificial Intelligence in PCB Inspection: A Review. *Journal of Intelligent Manufacturing*, 32(3), 735–750. <https://doi.org/10.1007/s10845-020-01562-9>

BÖLÜM 3

ORTAOKUL 8. SINIF ÖĞRENCİLERİNİN DENKLEMLER VE ÖZDEŞLİKLER KONUSUNDA YAPMIŞ OLDUKLARI HATALAR*

Dr. Osman BURAN

Prof. Dr. Abdullah KAPLAN

1. GİRİŞ

Matematik, evrensel bir dil olarak insan aklının en temel yapı taşlarını simgelemektedir. Doğal sayılarla başlayan aritmetik, zamanla değişken ve sembollerle zenginleşerek cebirsel düşünceyi mümkün kılar. Cebirsel ifadeler, yalnızca sembolik işlemler değil; aynı zamanda örnekten genellemeye, soyutlamaya ve ilişkiler arasında model kurmaya aracılık eden kavramsal bir köprüdür. Bu yönüyle cebir, matematiğin yalnızca bir alt alanı değil, problem çözme, analitik düşünme ve bilimsel muhakemenin merkezinde yer alan bir düşünme biçimidir (Kieran, 2007; Kaput vd., 2017).

Araştırmacılar cebiri “matematiğin dili” olarak tanımlamaktadır. Cebir, öğrencilerin farklı matematiksel kavramlar arasında bağlantı kurmasını sağladığı gibi, soyut düşünme, genelleme yapma ve sembolik ifadeleri anlamlandırma becerisini geliştirmekte ve ileri düzey matematiksel öğrenmeye geçişte kritik bir rol üstlenmektedir (Booth & Koedinger, 2012; Cai & Knuth, 2011). Bu bağlamda, cebirsel ifadeler ve özdeşlik

*Bu çalışma birinci yazarın “*Probleme dayalı öğretim metodunun birinci dereceden bir bilinmeyenli denklemler ve özdeşliklerin öğretiminde 8.sınıf öğrencilerinin akademik başarısına etkisi.*” adlı yüksek lisans tezinin bir bölümünden elde edilmiştir.

kavramları öğrencilerin hem işlemsel hem de kavramsal anlamda matematiksel akıl yürütmelerinde merkezi bir konuma sahiptir. Ancak özdeşlik ve denklem kavramları öğrenciler tarafından sürekli karıştırılmakta ve hatalar yapılmaktadır. Cantimer (2022), öğrencilerin özdeşlikleri sıklıkla denklemlerle aynı şekilde ele alma eğiliminde olduklarını ve özdeşlikleri çözmeye çalışırken denklem çözme stratejilerini uyguladıklarını belirtmektedir. Bu tür kavramsal karışıklık, yalnızca sembolik düzeyde yapılan hatalardan kaynaklanmamaktadır; aynı zamanda öğrencilerin özdeşlikler ile cebirsel ifadeler arasındaki ilişkiyi kavramadaki bilişsel eksikliklerini de yansıtmaktadır. Benzer şekilde, Booth ve Koedinger (2008), öğrencilerin cebirsel işlemler sırasında sıkça karşılaştıkları hataların, “kuralların bağlamdan kopuk biçimde uygulanmasından” kaynaklandığını vurgulamaktadır. Öğrenciler çoğunlukla cebirsel kuralları ezbere öğrenip mekanik biçimde uygularlar; bu durum, benzer terimleri toplama, bir sayı ile cebirsel ifadeyi çarpma ve temel özdeşliklerin eşitlerini bulma gibi işlemlerde anlam temelli hataların ortaya çıkmasına neden olmaktadır. Sonuç olarak, öğrenciler işlemleri yüzeysel bir biçimde yürütmekte ve kavramsal anlamı göz ardı etmektedirler.

Hiebert (1984), öğrencilerin matematiksel kavram ve becerileri, okulda öğretilen kural ve sembollerle ilişkilendirmekte zorlandıklarını belirtmektedir. Bu durum, sezgisel ve anlamlı problem çözme yaklaşımlarının etkisini azaltmaktadır. Matematiksel kavramlar ile kurallar ve semboller arasındaki bağlantıların öğrenciler tarafından kurulabilmesi, kavramsal öğrenmenin gerçekleşmesi açısından büyük

önem taşımaktadır. Bu bağlamda, Hiebert (1984), öğrencilerin matematiksel bilgisini iki boyutta ele almıştır: ilki yapılarla ilgili bilgi (semboller, bu sembollerle gerçekleştirilen işlemler ve algoritmaları kapsar) ve ikincisi ise anlamaya yönelik bilgi (matematiğin işleyişine dair düşünceler ve sezgileri içerir).

Kavram bilgisi, matematiksel kavramların kendilerini ve bu kavramlar arasındaki ilişkileri içermektedir. Matematikteki kavramların, insan zihninde kurulan soyut ilişkilerden oluşması, bireyin bu kavramları edinebilmesi için belirli bir zihinsel olgunluk düzeyine ulaşmasını gerektirir. Ancak okullarda, öğrencileri sınavlara hazırlama amacıyla yürütülen öğretim süreçlerinde kavramların oluşumuna yeterince önem verilmemekte; bu yaklaşım bazı aileler tarafından da talep edilip desteklenmektedir. Sonuç olarak, öğrencilerin zihninde gerekli ilişkiler gelişmeden yapılan öğretim, kavramların tam olarak kazanılamamasına yol açmakta; kavramlar arası ilişkiler kurulamaması ise sonraki öğrenmeleri zorlaştırmakta, hatta kimi durumlarda imkânsız hâle getirmektedir. İşlem bilgisi ise, matematikte kullanılan semboller, kurallar ve işlemlerden oluşan bilgi türü olarak tanımlanır (Baykul, 2009). İşlemsel bilgi, bir kavramın veya işlemin nedenini anlamaktan çok, onun nasıl uygulanacağını bilmeye dayanırken; kavramsal bilgi, bu kavramın anlamını ve altında yatan ilişkileri anlamaya odaklanmaktadır (Baki, 1996). Bu kavramsal bilgilerin öğrencilerde tam oluşmaması cebirsel ifadelerle ilgili olarak öğrencilerin farklı hatalar yapmasına neden olmaktadır.

.Birgin ve Demirören (2020) tarafından yapılan araştırmada, ortaokul öğrencilerinin cebirsel ifadeler konusundaki başarı düzeylerinin düşük olduğu ve özellikle “cebirsel ifadelerin anlamını açıklama” alt boyutunda kavramsal eksiklikler gösterdikleri belirtilmiştir. Araştırmada öğrencilerin parantez kullanımını ihmal ettikleri, terimleri yanlış birleştirdikleri ve özdeşlikleri belirlemede zorlandıkları gözlemlenmiştir. Bu durum, öğrencilerin cebirsel yapıların altında yatan genellemeleri fark edemediğini göstermektedir. Benzer şekilde, Aktaş ve Çinkılıç (2025) matematik eğitiminde kavram yanlışlarının özellikle cebirsel kavramlarda yoğunlaştığını ve bu yanlışların öğretim süreçlerinde yeterince dikkate alınmadığını belirtmiştir. Uluslararası alanda yapılan araştırmalar da benzer bulgular ortaya koymaktadır. O'Shea vd. (2017), öğrencilerin cebirde en sık karşılaştıkları kavram yanlışlarının yanlış genelleme, dağılma kuralının eksik uygulanması ve özdeşlik–denklem ayrımının ihmal edilmesi olduğunu belirtmiştir. Ayrıca; Stamele ve Jina-Asvat (2024), 9. sınıf öğrencilerinin cebirsel ifadelerde yaptıkları hata örüntülerini analiz etmiş ve bu hataların büyük çoğunluğunun “anlam eksikliğinden” değil, “aşırı işlem odaklı” öğretim yaklaşımlarından kaynaklandığını göstermiştir. Bu durum, cebir öğretiminde yalnızca işlemsel bilgiye değil, kavramsal anlayışa da odaklanılması gerektiğini göstermektedir. Cantimer (2022), 8. sınıf öğrencilerinin özdeşlik, denklem ve cebirsel ifade kavramlarına yönelik kavram imajlarını incelediği çalışmasında, öğrencilerin çoğunun özdeşliği “denklemlerle aynı” olarak algıladığını belirtmiştir. Bu bulgu, öğrencilerin sembolik temsillerle sözel anlamlar arasında kurdukları bağın zayıf olduğunu

ortaya koymaktadır. Sonuç olarak, özdeşlikler ve cebirsel ifadeler konusundaki hatalar yalnızca yanlış işlem uygulamalarının değil, aynı zamanda kavramların zihinsel temsillerindeki eksikliklerin ürünüdür. Bu nedenle, öğretim süreçlerinde öğrencilerin özdeşlik kavramını yapılandırmalarına fırsat veren, hata analizine dayalı, anlam temelli yaklaşımlara ihtiyaç vardır. Böylece öğrenciler, cebirsel ifadeleri yalnızca manipülatif araçlar olarak değil, matematiksel ilişkilerin temsilcileri olarak görebileceklerdir. Bu çalışmanın giriş bölümünde tartışıldığı üzere, özdeşlikler ve cebirsel ifadeler konusundaki hataların belirlenmesi ve bu hataların bilişsel kökenlerinin anlaşılması, matematik öğretiminde daha etkili öğrenme ortamları tasarlamak açısından kritik öneme sahiptir.

Öğrenme süreçleri açısından bakıldığında ise cebirsel düşüncenin gelişimi, öğrencilerin aritmetikten cebire geçişini desteklemektedir. Yapılan araştırmalar, öğrencilerin soyutlama düzeylerinin yaşla birlikte arttığını ve bu sürecin öğretim yaklaşımlarıyla doğrudan ilişkili olduğunu göstermektedir (Knuth vd., 2006; Blanton ve Kaput, 2011). Bu nedenle öğretmenlerin cebirsel kavramlarını yapılandırma biçimleri, öğrencilerin kavramsal anlayışı üzerinde belirleyici bir rol oynamaktadır.

1.1.Özdeşlik ve Denklem

Özdeşlik ve denklem kavramları, cebir öğreniminin temelini oluşturan ve öğrencilerin matematiksel düşünme becerilerinin gelişiminde kritik öneme sahip iki yapıdır. Özdeşlik, değişkenlere verilen tüm değerler için doğru olan eşitliklerdir; diğer bir ifadeyle, eşitliğin her iki tarafı da

aynı matematiksel ifadeyi temsil eder. En az bir bilinmeyen içeren ve bu bilinmeyenin her değeri için doğru olan, yani çözüm kümesi tüm reel sayılardan oluşan açık önermeler özdeşlik olarak adlandırılır (Cinkol, 2010). Buna karşılık denklem, “içinde değişken bulunan bir cebirsel eşitliktir, denklemde değişken bilinmeyen anlamında kullanılmıştır” (Baykul, 2009, s. 313). “Denklem, bilinmeyen içeren bir eşitliktir. Böyle bir eşitlik değişkenlerin alabileceği değerler için sağlanabilir veya sağlanamaz. Eğer bir eşitlik içerdiği değişkenlerin her değeri için sağlanıyorsa bu eşitliğe özdeşlik, bir kısmı için sağlanıyor veya hiçbir değer için sağlanmıyorsa bu eşitliğe de denklem denir” (Altun, 2016, s. 294). Öğrencilerin bu iki kavramı ayırt etmede yaşadıkları güçlükler, genellikle sembolik ifadelerin anlamını kavrayamamalarından ve işlemsel bilgiye aşırı odaklanmalarından kaynaklanmaktadır (Kieran, 2007). Bu bağlamda, özdeşlik ve denklemlerin öğretiminde kavramsal anlamaya dayalı etkinliklerin kullanılması, öğrencilerin cebirsel ifadeler arasındaki yapısal benzerlikleri fark etmelerine ve matematiksel genelleme becerilerini geliştirmelerine katkı sağlamaktadır (Sfard ve Linchevski, 1994). Dolayısıyla, özdeşlik ve denklem öğretimi yalnızca sembolik işlemleri öğretmekle sınırlı kalmamalı, öğrencilerin bu kavramların anlamlarını derinlemesine kavramalarına olanak tanıyacak öğretim yaklaşımları tercih edilmelidir.

1.2.Hata

Hata, matematiksel işlemler veya düşünsel süreçler sırasında doğruluğu sağlanmamış uygulamaları ifade eder (Bayar, 2007). Hata, hem bir kavram yanılgısından kaynaklanabileceği gibi, aynı zamanda

dikkatsizlik, konsantrasyon eksikliği veya bilgi eksikliğine bağlı yanlış yorumlamalar sonucu da ortaya çıkabilir (Gates, 2001). Matematiksel öğrenme sürecinde öğrencilerin yaptıkları hatalar, yalnızca yanlış sonucu üretmekle kalmaz; aynı zamanda öğrencinin kavramsal anlayışı ve matematiksel düşünme becerisi hakkında önemli ipuçları sunar. Örneğin, matematik eğitimi alanında yapılan çalışmalar, öğrencilerin cebirsel ifadeler, denklem çözümü veya problem çözme bağlamlarında gerçekleştirdikleri hataların “sadece aritmetik yanlışlıklar” olmadığını; bunun ötesinde kavramsal yanlış anlamalar, sembolik yanlış kullanımlar ve eğitim ortamı kaynaklı süreç hataları da barındırdığını göstermektedir (Hoth vd., 2022; Mathaba vd., 2024). Öğrencilerin, genellikle cebirsel ifadelerde temel semboller ve özellikle eşitlik işareti gibi gösterimleri yanlış veya eksik kullanma eğiliminde oldukları ve literatürde var olan hata türleri ile örtüştüğü saptanmıştır (Khoshaim, 2018).

Sonuç olarak, matematiksel hatalar bir başarısızlık göstergesi olarak görülmemelidir. Tam aksine, doğru tanımlandıklarında ve uygun biçimde öğretim sürecine dahil edildiklerinde, öğrencinin eksik veya yanlış anladığı kavramlara ışık tutan güçlü araçlardır. Matematik eğitimi bağlamında öğretmenlerin hataları yok saymak yerine analiz etmek ve öğrenme fırsatına çevirmek yönünde bir tutum geliştirmeleri önerilmektedir. Cebirsel ifadeler matematik öğretiminin hem teorik hem de uygulamalı yönünü temsil eden önemli bir konusudur. Bu ifadeler, öğrencilerin sembolik düşünme, model kurma ve genelleme becerilerini geliştirerek onları ileri düzey matematiksel düşünmeye



hazırlar. Aynı zamanda bilimsel ve toplumsal karar verme süreçlerinde kullanılan modellerin temelini oluşturur. Bu bağlamda ortaokul öğrencilerinin özdeşlikler ve cebirsel ifadeler konusunda yapmış oldukları hataların incelenmesi doğru bir cebir öğretimi için önem arz etmekte ve aritmetikten cebire geçişte öğretmenlere rehberlik etmesi beklenmektedir.


1.3.Denklem ve Özdeşlikler Konusunda Yapılan Öğrenci Hataları.

Ortaokul 8. sınıf öğrencileri ile gerçekleştirilen çalışma sonucunda, öğrencilerin cebirsel ifadeler, denklemler ve özdeşlikler konularında farklı türlerde hatalar yaptıkları belirlenmiştir. Elde edilen bulgular, öğrencilerin hem kavramsal anlamlandırma hem de işlemsel uygulama süreçlerinde çeşitli güçlüklerle karşılaştıklarını ortaya koymaktadır. Bu hatalar özellikle eşitlik kavramının yanlış yorumlanması, sembolik temsillerin anlamının eksik kavranması, benzer terimlerin uygun şekilde birleştirilememesi ve özdeşlik ile denklem arasındaki farkın doğru biçimde ayırt edilememesi gibi durumlarda ortaya çıkmaktadır. Öğrencilerin bu tür hataları, cebirsel düşünmenin gerektirdiği soyutlama, genelleme ve mantıksal ilişkilendirme becerilerindeki eksikliklerin bir yansıması olarak değerlendirilebilir.

Bu bağlamda, araştırma kapsamında tespit edilen hata türleri aşağıdaki tabloda kategoriler hâlinde sunulmuş ve her bir hata örneği, ilgili öğrenci yanıtlarıyla birlikte detaylı biçimde açıklanmıştır.

**Tablo 1. Ortaokul Öğrencilerinin Denklemler ve Özdeşlikler
Konusunda Yapmış Oldukları Hatalar.**

Soru ve Hatalı Cevap	Açıklama
$5xy$ ifadesine 5 eklersek hangi ifadeyi buluruz? 	Bu hata tipinde öğrenciye $5xy$ ifadesine 5 eklersek hangi ifadeyi buluruz şeklinde bir soru yöneltilmiştir. Öğrenci $5xy + 5$ ifadesini yazdıktan sonra ifadenin eşiti olarak benzer olmayan terimleri toplayarak $10xy$ ifadesine ulaşmıştır. Burada öğrenci, sembolik ifadeleri anlam temelli değil, işlemsel ezberlere dayalı bir şekilde yorumlamaktadır. Öğrenci $5xy + 5$ ifadesini bulmuş olmasına rağmen burada toplama işlemi yapması gerektiğine inanmakta ve eşitliğin diğer tarafına farklı bir sonuç yazma gerekliliği hissetmektedir. Öğrenci burada farklı değişkenleri toplama hatası yapmıştır.
$(m+n)^2 = m^2 + n^2 + ?$ İfadesinin özdeşlik olması için “?” işareti yerine ne yazılmalıdır? 	Bu hata tipinde öğrenciye $(m+n)^2 = m^2 + n^2 + ?$ İfadesinin özdeşlik olması için “?” işareti yerine ne gelmelidir şeklinde soru yöneltilmiş olup öğrenci “mn” cevabını vermiştir. Öğrenci burada iki terim toplamının karesi özdeşliğini yanlış anlamlandırmış olmakla birlikte hatalı cevap vermiştir. Öğrencinin burada iki terim toplamının

	karesi özdeşliğini yanlış ezberlemesinden dolayı hatalı cevaba ulaştığı düşünülmektedir. Öğrenci burada iki terim toplamının karesi özdeşliğinin açılımında hata yapmıştır.
İki sayının kareleri farkı 32, toplamı 8 ise bu iki sayının farkı kaçtır? 	Burada öğrenciye $x^2 - y^2 = 32$ ve $x + y = 8$ eşitlikleri verilmiş olup öğrenciden “$x - y$” ifadesinin değerini bulması istenmiştir. Öğrenci burada iki kare farkı özdeşliğinde $x^2 - y^2 = (x - y) \cdot (x + y)$ eşitliği yerine $x^2 - y^2 = (x - y) + (x + y)$ şeklinde bir eşitlik yazarak çözüm yapmıştır ve sonuç olarak “$x - y$” ifadesinin eşitini 24 bulmuştur. Bu hata, öğrencinin çarpanlara ayırma ve özdeşlikler konusundaki yapısal ilişkiyi (çarpma işlemi yoluyla elde edilen eşitlik) fark edemediğini, toplama işlemini işlemsel bir alışkanlık olarak kullandığını ortaya koymaktadır. Öğrenci burada, iki kare farkı özdeşliğinde yer alan çarpma ilişkisini toplama ilişkisiyle karıştırmış, dolayısıyla anlamsal işlem hatası gerçekleştirmiştir. Öğrenci burada iki terim karesinin farkı özdeşliğinin açılımında hata yapmıştır.
Denklem nedir?	Öğrenci, denklem kavramını tanımlarken “içinde bilinmeyen bulunan ifade”

İçinde bilinmeyen bulunan ifade

biçiminde bir açıklama yapmıştır. Bu tanım, öğrencinin denklem kavramını yalnızca “bilinmeyen” ögesiyle ilişkilendirdiğini, ancak eşitlik ilişkisini göz ardı ettiğini göstermektedir. Dolayısıyla öğrenci, “bilinmeyen içeren ifade” ile “denklem” kavramlarını birbirine karıştırmaktadır. Öğrencinin bilinmeyen bulunan tüm ifadeleri denklem olarak kabul ettiği ve eşitliği önemsemediği düşünülmektedir. Öğrenci burada denklem ile ilgili tanımsal hata yapmıştır.

Özdeşlik nedir?

İçinde birden fazla bilinmeyen bulunan

Öğrenci, özdeşlik kavramını tanımlarken, bu kavramın temel özelliği olan “her değişken değeri için eşitliğin sağlanması” durumuna değinmemiştir. Bunun yerine, özdeşliği birden fazla bilinmeyen içeren ifade olarak nitelendirmiştir. Bu durum, öğrencinin özdeşliği eşitliğin yapısal veya doğruluk yönünden değil, içerdiği bilinmeyen sayısına göre sınıflandırdığını göstermektedir.

Bu tür bir tanım, öğrencinin özdeşlik kavramına ilişkin hatalı bilgiye sahip olduğunu ortaya koymaktadır. Öğrenci, özdeşlik kavramını “bilinmeyen sayısı”

üzerinden açıklamaktadır. Öğrenciye göre bir ifadenin özdeşlik olabilmesi için birden fazla bilinmeyen içermesi gerekmektedir. Öğrenci burada özdeşlik kavramı ile ilgili tanımsal hata yapmıştır.

$a - c + 6 = 19$ ise $a - c = ?$

$a - c + 6 = 19$
 $a - c = 19 + 6$
 $a - c = 25$

Öğrenci, burada eşitliğin korunumu ilkesini doğru biçimde uygulayamamıştır.

Bu tarz durumlarda amaç, eşitliğin her iki tarafına aynı işlemi uygulayarak değişkeni (veya istenen ifadeyi ki burada $a - c$ ifadesidir) yalnız bırakmaktır.

Ancak burada öğrenci, $+6$ terimini karşı tarafa işlem yönünü değiştirerek değil, doğrudan toplama işlemiyle aktarmıştır. Öğrenci doğru çözüm yolunu biliyor görünsede, eşitliğin iki tarafında yapılan işlemler arasındaki ilişkiyi kavramsal düzeyde anlamlandıramamıştır.

Ayrıca hata, cebirde “işaret (pozitif/negatif) kavramı” ve “eşitliğin korunumu” konularında kavramsal eksikliğe işaret etmektedir. Öğrenci burada ters işlem hatası yapmıştır.

Hangi sayının 2 fazlasının yarısının 4 katı 32 eder?

Öğrenci, payda içeren bir ifadenin önündeki katsayıyı parantez içine doğru şekilde dağıtmamıştır. Bu durum, dağıtma özelliği ve rasyonel ifadelerde çarpma işlemi kurallarının yanlış

$$4\left(\frac{x+2}{2}\right)=32$$

$$\frac{4x+2}{2}x=\frac{92}{1}$$

$$4x+2=64$$

$$\frac{4x+62}{4}$$

$$x=62$$

uygulanmasıdır. Doğru biçimde, katsayı payın tamamına uygulanmalı ve ardından sadeleştirme yapılmalıdır. Yanlış uygulama sonucu denklemdeki katsayıların oranı bozulmuş, dolayısıyla elde edilen x değeri hatalı çıkmıştır. Öğrenci burada işlem yaparken parantezi görmezden gelerek parantez hatası yapmıştır.

Aşağıda verilen ifadelerin eşitlerinin yazınız.

a) $5a-8a=$

b) $4x+7=$

c) $5a+8a=$

d) $4x-7=$

b) $4x+7=11x+7$ topladın

Bu durum, öğrencinin eşittir işaretini bir işlem yapma yönlendirmesi olarak (yani “şimdi toplamalısın” ya da “işlem yapmaya devam etmelisin” anlamında) algıladığını gösterir. Bu tür bir hata, cebirsel düşünmenin gelişiminde sık görülür ve öğretimde eşittir işaretinin “denkliği ve dengeyi ifade ettiği” vurgulanmalıdır. Yani, amaç iki tarafın birbirine eşit olmasını sağlamak, yalnızca toplama veya çıkarma işlemi yapmak değildir. Burada öğrencinin eşittir ifadesinin sadece işlem yap anlamına yoğunlaşmış olup denge anlamını kavrayamadığı görülmektedir. Burada öğrenci “=” işaretinin verilenden farklı bir sonuç üretmesi gerektiğine inandığı için benzer olmayan terimleri toplama hatası yapmıştır.

$a+9$ ifadesinde “a” için ne söyleyebilirsiniz?

$$a = \boxed{-9}$$

Öğrenci, ifade ile denklem kavramlarını karıştırmıştır.


Soruda $a + 9$ bir ifade olarak verilmiştir; bu ifade herhangi bir değere eşitlenmemiştir. Dolayısıyla bu ifadeden a 'nın belirli bir sayısal değeri çıkarılamaz. Öğrenciden burada “a” için bilinmeyen kavramını söylemesi beklenmekte olup öğrenci verilen ifadede bilinmeyen için bir sayısal değer vermesi gerektiğine inanmıştır. Öğrenci burada “ $a+9$ ” ifadesini bir denklem gibi düşünüp a değerini -9 olarak bulduğu varsayılmaktadır. Öğrencide bilinmeyen kavramının oluşmamasından dolayı hatalı cevap vermiştir.

$\frac{y}{3} + 2 = 14$ denklemini
çözünüz

$$\frac{y}{3} = 12 \quad y = 4$$


Bu hata, öğrencinin cebirsel işlemlerdeki eşitlik ilkesini (her iki tarafa aynı işlemin uygulanması gerektiği kuralını) doğru biçimde uygulayamadığı için yaptığı düşünülmektedir. Öğrenci burada her iki tarafı 3 ile çarpmak yerine sağ tarafı 3'e bölmeyi tercih etmiştir. Burada öğrenci bölme işleminin tersi olarak çarpma işlemi yapmak yerine yine bölme işlemi yapmayı tercih etmiş olup ters işlem hatası yapmıştır.

2.(a+b)-c=2a+2b+3 İfadesi
bir özdeşlik ise c=?



Öğrenci, eşitlik kavramının denge özelliğini ve terimlerin eşitliğin iki tarafı arasında geçişinde işaret değişiminin gerekliliğini kavrayamamıştır. Bu durum, cebirsel işlemlerde “işaret duyarlılığı” ve “denge temelli düşünme” becerilerinin henüz gelişmediğini göstermektedir. Öğrenci, eşitliğin her iki tarafında yer alan ortak terimleri eşitlerken $-c$ ifadesindeki negatif işareti dikkate almamıştır. Bu durum, işlemin yönünü ve sonucun doğruluğunu etkilemiştir. Öğrenci burada işaret hatası yapmıştır.

$9x-6(2-x)=48$ Denklemini
çözünüz.



Öğrenci, denklemi çözerken dağılma özelliğini yanlış uygulamış olup negatif katsayılı parantezlerin açılımında işaret değişiminin gerekliliğini kavramsal olarak fark edememiştir. Bu durum, cebirsel ifadelerin yapılarını ezbere uygulama eğiliminden kaynaklanabilir. Bu tür bir hata, genellikle öğrencilerin “dağılma özelliğini uygularken negatif işaretin etkisini parantez geneline yaymayı” unutması sonucu ortaya çıkmaktadır. Öğrenci burada işaret hatası yapmıştır.

2. SONUÇ

Yapılan öğrenci hataları incelendiğinde, öğrencilerin cebirsel işlemlerde yaptıkları hataların büyük oranda kavramsal yetersizliklerden kaynaklandığı görülmektedir. Öğrencilerin yalnızca işlemsel süreçleri ezbere dayalı biçimde uyguladıkları, ancak bu süreçlerin altında yatan sembolik anlamları, eşitlik kavramını ve cebirsel temsil ilişkilerini yeterince içselleştiremedikleri anlaşılmaktadır. Özellikle “benzer olmayan terimlerin toplanması”, “özdeşliklerde eksik terim bırakılması” ve “denklem–ifade ayrımının yapılamaması” gibi hatalar, öğrencilerin cebiri işlemsel bir araç olarak gördüklerini; dolayısıyla cebirsel düşünmenin temelini oluşturan genelleme yapmada, harflerin ve sembollerin anlamını kavramada ve ilişki kurma süreçlerinde zorlandıklarını göstermektedir (Kieran, 2007; Booth ve Koedinger, 2012). Öğrenciler, özdeşlik formüllerini uygularken işaret hataları yapmakta, orta terimleri unutmakta ya da farklı yapıya sahip ifadeleri ezberledikleri kalıplara zorla uydurmaya çalışmaktadır (Aydın-Güç ve Aygün, 2022).

Elde edilen bulgulara göre öğrenciler, eşitlik kavramını çoğu zaman “işlem yapma yönergesi” olarak yorumlamakta; “eşitliğin iki tarafının denkliği” fikrini ise ihmal etmektedir (Powell, 2012). Bu durum, literatürde sıkça vurgulanan “eşittir işareti kavram yanılgısı” ile örtüşmektedir (Knuth vd., 2006). Özellikle denklem çözme sürecinde yapılan hatalar, öğrencilerin eşitliğin korunumu ilkesini uygulamada güçlük yaşadıklarını; pozitif/negatif işaret değişimlerini sezgisel olarak

değil, yüzeysel işlemsel kalıplarla gerçekleştirdiklerini ortaya koymaktadır. Bu bağlamda öğrencilerin “denge temelli düşünme” becerilerinin henüz tam olarak gelişmediği ve ezber bilgiye dayalı işlemler yaptığı söylenebilir (Hoth vd., 2022).

Analizlerde dikkat çeken bir diğer unsur, öğrencilerin ifade ile denklem kavramlarını karıştırmalarıdır. Öğrencilerin “a+9” gibi bir ifadeyi doğrudan “0”a eşitleyerek çözmeye çalışmaları, matematiksel nesnelerin anlamları arasındaki farkın kavramsal düzeyde ayırt edilmediğini göstermektedir. Bu tür hatalar, sembolik temsillerin anlamsal boyutunun öğretimde yeterince vurgulanmadığına işaret etmektedir (Cai & Knuth, 2011).

Ters işlemi sınırlı olarak uygulayan öğrenci hatalarına yönelik olarak $\frac{y}{3} + 2 = 14$ denkleminde önce 12 sayısından 2’ yi çıkartmış ve 12 bulmuş, ardından ise bilinmeyeni bulmak için 12’ yi 4’ e bölmüş ve 3 bulmuştur. Kieran (1992) yapmış olduğu çalışmada benzer hata türüne rastlamıştır. Yine bir başka denklem çözümünde öğrenci parantezi yok saymış ve $4.(\frac{x+2}{3})$ ifadesinde 4’ ü sadece x değişkeni ile çarpmış 2 ile çarpmamıştır. Öğrenciler bu şekilde yazımın doğru olduğunu bilmekte ve parantezi yok saymaktadırlar (Perso, 1992).

Cebirsel sembollerle etkili bir biçimde çalışabilme becerisi kazanabilmek için, öncelikle matematiksel işlemlerin ve ilişkilerin yapısal özelliklerinin derinlemesine anlaşılması gerekmektedir. Öğrenciler, denklemlerin ve özdeşliklerin yapısal özelliklerini

başlangıçta fark etmekte zorlanabilirler. Özdeşlikler konusundaki en yaygın hatalardan biri, öğrencilerin özdeşlik ile denklem arasındaki farkı yeterince kavrayamamasıdır (Sarımanoğlu, 2019). Özdeşliklerin tüm değişken değerleri için geçerli olduğuna ilişkin kavramsal bilginin göz ardı edilmesi hatalara neden olmaktadır. Bu nedenle, öğretim sürecinin temel hedefi, öğrencilere bu kavramların yapısal yönlerini anlamaya yönelik bir kavramsal bakış açısı kazandırmak olmalıdır. Bu doğrultuda, öğretmenlerin konuya ilişkin bilgi ve farkındalıklarının artırılması, sınıf içinde karşılaştıkları öğrenci düşünme biçimlerini doğru analiz edebilmeleri ve etkili biçimde yönlendirebilmeleri açısından önemli bir destek sağlayacaktır (Buran, 2012).

Genel olarak, analiz edilen hata türleri öğrencilerin cebirsel düşünme süreçlerinde yüzeysel işlem pratiğine dayalı bir anlayış geliştirdiklerini; anlam temelli öğrenmeye yeterince erişemediklerini göstermektedir. Bu durum, cebir öğretiminde öğrencilerin yalnızca doğru sonuca ulaşmalarını değil, aynı zamanda cebirsel yapıların altında yatan ilişkileri, eşitlik dengesini ve sembollerin temsil gücünü fark etmelerini sağlayacak öğretim tasarımlarına gereksinim olduğunu göstermektedir. Dolayısıyla öğretmenlerin, hata analizini bir “değerlendirme aracı” olarak değil, öğrencinin düşünme biçimini anlamaya yarayan bir tanısal öğrenme fırsatı olarak kullanmaları büyük önem taşımaktadır (Blanton & Kaput, 2011).

3. ÖNERİLER

Yapılan analizler, ortaokul 8. sınıf öğrencilerinin denklemler ve özdeşlikler konusundaki hatalarının büyük ölçüde kavramsal eksikliklerden, işlemsel ezbere dayalı öğrenme yaklaşımlarından ve sembolik ifadeleri anlamlandırmadaki güçlüklerden kaynaklandığını ortaya koymaktadır. Bu bulgu, cebir öğretiminde yalnızca işlem becerilerine odaklanmanın yeterli olmadığını; aynı zamanda öğrencilerin anlam temelli düşünme, ilişkilendirme ve kavramsal muhakeme becerilerini geliştirmeye yönelik etkinliklerin de önem taşıdığını göstermektedir. Bu çerçevede, öğrencilerin cebirsel kavramları daha derinlemesine anlamlandırabilmeleri ve yaptıkları hatalardan öğrenme fırsatları elde edebilmeleri amacıyla çeşitli öneriler sunulmuştur.

3.1.Kavramsal Anlamlandırmaya Dayalı Öğretim Yaklaşımları

Öğretim sürecinde cebirin yalnızca sembolik işlemler bütünü değil, aynı zamanda ilişkiler ve genellemelerin dili olduğu vurgulanmalıdır. Bu amaçla modelleme, örüntü analizi, temsil dönüşümleri (örneğin, sözel, grafiksel ve sembolik gösterimler arası geçişler) ve öğrenci açıklamalarına dayalı etkinlikler kullanılabilir. Ayrıca kavram öğretiminde öğrencinin merkezde olduğu gözlem yapmalarına ve hatalarını fark etmelerine olanak sağlayacak etkinlik temelli öğretim metodu kullanılarak öğrencilerin kavramları içselleştirmeleri sağlanabilir. Baykul (2009) denklem kavramına girişte kavramlarla ilgili yeteri kadar çalışmalar yapılması gerektiğini, kavram öğretiminin

etkinliklerle yapılabileceğini vurgulamıştır. Benzer şekilde probleme dayalı öğretim metodu gibi öğrenciyi merkeze alan öğretim metotları kullanılabilir. Özellikle konu ile ilgili olarak öğrencilerin özdeşlik ve denklem ile ilgili tanımları yapabilmeleri sağlanmalıdır.

3.2. Eşitlik Kavramının Denge Temelli Öğretimi

Öğrenciler eşitlik kavramını gördükleri zaman genellikle işlem yapma gerekliliği hissetmektedirler. Bundan dolayı öğrencilerin eşitlik kavramını yalnızca işlem yönergesi değil, bir ilişki ve denge göstergesi olarak algılamaları sağlanmalıdır. Bu doğrultuda, denge modeli etkinlikleri (Baratta, 2011)., somut materyaller veya dijital araçlar yardımıyla eşitliğin korunumu ilkesi vurgulanabilir. Eşitlik kavramı ile ilgili etkinliklerde terazi kullanılabilir (Baykul, 2009). Öğrencilere bireysel ya da grup çalışması şeklinde dijital ya da geleneksel etkinlikler yaptırılabilir.

3.3. Matematikte Sembol ve Terim Kullanımına Yönelik Çalışmalar

Eşitliğin bir tarafından diğer tarafına bir terim geçirilirken yapılan işaret hataları, genellikle işlem sırasında eşitliğin her iki tarafına aynı matematiksel işlemi uygulamak yerine ezbere işlem yapan öğrencilerde görülmektedir (Kieran, 1992). Öğrencilerin, parantez açma veya bir terimin eşitliğin diğer tarafına geçmesi durumunda işaret değişimlerini ezbere öğretilmemeli öğrencilere bu durumun nedeni mantıksal gerekçelendirme üzerinden öğretilmelidir. Eşitlik işaretinin her zaman

bir işlemin sonucunu göstermediği, iki taraf arasında bir dengeyi ifade ettiği öğrenciler tarafından kavranırsa, eşitlik kavramından kaynaklanan hataların azalması sağlanacaktır (Akyüz ve Hangül, 2014). Öğrencilerin sembol ve terim kullanım becerilerinin geliştirilmesi amacıyla, bireysel veya grup çalışmaları şeklinde etkinliklere katılmaları teşvik edilmelidir. Bu yaklaşım, öğrencilerin matematiksel ifadeleri anlam temelli kavramalarını desteklerken, aynı zamanda işbirlikçi öğrenme yoluyla problem çözme ve eleştirel düşünme becerilerinin de gelişmesini sağlayabilir. Böylece öğrenciler, sembolik gösterimleri yalnızca ezberlemiş kurallar olarak değil, anlamlı matematiksel yapılar olarak öğrenebilirler.

3.4.Teknoloji Destekli Matematik Öğretimi

Matematik öğretiminde teknolojinin etkili biçimde kullanılması, öğrencilerin soyut sembolik ilişkileri daha somut ve görselleştirilebilir bir biçimde anlamalarına olanak tanımaktadır. Dinamik cebir yazılımları (örneğin *GeoGebra*, *Desmos*) aracılığıyla öğrenciler, cebirsel ifadelerin grafiksel temsillerini gözlemleyebilmekte; değişkenler arasındaki ilişkileri etkileşimli biçimde deneyimleyebilmektedir. Bu tür araçlar, öğrencilerin yalnızca işlemsel doğruluğa odaklanmak yerine, cebirsel yapıların anlamsal ve yapısal yönlerini keşfetmelerini desteklemektedir (Bokhove ve Drijvers, 2010).

Öğrencilere, Milli Eğitim Bakanlığı tarafından geliştirilen MEBİ ve EBA platformlarında yer alan cebir öğretimine yönelik dijital etkinlikler gösterilerek, bu etkinlikler üzerinden ödevlendirmeler

yapılabilir. Ayrıca, öğrencilerin cebirsel kavramlarda sıkça yaptıkları hataları fark etmeleri ve gidermeleri amacıyla sınıf içinde bu tür etkinlikler üzerinde tartışmalar ve uygulamalar gerçekleştirilebilir. Böylece öğrencilerin cebirsel düşünme becerileri gelişirken, dijital ortamda sunulan geri bildirimlerle hatalarını analiz etme ve düzeltme fırsatı bulmaları sağlanır. Bu yaklaşım, hem dijital okuryazarlık becerilerini destekler hem de teknolojik araçlarla zenginleştirilmiş bir öğrenme süreci oluşturarak cebir öğretiminin etkililiğini artırır (Meylani ve Bitter, 2023).

Teknoloji destekli öğretim yaklaşımları, öğrencilerin cebirsel düşünmeyi yalnızca kural uygulama düzeyinde değil, ilişkilendirme ve genelleme düzeyinde de geliştirmelerine katkı sağlayacaktır. Ayrıca teknoloji destekli matematik eğitiminin öğrencilerin akademik başarılarını olumlu anlamda artırdığı görülmektedir (Eraytaç ve Tarım, 2024).

3.5.Değerlendirme Yaklaşımları

Cebir öğretiminde kullanılan değerlendirme süreçlerinin amacı, yalnızca öğrencilerin doğru sonuca ulaşp ulaşmadığını belirlemekle sınırlı olmamalıdır. Etkili bir değerlendirme süreci, öğrencilerin nasıl düşündüklerini, hangi stratejileri kullandıklarını ve hatalarının altında yatan bilişsel nedenleri ortaya çıkaracak biçimde tasarlanmalıdır. Bu anlayış, değerlendirmeyi bir ölçme aracı olmaktan çıkarıp, öğrenme sürecinin ayrılmaz bir parçası haline getirecektir.

Ayrıca, süreç odaklı değerlendirme yaklaşımları (örneğin portfolyo değerlendirmesi veya performans görevi uygulamaları vb.) öğrencilerin öğrenme süreçlerine yönelik zengin nitel veriler sunar. Bu tür değerlendirmelerde öğretmen, yalnızca öğrencinin ulaştığı sonuca değil, kullandığı stratejilere, yaptığı açıklamalara ve problem çözme sürecindeki akıl yürütmelere odaklanır (Demosthenous vd., 2021). Bu yaklaşım, öğrencinin kavramsal anlayışını ve cebirsel düşünme biçimini daha doğru biçimde ortaya koymasına ve var olan hataların fark edilerek düzeltilmesine yardımcı olacaktır.

3.6.Öğretmen Farkındalığının Artırılması

Literatürde yapılan çalışmalarda konu ile ilgili olarak öğretmen ve öğretmen adaylarının da kavram yanlışlarına sahip olduğu görülmektedir. Bundan dolayı öğretmen ve öğretmen adaylarının konu ile ilgili farkındalıklarının artırılması mevcut kavram yanlışlarının düzeltilmesine fayda sağlayacaktır. Literatürde mevcut olan öğrencilerin cebirsel ifadeler ve özdeşlikler konusunda yapmış oldukları hata türlerinin öğretmenler tarafından bilinmesi bu olumsuz etkiyi en aza indirmek için öğretmenlere fırsat sunacaktır (Akyüz ve Hangül, 2014).

Öğrencilerin cebirsel düşünme süreçlerinde yaptıkları hataların doğru biçimde analiz edilmesi, büyük ölçüde öğretmenin bu hataları tanıma, yorumlama ve pedagojik olarak dönüştürme becerisine bağlıdır. Hata ve yanlışlar birer öğrenme fırsatı olarak kullanılmalı; öğrenciler yanlış yaptıkları adımı belirleyip neden hatalı olduğunu keşfetmeye

yönlendirilmelidir. Bu nedenle öğretmenler, öğrencilerin hatalarını yalnızca “yanlış cevaplar” olarak değil, öğrencinin düşünme biçiminin, kavramsal düzeyinin ve öğrenme sürecindeki zorluklarının bir yansıması olarak değerlendirmelidir. Öğrenci hatalarına bu perspektiften yaklaşmak, öğretmene hem öğrencinin düşünme süreçlerini daha derinlemesine anlama hem de öğretimi bu doğrultuda yeniden yapılandırma imkanı sunacaktır.

Bu bağlamda, öğretmen eğitim programlarının içeriğinde hata analizi, tanısal değerlendirme, kavramsal anlama ve öğrenci düşüncesinin çözümlemesi gibi alanlara sistematik biçimde yer verilmesi gerekmektedir. Öğretmen ve Öğretmen adaylarına, farklı öğrenci örneklerinden yola çıkarak yapılan hata türleri, hataların altında yatan bilişsel süreçleri çözümleme, alternatif düşünme biçimlerini fark etme ve uygun öğretimsel müdahaleler geliştirme fırsatı sunulmalıdır. Böylece öğretmenler, öğrencilerin yalnızca “nerede hata yaptıklarını” değil, “neden bu şekilde düşündüklerini” de anlayabilecek donanıma sahip olurlar.

4. KAYNAKÇA

- Aktaş-Sarpkaya, G., & Çinkılıç, K. (2025)"Matematik Eğitiminde Kavram Yanılgılarının Giderilmesine Yönelik Yapılan Çalışmaların Eğilimleri: Sistemik Alan Yazın Tarama." *İhlara Eğitim Araştırmaları Dergisi* 10(1), 41-62.
- Akyüz, G., & Hangül, T. (2014). 6. sınıf öğrencilerinin denklemler konusunda sahip oldukları yanılgıların giderilmesine yönelik bir çalışma. *Journal of Theoretical Educational Science*, 7(1), 16-43
- Altun, M. (2016). *Ortaokullarda (5, 6, 7 ve 8. Sınıflarda) matematik öğretimi*. Aktüel Yayıncılık.
- Aydın-Güç, F., & Aygün, D. (2021). Errors and Misconceptions of Eighth-Grade Students Regarding Operations with Algebraic Expressions. *International Online Journal of Education and Teaching*, 8(2), 1106-1126.
- Baki, A.(1996). Okul matematiğinde ne öğretelim, nasıl öğretelim? *Matematik Dünyası*, 6(3), 6-11.
- Baratta, W. (2011). Linear equations: Equivalence=success. *Australian Mathematics Teacher*, 67(4), 6-11.
- Bayar, H. (2007). *1.Dereceden bir bilinmeyenli denklem konusundaki öğrenci hatalarının analizi*. (Tez No. 177968) [Yüksek lisans tezi, Balıkesir Üniversitesi-Balıkesir]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Baykul, Y. (2009). *İlköğretimde matematik öğretimi: 6.-8. sınıflar için*. Pegem A. Yayıncılık.

- Birgin, O., & Demirören, K. (2020). Sekizinci sınıf öğrencilerinin basit görsel ve cebirsel ifadeler konusundaki hata ve kavram yanlışlarının incelenmesi. *Uluslararası Sosyal ve Eğitim Bilimleri Dergisi*, 7(14), 233-247.
- Blanton, M. L., & Kaput, J. J. (2011). Functional thinking as a route into algebra in the elementary grades. In *Early algebraization: A global dialogue from multiple perspectives* (pp. 5-23). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Bokhove, C., & Drijvers, P. (2010). Digital tools for algebra education: Criteria and evaluation. *International Journal of Computers for Mathematical Learning*, 15(1), 45-62.
- Booth, J. L., & Koedinger, K. R. (2008). Key misconceptions in algebraic problem solving. In *Proceedings of the annual meeting of the cognitive science society* (Vol. 30, No. 30).
- Buran, O. (2012). *Probleme dayalı öğretim metodunun birinci dereceden bir bilinmeyenli denklemler ve özdeşliklerin öğretiminde 8.sınıf öğrencilerinin akademik başarısına etkisi*. (Tez No. 301120) [Yüksek lisans tezi, Atatürk Üniversitesi-Erzurum]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Cai, J., & Knuth, E. (Eds.). (2011). *Early algebraization: A global dialogue from multiple perspectives*. Springer Science & Business Media.
- Cantimer, G. G. (2022). 8. Sınıf Öğrencilerinin Cebirsel İfade,

- Denklem ve Özdeşliklere Yönelik Kavram İmajlarının İncelenmesi. *Muğla Sıtkı Koçman Üniversitesi Eğitim Fakültesi Dergisi*, 9(2), 421-440.
- Cinkol, H. (2010). İlköğretim 8. sınıf matematik ders kitabı, Ankara: Pasifik Yayınları.
- Demosthenous, E., Christou, C., & Pitta-Pantazi, D. (2021). Mathematics classroom assessment: A framework for designing assessment tasks and interpreting students' responses. *European Journal of Investigation in Health, Psychology and Education*, 11(3), 1088-1106.
- Eraytaç, Ö. F., & Tarım, K. (2024). 6. Sınıf Matematik Dersinde Teknoloji Destekli Öğretimin Öğrencilerin Akademik Başarılarına Etkisi. *Eğitimde Kuram ve Uygulama*, 20(2), 184-205.
- Gates, P. (2001). Issues in mathematics teaching. London, England: Routledge Falmer.
- Hiebert, J. (1984). Children's mathematics learning: The struggle to link form and understanding. *The elementary school journal*, 84(5), 497-513.
- Hoth, J., Larrain, M., & Kaiser, G. (2022). Identifying and dealing with student errors in the mathematics classroom: Cognitive and motivational requirements. *Frontiers in psychology*, 13, 1057730.
- Kaput, J. J., Carragher, D. W., & Blanton, M. L. (Eds.). (2017). *Algebra in the early grades*. Routledge.
- Kieran, C. (2007). Learning and teaching algebra at the middle

- school through college levels: Building meaning for symbols and their manipulation. *Second handbook of research on mathematics teaching and learning*, 2, 707-762.
- Khoshaim, H. B. (2018). Inattentive Students Errors in Mathematics: Alarming Repetition. *International Journal of Learning, Teaching and Educational Research*, 17(11).
- Knuth, E. J., Stephens, A. C., McNeil, N. M., & Alibali, M. W. (2006). Does understanding the equal sign matter? Evidence from solving equations. *Journal for research in Mathematics Education*, 37(4), 297-312.
- Mathaba, P. N., Bayaga, A., Tîrnovan, D., & Bossé, M. J. (2024). Error Analysis in Algebra Learning: Exploring Misconceptions and Cognitive Levels. *Journal on Mathematics Education*, 15(2), 575-592.
- Meylani, R., & Bitter, G. G. (2023). Algebra in the Digital Age: Mastering Concepts with Online Learning Objects. *International Society for Technology, Education, and Science*.
- O'Shea, A., Booth, J. L., Barbieri, C., McGinn, K. M., Young, L. K., & Oyer, M. H. (2017). Algebra performance and motivation differences for students with learning disabilities and students of varying achievement levels. *Contemporary Educational Psychology*, 50, 80-96.
- Perso, T. (1992). Making the most of errors. *Australian Mathematics Teacher*, 48(2), 12-14
- Powell, S. R. (2012). Equations and the equal sign in elementary

- mathematics textbooks. *The Elementary school journal*, 112(4), 627-648.
- Sarımanoğlu, N. U. (2019). The investigation of middle school students' misconceptions about algebraic equations. *Studies in Educational Research and Development*, 3(1), 1-20.
- Sfard, A., & Linchevski, L. (1994). The gains and the pitfalls of reification—the case of algebra. *Educational studies in mathematics*, 26(2), 191-228.
- Stemele, B. P., & Jina Asvat, Z. (2024). Exploring learner errors and misconceptions in algebraic expressions with Grade 9 learners through the use of algebra tiles. *African Journal of Research in Mathematics, Science and Technology Education*, 28(1), 153-170.

YAPAY ZEKANIN TARIM, TEKNOLOJİ VE EĞİTİM ALANLARINA YANSIMALARI ÜZERİNE DİSİPLİNLERARASI BİR İNCELEME

