

BİLGİSAYAR MÜHENDİSLİĞİ

ALANINDA ARAŞTIRMALAR VE DEĞERLENDİRMELER

MART 2026

EDİTÖR

Prof. Dr. Selahattin BARDAK

İmtiyaz Sahibi / Yaşar Hız
Yayına Hazırlayan / Gece Kitaplığı

Birinci Basım / Mart 2026 - Ankara
ISBN / 978-625-321-060-1

© copyright

Bu kitabın tüm yayın hakları Gece Kitaplığı'na aittir.
Kaynak gösterilmeden alıntı yapılamaz, izin almadan hiçbir yolla çoğaltılamaz.

Gece Kitaplığı

Kızılay Mah. Fevzi Çakmak 1. Sokak
Ümit Apt No: 22/A Çankaya/ANKARA
0312 384 80 40
www.gecekitapligi.com / gecekitapligi@gmail.com

Baskı & Cilt

Bizim Büro
Sertifika No: 42488

**BİLGİSAYAR MÜHENDİSLİĞİ
ALANINDA ARAŞTIRMALAR VE
DEĞERLENDİRMELER**

MART 2026

EDİTÖR

Prof. Dr. Selahattin BARDAK

gece
kitaplığı

İÇİNDEKİLER

BÖLÜM 1

SÜRDÜRÜLEBİLİR ARICILIKTA AKILLI SİSTEM MİMARİSİ VE YAPAY ZEKA YAKLAŞIMLARI

Didem İŞSEVER 7

BÖLÜM 2

UZAMSAL VE KANAL ATTENTION MEKANİZMALARI İLE SAHTE GÖRÜNTÜ ALGILAMA

Engin OĞUZAY, Gökhan UÇKAN 25

BÖLÜM 3

OYUN BİLGİSAYARLARINA YÖNELİK KULLANICI ŞİKAYETLERİNİN WEB VE METİN MADENCİLİĞİ İLE ANALİZİ

Selahattin BARDAK, Kinyas POLAT 55

BÖLÜM 1

SÜRDÜRÜLEBİLİR ARICILIKTA AKILLI SİSTEM MİMARİSİ VE YAPAY ZEKA YAKLAŞIMLARI

Didem İŞSEVER¹

¹ Dr. Öğr. Üyesi, Bingöl Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, dissever@bingol.edu.tr, Orcid: 0000-0003-0226-1442

1. Giriş

Tarımsal üretim sistemleri, artan nüfus, doğal kaynakların sınırlılığı ve çevresel baskılar nedeniyle önemli bir dönüşüm sürecinden geçmektedir. Bu dönüşüm, yalnızca bitkisel ve hayvansal üretimi değil, ekosistem dengesi açısından kritik öneme sahip arıcılık faaliyetlerini de kapsamaktadır. Arıcılık; hem gıda üretimi hem de tozlaşma yoluyla biyolojik çeşitliliğin sürdürülmesi açısından stratejik bir tarımsal faaliyet olarak öne çıkmaktadır. Bu nedenle arıcılıkta sürdürülebilirliğin sağlanması, tarımsal sistemlerin dayanıklılığı ve uzun vadeli üretim güvenliği açısından önemli bir gereklilik olarak değerlendirilmektedir. İklim değişikliğinin tarımsal üretim üzerindeki etkileri ve artan gıda talebi, üretim süreçlerinde daha izlenebilir ve veri temelli yaklaşımların benimsenmesini zorunlu kılmaktadır. Çevresel değişkenlerin koloni sağlığı üzerindeki etkilerini analiz etmek için kovan ağırlığı ve koloni gelişiminin izlenmesi, etkili bir yöntem olarak öne çıkmaktadır (Flores vd., 2019). Bu bağlamda, dijital izleme sistemleri ve veri analitiğine dayalı yaklaşımlar, arıcılık faaliyetlerinin daha sistematik ve öngörülebilir biçimde yönetilmesine katkı sağlamaktadır. Böylece üretim verimliliği ile ekolojik sürdürülebilirlik arasında daha dengeli ve bütüncül bir yönetim modeli oluşturulabilmektedir. Geleneksel arıcılık uygulamaları büyük ölçüde deneyim ve periyodik olarak fiziksel şekilde gerçekleştirilen kontrollere dayanmaktadır. Ancak kolonilerdeki hastalık yayılımı, parazit baskısı ve çevresel stres faktörleri gibi çok boyutlu riskler karşısında bu yaklaşım yetersiz kalabilmektedir. Bu noktada sensör tabanlı izleme sistemleri ve biyosensör yaklaşımları ön plana çıkmaktadır (Bromenshenk vd., 2015). Çevresel değişimlere karşı erken uyarı mekanizması işlevi gören bal arıları, gelişmiş dijital izleme sistemleriyle desteklendiğinde; dinamik yaklaşımların ötesine geçen, veri odaklı birer biyosensör olarak değerlendirilmektedir. Son yıllarda yapay zekanın gelişimi ve veri odaklı makine öğrenmesi tekniklerinin arıcılıkta uygulanması, koloni davranışlarının otomatik analizinin yapılabilmesini sağlamaktadır (Tu vd., 2016). Bu yaklaşım, arıcılık faaliyetlerini geleneksel yöntemlerden ziyade önleyici ve veri odaklı bir yaklaşıma dönüştürmektedir. Veri odaklı sistemler, bal arısı davranışlarının otomatik analizine imkan tanıyarak koloni aktivitesinin sürekli ve nesnel biçimde değerlendirilmesini sağlamaktadır. Benzer şekilde, hibrit derin öğrenme yöntemleri aracılığıyla arı hastalıklarının erken teşhisinin mümkün olduğu ortaya konulmuş; böylece koloni sağlığının korunmasında yapay zeka tabanlı çözümlerin uygulanabilirliği kanıtlanmıştır (Metlek ve Kayaalp, 2021).

Kovan içi mikroklima ve koloni dinamiklerinin gerçek zamanlı takibi, geliştirilen izleme yöntemleri sayesinde daha kolay hale gelmektedir (Gil-Lebrero vd., 2017). Bu kapsamda; sıcaklık, nem ve ağırlık sensörlerinden elde edilen verilerin merkezi sistemlere aktarılması,


hem koloni durumunun uzaktan izlenmesini hem de arıcıların kritik durumlarda zamanında müdahale etmesini mümkün kılmaktadır. Ayrıca, ağırlık temelli otomatik izleme sistemleri de bal akışı ve koloni aktivitesinin değerlendirilmesinde etkin bir araç olarak kullanılmaktadır (Zacepins vd., 2017). Gerçek zamanlı veri üretimi kapasitesine sahip bu sistemler, arıcılıkta operasyonel risklerin yönetilmesi ve hızlı müdahale stratejilerinin belirlenmesi için gerekli olan karar destek sistemlerinin de altyapısını optimize etmektedir. Güncel teknolojik gelişmeler ışığında akıllı arıcılık, sadece bağımsız veri toplama araçları olarak değil aynı zamanda da hassas hayvancılık prensipleriyle uyumlu, veri odaklı ve geniş ölçekli akıllı tarım mimarilerinin stratejik bir bileşeni olarak ele alınmaktadır. Hayvancılık için geliştirilen modeller, üretim döngülerinin daha şeffaf ve izlenebilir bir yapıya kavuşturulmasına sağlayarak veriye dayalı yönetim süreçlerini optimize etmektedir (Norton vd., 2019). Modern tarımsal sistemlerde karar destek altyapılarının, üretim planlama süreçlerinin şeffaflığı, veri tabanlı yönetim kapasitesi açısından temel bir gereksinim olduğunu ortaya koymaktadır (Zhai vd., 2020). Akıllı arıcılık sistemleri; sensör ağları, veri işleme altyapıları ve yapay zeka modellerinin entegre çalıştığı üretim yapıları olarak değerlendirilmektedir. Türkiye bağlamında yapılan çalışmalar da arıcılık sektöründe dijital dönüşümün önemini ortaya koymaktadır. Akıllı arı kovanı ortam zekası uygulamalarının arıcılık sistemlerine entegre edilebileceğini gösteren çalışmalar, sensörler, gömülü sistemler ve veri işleme modüllerinin birlikte çalıştığı bir mimarinin kovan ortamında da uygulanabilir olduğunu ortaya koymuştur (Koçak vd., 2019). Üretim verilerinin mekansal analizlerle ilişkilendirilmesi, bal üretim potansiyelinin değerlendirilmesine katkı sağlamaktadır (Arslan vd., 2024). Bu tür yaklaşımlar, üretim planlaması ve kovan konumlandırma stratejilerinin bilimsel verilere dayandırılmasını sağlamaktadır. Yapay zeka destekli sensör ve veri analitiği teknolojileri, arıcılığı geleneksel gözleme dayalı bir üretim pratiğinden sürekli izlenen, modellenen ve optimize edilebilen bir sisteme dönüştürmektedir. Bu dönüşüm, yalnızca üretim verimliliğini artırmayı değil, aynı zamanda koloni sağlığını korumayı ve iklim değişikliğine adaptasyon kapasitesini güçlendirmeyi hedeflemektedir. Akıllı sistem mimarisi ve yapay zeka yaklaşımları yalnızca üretim performansının artırılmasına hizmet etmemekte; aynı zamanda arıcılık faaliyetlerinin ekolojik sürdürülebilirlik ilkeleri doğrultusunda yeniden yapılandırılmasına katkı sağlamaktadır.

Sensör tabanlı izleme ve veri odaklı analiz mekanizmaları, kaynak kullanımının daha verimli planlanmasına, gereksiz müdahalelerin azaltılmasına ve koloni sağlığının uzun vadeli korunmasına imkan tanımaktadır. İklim değişikliği ve çevresel dalgalanmalar karşısında uyarlanabilir ve öngörücü sistemlerin geliştirilmesi, arı kolonilerinin dayanıklılığını artırarak

sürdürülebilir üretim modeline geçişi desteklemektedir. Bu bağlamda akıllı sistem ve yapay zeka destekli arıcılık yaklaşımları, ekonomik verimlilik ile ekoloji arasında bütüncül bir denge kurmayı hedeflemektedir.

2. Yapay Zeka Tabanlı Metodolojiler

Arıcılık sistemleri; biyolojik süreçler, çevresel değişkenler ve üretim parametrelerinin dinamik etkileşiminden oluşan çok boyutlu ve karmaşık yapılarıdır. Koloni içi mikroklima, ana arı mevcudiyeti, işçi arı aktivitesi ve besin kaynakları gibi faktörler, iklimsel değişkenlerle birlikte üretim performansını da doğrudan belirlemektedir. Geleneksel arıcılıkta bu değişkenler tecrübe ve gözlemlere dayanırken; sensör teknolojileri ve IoT (Nesnelerin İnterneti) tabanlı veri toplama altyapılarındaki ilerlemeler, yüksek hacimli ve kesintisiz veri üretimini mümkün kılmıştır (Gil-Lebrero vd., 2017; Zacepins vd., 2017). Şekil 1’de yapay zeka tabanlı metodolojiler görülmektedir. Elde edilen veriler mekana bağlı olarak yapay zeka ve makine öğrenmesi yöntemlerinin uygulanmasını mümkün kılmaktadır. Hassas hayvancılık yaklaşımında olduğu gibi, arıcılıkta da dijital verilerle üretim süreçlerinin modellenmesi hedeflenmektedir (Norton vd., 2019). Karar destek sistemleri, veri analitiği ve tahmin modelleri üretim planlamasında önemli rol oynamaktadır (Zhai vd., 2020). Yapay zeka tabanlı metodolojiler; koloni sağlığı izleme, hastalık tespiti, üretim tahmini, davranış analizi ve konum optimizasyonu gibi alanlarda sıklıkla uygulanmaktadır. Veri odaklı bu yaklaşımların entegrasyonu, geleneksel arıcılık uygulamalarını modernize ederek reaktif yönetimden proaktif yönetime geçişi hızlandırmaktadır. Bu dijital dönüşüm, sektörün karşılaştığı karmaşık zorlukların aşılmasında ve sürdürülebilirliğin sağlanmasında kritik bir rol oynamaktadır.



Şekil 1. Yapay Zeka Tabanlı Metodolojiler

2.1. Koloni Sağlığının İzlenmesi ve Hastalık Tespiti

Makine öğrenmesi ve derin öğrenme algoritmaları, özellikle görüntü işleme ve karmaşık sınıflandırma problemlerinde yüksek başarılı sonuçlar sunmaktadır. Yapay zeka tabanlı sistemler aracılığıyla bal arısı davranışları otonom olarak analiz edilerek koloni aktivitesinin

objektif parametrelerle değerlendirilebileceği görülmüştür (Tu vd., 2016). Aynı zamanda derin öğrenme mimarileri kullanarak arı hastalıklarının tespitinde de yüksek doğruluk oranlarına ulaşılmış; bu durumun erken teşhis sistemlerinin geliştirilmesi için kritik bir temel oluşturduğu ortaya konulmuştur (Metlek ve Kayaalp, 2021). Buna ek olarak, petek yüzeyindeki larvaların buldukları yer ve morfolojik özellikleri görüntü işleme teknikleri kullanılarak analiz edilebilmektedir (Güngörmüş, 2020). Derin öğrenme tabanlı mimariler kullanılarak polen taşıyan bal arılarının sınıflandırılması da yüksek doğruluk oranlarıyla gerçekleştirilmektedir (Baydilli, 2021). Söz konusu teknolojik çözümler, insan gücüne dayalı manuel denetim gereksinimini minimuma indirirken, daha geniş ölçekli ve sürdürülebilir izleme stratejilerine de olanak sağlamaktadır. Bu yaklaşımlar, koloni sağlığının sürekli ve nesnel parametreler üzerinden değerlendirilmesine imkan tanıyarak erken müdahale kapasitesini artırmaktadır. Böylece hastalık yayılımı ve koloni kayıplarına yol açabilecek riskler daha sistematik biçimde yönetilebilmekte ve üretim sürekliliği desteklenmektedir.

2.2. Üretim Tahmini ve Verim Optimizasyonu

Bal üretimi; koloni gücü, bitki örtüsü, mevsimsel değişkenler ve meteorolojik faktörlere bağlı olarak değişkenlik göstermektedir. Ağırlık sensörleri aracılığıyla kovanın günlük veya saatlik ağırlık değişimleri izlenebilmekte ve bal akışı hakkında bilgi elde edilebilmektedir (Zacepins vd., 2017). İklim değişikliğinin koloni performansı üzerindeki etkilerini inceleyen çalışmalar, uzun dönemli kovan ağırlık verilerinin çevresel değişkenlerle birlikte analiz edilmesinin koloni performansı ve üretim dinamiklerinin değerlendirilmesine katkı sağladığını ortaya koymaktadır (Flores vd., 2019). Coğrafi bilgi sistemleri kullanılarak gerçekleştirilen mekansal analizler de bal üretim potansiyelinin değerlendirilmesinde kullanılmaktadır (Arslan vd., 2024). Söz konusu modeller, geçmiş üretim verileri ile iklimsel parametreleri ilişkilendirerek; hem hasat dönemi periyot yönetimi hem de yerleşim alanı optimizasyonu hususunda bilimsel bir karar destek mekanizması kullanılabilmesini sağlamaktadır. Akıllı tarım ve arıcılık mimarileri çerçevesinde geliştirilen bu tür mekanizmalar, veriye dayalı üretim planlamasının başarısı için kritik bir öneme sahiptir (Zhai vd., 2020). Teknolojik araçlar ile ekolojik verilerin senkronizasyonu, modern arıcılığın rekabetçi ve sürdürülebilir yapısını güçlendiren temel bir bileşen haline gelmektedir.

2.3. Davranış Analizi ve Oğul Verme Tahmini

Arıcılıkta sürdürülebilir verimlilik, koloni davranışlarının etkili biçimde takibiyle doğrudan ilişkilidir. Koloni bütünlüğünü tehdit eden oğul verme süreci, işçi arı popülasyonunun azalmasına ve dolayısıyla bal üretim kapasitesinin düşmesine sebep olmaktadır. Bunun önüne

geçebilmek için kovan içi akustik sinyallerin hassas mikrofonlar vasıtasıyla izlenmesi ve kovan titreşimlerinin frekans karakteristiklerinin analizi etkili bir yöntem olarak görülmüştür (Ferrari vd., 2008; Bencsik vd., 2011). Ses analizi temelli çalışmalar, ana arı varlığının veya koloni içi stres durumlarının belirlenebileceğini göstermektedir (Cejrowski vd., 2018). Bu sinyallerden çıkarılan özellikler makine öğrenmesi algoritmalarına girdi olarak verilerek sınıflandırma yapılabilmektedir. Böylece oğul verme eğilimi gibi kritik olaylar önceden tahmin edilebilmekte ve arıcıya erken uyarı sağlanabilmektedir. Bu tür uygulamalar biyolojik davranışların nicel verilere dönüştürülmesi yoluyla arıcılıkta veri temelli yönetim anlayışını güçlendirmektedir.

2.4. Karar Destek Sistemleri ve Entegre Yaklaşımlar

Akıllı arıcılık sistemlerinde sensörlerden elde edilen verilerin anlamlandırılması, karar destek sistemleri üzerinden yürütülmektedir. Hassas hayvancılık ilkeleriyle paralel şekilde, üretim süreçlerinin dijital temsillerinin oluşturulması ve analiz edilmesi, karar verme kalitesini doğrudan artırmaktadır (Norton vd., 2019). Tarım 4.0 kapsamında geliştirilen bu sistemler; veri analitiği ve gelişmiş modelleme yaklaşımları kullanarak üretim süreçlerine yönelik stratejik öngörüler sunmaktadır (Zhai vd., 2020). Arıcıların tecrübe odaklı yaklaşımlarını veri temelli analizlerle destekleyen bu entegrasyon, geleneksel yöntemlerden sürdürülebilir ve teknoloji yoğun üretim modellerine geçişi kolaylaştırmaktadır. Sonuç olarak, dijitalleşen arıcılık faaliyetleri yalnızca verimlilik artışı sağlamakla kalmayıp, ekosistemin korunmasına yönelik daha dirençli ve önleyici bir yönetim anlayışını beraberinde getirmektedir.

3. Sistem Mimarisi ve Veri Altyapısı

Kovan ortamında gerçekleşen biyolojik süreçler, dijital veri analiz katmanının bütünleşik biçimde çalıştığı yapılardır. Bu akıllı sistemler Şekil 2’de görüldüğü üzere veri toplama, veri iletimi, veri işleme ve analitik değerlendirme aşamalarından oluşan çok katmanlı bir yapı çerçevesinde ele alınmaktadır. Hassas hayvancılık uygulamalarında olduğu gibi, üretim süreçlerinin dijital temsillerinin oluşturulması sistem performansının izlenebilirliğini ve yönetilebilirliğini artırmaktadır (Norton vd., 2019). Tarım alanındaki çalışmalarda da veri akışı, karar destek sistemleri ve otomasyon bileşenleri bütünleşik bir altyapı gerektirmektedir (Zhai vd., 2020).

Bu bütünleşik yapı, yalnızca teknik bileşenlerin bir araya getirilmesinden ibaret değildir; aynı zamanda veri akışının sürekliliğini, katmanlar arası uyumu ve sistem ölçeklenebilirliğini sağlayacak biçimde tasarlanmalıdır. Sensörlerden elde edilen ham verinin anlamlı bilgiye dönüştürülmesi, mimarinin her katmanında tanımlı ve planlı süreçler gerektirir. Bu nedenle akıllı arıcılıkta sistem mimarisi, biyolojik değişkenlik ile dijital analiz kapasitesini eş zamanlı

olarak dengeleyen bütüncül bir tasarım yaklaşımını ifade etmektedir. Böyle bir yapı, sürdürülebilir üretim hedefleri doğrultusunda uzun vadeli izleme ve adaptif yönetim imkanı sunmaktadır.

3.1. Veri Toplama Katmanı

Veri toplama katmanı, kovan içi ve çevresel değişkenleri ölçen sensör ağlarından oluşmaktadır. Literatürde en yaygın kullanılan sensörler şunlardır:

- **Sıcaklık ve nem sensörleri:** Koloni birliğinin sürdürülmesi açısından kritik bir parametre olarak değerlendirilmekte olup kovan içi ikliminin izlenmesi amacıyla kullanılmaktadır. Uzaktan izleme sistemleri kapsamında sıcaklık ve nem verilerinin sürekli kaydedilmesi, koloni içi koşulların değerlendirilmesine olanak tanımaktadır (Gil-Lebrero vd., 2017). Sıcaklık değişimleri, özellikle yavru gelişimi ve koloni stabilitesi için belirleyici rol oynamaktadır.
- **Ağırlık sensörleri (load cells):** Kovan ağırlığında meydana gelen periyodik (günlük veya saatlik) değişimler; nektar akışı, stok durumu ve koloni aktivitesine dair dolaylı fakat güvenilir veriler sunar (Zacepins vd., 2017). Uzun vadeli ağırlık verilerinin çevresel değişkenlerle korelasyonu, koloni performansının verimliliğinin nesnel bir şekilde ölçülmesine stratejik katkı sağlamaktadır (Flores vd., 2019).
- **Akustik sensörler:** Kovan içi ses sinyallerinin takibi, başta oğul verme döneminin öngörülmesi olmak üzere kritik koloni süreçlerinin teşhisinde etkili bir yöntemdir (Ferrari vd., 2008). Arıların kanat çırpma frekansları ve iletişim sinyallerindeki değişimleri analiz eden bu teknoloji; oğul hazırlığı, ana arı kaybı veya dış tehditler gibi anomalilerin fiziksel belirtiler henüz oluşmadan tespit edilmesini sağlamaktadır. Düşük güç tüketimine sahip mikrodenetleyici tabanlı gömülü yapılarla entegre edilen bu sistemlerde, enerji verimliliği saha koşullarındaki sürdürülebilirlik açısından temel bir tasarım kriteridir (Neethirajan vd., 2017). Özellikle yüksek veri örnekleme kapasitesi gerektiren akustik sensörlerin kullanımı, enerji bütçesinin optimize edilmesini ve uçta işleme tekniklerinin uygulanmasını daha kritik hale getirmektedir. Bu sayede, koloni ses profilindeki frekans değişimleri gerçek zamanlı olarak analiz edilirken, sistemin toplam güç tüketimi sürdürülebilir seviyelerde tutulabilmektedir.

3.2. İletişim ve Veri Aktarım Altyapısı

Sensörlerden elde edilen verilerin merkezi analiz sistemlerine aktarılması için kablosuz iletişim teknolojileri kullanılmaktadır. Arıcılık faaliyetleri çoğunlukla kırsal alanlarda gerçekleştirildiğinden, düşük güç tüketimli ve uzun menzilli haberleşme çözümleri tercih edilmektedir.

- **Kablosuz Sensör Ağları:** Kırsal bölgelerde konumlandırılan kovanlardan veri toplanması amacıyla düşük güç tüketimli kablosuz iletişim altyapılarından yararlanılmaktadır. Bu sistemler, sensör verilerinin uzaktan izleme ve merkezi değerlendirme süreçlerine aktarılmasına olanak tanımaktadır (Bayir ve Albayrak, 2016). Söz konusu teknolojiler, sahip oldukları yüksek sinyal yayılım yetenekleri ile engebeli arazilerde ve uzak arıcılık bölgelerinde dahi kesintisiz bağlantı altyapısı sunmaktadır.
- **Uzaktan izleme ve veri aktarım sistemleri:** Akıllı arıcılık çerçevesinde tasarlanan sistemlerde, sensörlerden elde edilen veriler çeşitli haberleşme protokolleri vasıtasıyla merkezi birimlere aktarılmaktadır (Zacepins vd., 2016). Söz konusu uzaktan izleme kovanların fiziksel olarak yerinde ve periyodik denetlenmesi zorunluluğunu minimize ederek arıcılık faaliyetlerinde yüksek operasyonel verimlilik sağlamaktadır. Bu teknolojik dönüşüm, arıcılığı geleneksel ve tecrübe odaklı bir uğraş olmaktan çıkarıp veri temelli ve öngörülebilir modern tarım disiplinine dönüştürmektedir. Böylece, iş gücü optimizasyonu sağlanırken koloni yönetimi de daha bilimsel bir temele oturtulmaktadır."
- **Hücrenel veya yerel ağ çözümleri:** Mevcut iletişim altyapısının uygun olduğu bölgelerde hücrenel ağlar veya yerel ağ çözümleri veri aktarımı amacıyla kullanılabilir. İletişim yönteminin seçimi, uygulama alanının fiziksel koşullarına ve veri iletim gereksinimlerine bağlı olarak değişebilmektedir. İletişim altyapısının tasarımında veri sürekliliği ve enerji tüketimi önemli parametreler arasında yer almaktadır (Zacepins vd., 2016). Özellikle zaman serisi formatında toplanan verilerin kesintisiz aktarımı, sonraki analiz süreçlerinin sağlıklı biçimde yürütülmesi açısından önem taşımaktadır.

3.3. Veri İşleme ve Depolama Katmanı

Akıllı arıcılık sistemlerinde üretilen veriler çoğunlukla zaman serisi formatındadır. Bu nedenle veri işleme süreçleri, sürekli veri akışını destekleyecek biçimde tasarlanmaktadır. Tarım 4.0 kapsamında ele alınan karar destek sistemleri, sensör verilerinin uzaktan izlenmesi ve merkezi sistemlerde değerlendirilmesi yaklaşımını benimsemiştir (Zhai vd., 2020). Gerçek zamanlı analiz gerektiren durumlarda, verinin bir kısmı kovan yakınında işlenebilmektedir.

Bu yaklaşım, dağıtık sistem mimarilerinde gecikmeyi azaltmak amacıyla kullanılmaktadır (Zacepins vd., 2016). Görüntü tabanlı davranış analizlerinde ise bilgisayarlı görü teknikleri kullanılarak otomatik değerlendirme yapılabilmektedir (Tu vd., 2016). Derin öğrenme tabanlı hastalık tespit çalışmalarında da veri işleme ve modelleme süreçleri uygulanmaktadır (Metlek ve Kayaalp, 2021).

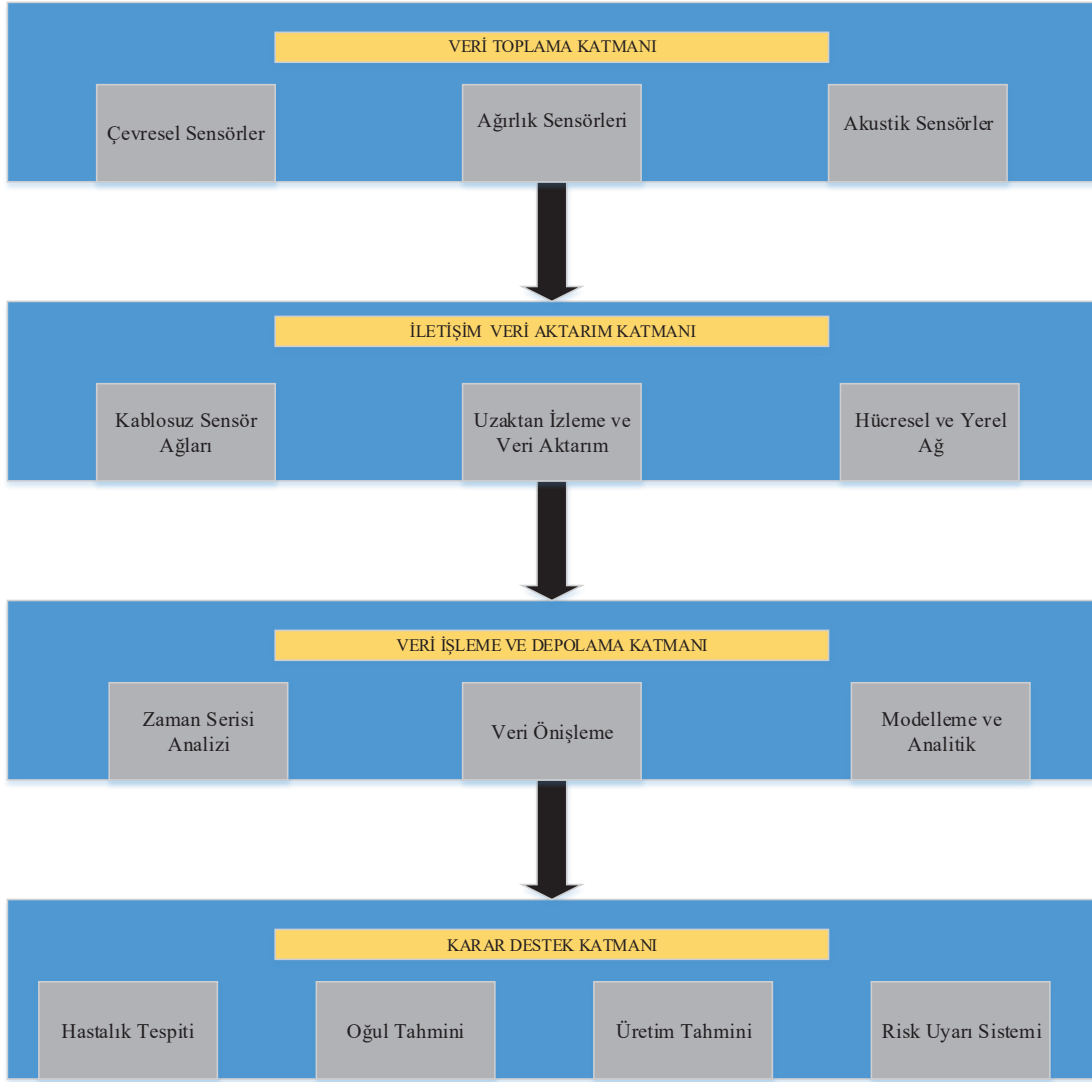
3.4. Akıllı Çıkarım ve Karar Katmanı

Analitik katman, makine öğrenmesi ve derin öğrenme modellerinin çalıştırıldığı sistem bileşenidir. Bu katmanda gerçekleştirilen başlıca işlemler şunlardır:

- **Sınıflandırma algoritmaları:** Hibrit derin öğrenme yöntemleri kullanılarak arı hastalıklarının belirlenebileceği görülmüştür (Metlek ve Kayaalp, 2021).
- **Davranış analizi:** Bilgisayarlı görü temelli sistemlerle bal arısı davranışlarının otomatik analizi gerçekleştirilmektedir (Tu vd., 2016).
- **Zaman serisi değerlendirme:** Kovan ağırlık verilerinin uzun dönemli analizi, çevresel faktörlerle birlikte koloni performansının incelenmesine olanak tanımaktadır (Flores vd., 2019).
- **Akustik analiz:** Ses sinyalleri kullanılarak ana arı varlığı ve oğul süreci gibi durumların belirlenebileceği tespit edilmiştir (Cejrowski vd., 2018; Ferrari vd., 2008).

3.5. Bütünleşik Sistem Mimarisi

Akıllı arıcılık sistemleri, fiziksel kovan ortamı ile dijital analiz katmanı arasında sürekli veri akışı sağlayan siber-fiziksel yapılardır. Hassas hayvancılık sistemlerinde olduğu gibi, dijital temsiller oluşturularak üretim süreçleri daha şeffaf ve kontrol edilebilir hale getirilmektedir (Norton vd., 2019). Bu bütünleşik yapı; sensör füzyonu, dağıtık veri işleme, makine öğrenmesi modelleri ve kullanıcı arayüzlerinden oluşan bir ekosistem gerektirir. Böylece arıcılık faaliyetleri, klasik manuel gözlem yaklaşımından veri odaklı ve algoritmik karar mekanizmalarına dayalı bir yönetim modeline evrilmektedir. Bu analizlerin çıktıları, karar destek sistemleri aracılığıyla kullanıcıya sunulmaktadır. Tarım 4.0 çerçevesinde geliştirilen karar destek sistemleri, veri temelli üretim planlamasının temel araçları arasında yer almaktadır (Zhai vd., 2020). Bu yapı içerisinde veri bütünlüğünün korunması ve sistem katmanları arasındaki uyumun sağlanması, mimarinin etkinliği açısından kritik önem taşımaktadır. Gerçek zamanlı izleme ve geri besleme mekanizmaları, üretim süreçlerinde hızlı ve tutarlı müdahale imkanı sunarak operasyonel esnekliği artırmaktadır. Böylece akıllı arıcılık sistemleri, yalnızca izleme değil aynı zamanda öngörücü ve uyarlanabilir yönetim kapasitesi geliştiren bütünleşik üretim platformlarına dönüşmektedir.

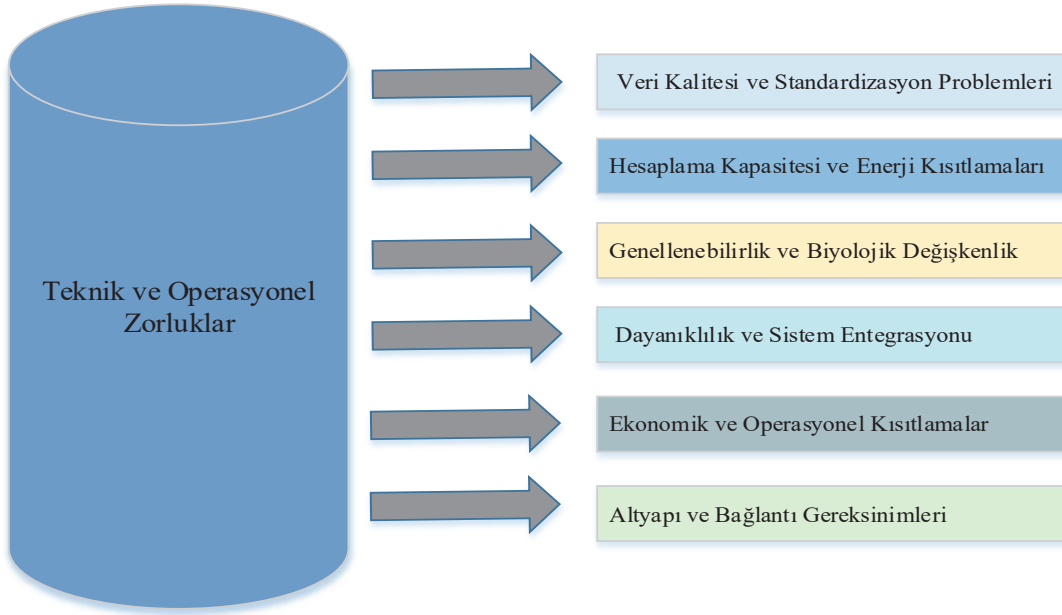


Şekil 2. Akıllı Sistem Mimarisi

4. Teknik ve Operasyonel Zorluklar

Akıllı arıcılıkta yapay zeka ve sensör tabanlı sistemler önemli avantajlar sunmakla birlikte, bu teknolojilerin saha koşullarında sürdürülebilir biçimde uygulanması çeşitli teknik, operasyonel ve yapısal zorlukları beraberinde getirmektedir. Şekil 3'te görüldüğü gibi bu zorluklar yalnızca biyolojik değişkenliğin karmaşıklığından değil; veri mühendisliği, sistem entegrasyonu, donanım dayanıklılığı ve kullanıcı adaptasyonu gibi çok katmanlı faktörlerden kaynaklanmaktadır (Norton vd., 2019; Zhai vd., 2020). Bu zorlukların etkin biçimde yönetilebilmesi, yalnızca teknolojik çözümlerin geliştirilmesine değil, aynı zamanda saha koşullarına uyarlanabilir sistem tasarımlarının oluşturulmasına bağlıdır. Akıllı arıcılık uygulamalarında teknik altyapı ile biyolojik süreçler arasındaki etkileşimin doğru analiz edilmesi, sistem performansının sürdürülebilirliği açısından kritik önem taşımaktadır.

Kullanıcı deneyimi, bakım gereksinimleri ve uzun vadeli operasyonel maliyetler de sistem başarısını belirleyen unsurlar arasında yer almaktadır. Bu nedenle zorlukların bütüncül bir perspektifle değerlendirilmesi, sürdürülebilir ve ölçeklenebilir çözümlerin geliştirilmesini desteklemektedir.



Şekil 3. Teknik ve Operasyonel Zorluklar

4.1. Veri Kalitesi ve Standardizasyon Problemleri

Makine öğrenmesi tabanlı sistemlerin performansı, kullanılan veri setlerinin niteliği ile yakından ilişkilidir. Akıllı arıcılık uygulamalarında sıcaklık, nem ve kovan ağırlığı gibi farklı sensörlerden veri üretilmektedir (Gil-Lebrero vd., 2017; Zacepins vd., 2017). Bu veriler çoğunlukla zaman serisi formatında olup uzun dönemli izleme süreçlerinde kullanılmaktadır (Flores vd., 2019). Akıllı arıcılık yönetim sistemlerinde sensör verilerinin uzaktan iletimi ve merkezi değerlendirilmesi yaklaşımı benimsenmiştir (Zacepins vd., 2016). Ancak saha koşullarında veri sürekliliğinin sağlanması ve farklı sistemlerden elde edilen verilerin bütüncül biçimde değerlendirilmesi belirli teknik gereksinimleri beraberinde getirebilmektedir. Uçtan uca veri akışının optimize edilmesi, karmaşık biyolojik döngülerin dijital ortamdaki temsilini güçlendirerek sistemin kestirimci analiz kabiliyetini artırmaktadır. Derin öğrenme tabanlı hastalık tespit çalışmalarında da veri işleme ve modelleme süreçlerinin performans üzerinde belirleyici olduğu gösterilmiştir (Metlek ve Kayaalp, 2021). Bu

bağlamda, veri bütünlüğünün korunması ve analiz süreçlerinin tutarlılığı, akıllı arıcılık sistemlerinin etkinliği açısından önemli bir unsur olarak değerlendirilmektedir.

4.2. Hesaplama Kapasitesi ve Enerji Kısıtlamaları

Akustik ve görüntü verileri gibi yüksek boyutlu veri türlerinin analizinde, özellikle bilgisayarlı görü ve derin öğrenme temelli yaklaşımlar kullanıldığında belirli bir hesaplama kapasitesine ihtiyaç duyulmaktadır (Tu vd., 2016; Baydilli, 2021). Bu tür uygulamalar, veri işleme süreçlerinin sistem tasarımında önemli bir bileşen haline gelmesine neden olmaktadır. Akıllı arıcılık sistemlerinde sensör verilerinin kablosuz iletişim altyapısı aracılığıyla iletilmesi, kırsal alan koşullarında düşük güç tüketimli çözümlerin tercih edilmesini gerektirmektedir (Bayir ve Albayrak, 2016). Sistem tasarımında işlem kapasitesi ile enerji tüketimi arasında denge kurulması önemli bir mühendislik gereksinimi olarak ortaya çıkmaktadır. Özellikle veri iletim sıklığı ve analiz karmaşıklığı arttıkça sistem kaynaklarının planlanması kritik hale gelmektedir. Enerji tüketimi, özellikle kırsal alanlarda konumlandırılan ve sınırlı güç kaynaklarıyla çalışan akıllı arıcılık sistemlerinde kritik bir tasarım parametresidir. Sensörlerin, iletişim modüllerinin ve veri işleme birimlerinin enerji gereksinimlerinin dengeli biçimde planlanması, sistemin uzun süreli ve kesintisiz çalışabilmesi açısından önem taşımaktadır.

4.3. Genellenebilirlik ve Biyolojik Değişkenlik

Bal arısı kolonileri, çevresel ve genetik faktörlere bağlı olarak değişkenlik göstermekte ve çevresel koşullar ile kovan ağırlığı arasındaki ilişkinin bölgesel farklılıklar gösterebildiği tesbit edilmiştir (Flores vd., 2019). Bu durum, farklı koşullarda toplanan verilerin analizinde dikkatli modelleme yaklaşımlarını gerektirebilmektedir. Görüntü işleme ve derin öğrenme tabanlı hastalık tespit çalışmalarında, model performansının kullanılan veri seti özelliklerine bağlı olduğu gösterilmiştir (Metlek ve Kayaalp, 2021; Güngörmüş, 2020). Bu nedenle veri setinin temsil gücü ve çeşitliliği, model çıktılarının güvenilirliği açısından önemli bir faktör olarak değerlendirilmektedir. Makine öğrenmesi uygulamalarında sınırlı veri kümeleri ile çalışılması durumunda modelin eğitim verisine aşırı uyum göstermesi riski ortaya çıkabilmektedir. Bu yüzden çeşitli ve yeterli sayıda örnek içeren veri setleri, modelin genellenebilirliğini ve performans tutarlılığını artıran temel unsurlar arasında yer almaktadır. Veri seti çeşitliliği ile model karmaşıklığı arasındaki dengenin titizlikle kurulması, tahminleme süreçlerinde hata payını minimize ederek sistemin operasyonel güvenilirliğini artırmaktadır.

4.4. Dayanıklılık ve Sistem Entegrasyonu

Akıllı arıcılık sistemleri; sensörler, mikrodenetleyiciler, iletişim modülleri ve yazılım bileşenlerinden oluşan çok katmanlı yapılardır. Bu bileşenlerin saha koşullarında güvenilir ve kesintisiz biçimde çalışması sistem performansı açısından önem taşımaktadır. Kovan içi sıcaklık ve nem değişimlerinin sürekli izlenmesi gerektiği gösterilmiştir (Gil-Lebrero vd., 2017). Akıllı arılık yönetimi kapsamında farklı sensörlerden elde edilen verilerin uzaktan izleme altyapısı ile bütünleştirildiği sistemler tanımlanmıştır (Zacepins vd., 2016). Bu tür çok bileşenli yapılar, sistem entegrasyonu açısından dikkatli tasarım gerektirmektedir. Hassas hayvancılık uygulamalarında da üretim süreçlerinin dijital temsillerinin oluşturulması ve sistem bileşenlerinin uyumlu biçimde çalışması önemli tasarım kriterleri arasında yer almaktadır (Norton vd., 2019). Bu bütünleşik yapı, biyolojik değişkenlerin dijital ortamda gerçek zamanlı analizine imkan tanıyarak üretim süreçlerinde tam bir denetlenebilirlik ve şeffaflık sağlamaktadır. Bu sayede, operasyonel riskler asgari düzeye indirilmekte ve kaynakların en yüksek verimlilikle kullanıldığı sürdürülebilir bir yönetim modeli ortaya konulmaktadır. Böylece, teknolojik altyapı ile biyolojik sürecin uyumu, arıcılık faaliyetlerini veriye dayalı bir disipline dönüştürerek modern tarım uygulamalarının sunduğu stratejik avantajları sahaya yansıtmaktadır. Bu yaklaşım, ekosistemin korunması ile üretim hedefleri arasında teknoloji temelli güçlü bir köprü kurmaktadır.

4.5. Ekonomik ve Operasyonel Kısıtlamalar

Akıllı kovan sistemlerinin kurulumu; sensör donanımı, veri iletim altyapısı ve yazılım bileşenleri gerektirmektedir. Arıcılık sektöründe ekonomik yapı ve maliyet bileşenleri üretim süreçlerini doğrudan etkilemektedir (Aksoy vd., 2022). Bu çerçevede, ilave teknolojik yatırımların özellikle küçük ölçekli işletmeler açısından dikkatli planlanması gerekmektedir. Sistemlerin etkin biçimde kullanılabilmesi, kullanıcıların teknik altyapıyı anlayabilmesi ve elde edilen verileri yorumlayabilmesi ile ilişkilidir. Akıllı kovan uygulamalarında sistem tasarımı ve kullanıcı etkileşimi önemli bir unsur olarak değerlendirilmektedir (Koçak vd., 2019). Bu nedenle teknoloji kabulü ve kullanıcı eğitimi, sistem performansını etkileyen faktörler arasında yer almaktadır. Bununla birlikte, yatırım maliyetleri ile sağlanan operasyonel faydalar arasındaki dengenin doğru kurulması, sistemlerin uzun vadeli sürdürülebilirliği açısından belirleyici bir unsurdur. Ölçeklenebilir ve modüler tasarım yaklaşımları, farklı büyüklükteki işletmelerin teknolojik dönüşüm sürecine daha erişilebilir biçimde dahil olmasını destekleyebilir.

4.6. Altyapı ve Bağlantı Gereksinimleri

Akıllı arıcılık sistemlerinin büyük bölümü kırsal alanlarda konumlandırılmaktadır. Bu alanlarda internet erişimi ve enerji sürekliliği sınırlı olabilmektedir. Uzun menzilli ve düşük güç tüketimli kablosuz sensör ağı çözümleri, kırsal ortamlarda veri iletimini mümkün kılmaktadır (Bayir ve Albayrak, 2016). Bununla birlikte bağlantı kesintileri veri akışının sürekliliğini etkileyebilmektedir. Veri iletiminde yaşanabilecek gecikmeler, özellikle sürekli izleme gerektiren uygulamalarda analiz süreçlerinin etkinliğini azaltabilmektedir. Bu nedenle iletişim altyapısının tasarımında veri sürekliliğini destekleyen ve kesintilere karşı dayanıklılığı artıran teknik yaklaşımların dikkate alınması önem taşımaktadır. Bunun yanı sıra, enerji yönetimi stratejilerinin etkin biçimde planlanması ve yenilenebilir enerji çözümlerinin sisteme entegre edilmesi, kırsal koşullarda operasyonel sürekliliği destekleyebilir. Altyapı tasarımında esneklik ve modülerlik yaklaşımının benimsenmesi ise farklı coğrafi ve çevresel koşullara uyum sağlama kapasitesini artırarak sistem dayanıklılığını güçlendirmektedir.

5. Stratejik Öngörüler

Akıllı arıcılıkta yapay zeka uygulamaları, mevcut izleme ve tahmin sistemlerinin ötesine geçerek daha entegre, otonom ve adaptif üretim modellerine doğru evrilmektedir. Bu dönüşüm; siber-fiziksel sistemler, dijital temsiller, dağıtık veri işleme altyapıları ve gelişmiş karar destek mekanizmaları ile desteklenmektedir (Norton vd., 2019; Zhai vd., 2020). Gelecekte arıcılık sistemlerinin yalnızca veri toplayan değil, aynı zamanda veriyi yorumlayan ve eyleme dönüştüren akıllı üretim birimlerine dönüşmesi beklenmektedir. Çoklu sensör verilerinin bütünleşik analizine dayalı sistem mimarileri, koloni dinamiklerinin daha bütüncül biçimde anlaşılmasına katkı sağlayacaktır. Veri temelli yaklaşımların yaygınlaşması, üretim planlamasında belirsizliğin azaltılmasına ve kaynak kullanımının daha etkin yönetilmesine imkan tanıyabilir. İklim değişikliği ve çevresel dalgalanmalar karşısında uyarlanabilir sistemlerin geliştirilmesi, arıcılık sektörünün dayanıklılığını artıran stratejik bir unsur olarak değerlendirilmektedir. Veri paylaşım ekosistemlerinin geliştirilmesi ve farklı sistemler arasında birlikte çalışabilirliğin sağlanması, akıllı arıcılık uygulamalarının yaygınlaşmasında belirleyici bir rol oynayacaktır. Disiplinlerarası iş birlikleriyle desteklenen bütünleşik mimari yaklaşımlar, hem teknolojik inovasyonu hızlandıracak hem de sürdürülebilir üretim hedeflerine daha güçlü katkı sunacaktır.

5.1. Dijital Modelleme Yaklaşımı

Entegre sistem mimarileri, fiziksel üretim ortamı ile dijital analiz katmanının veri alışverişi içerisinde olduğu bütünleşik yapılar olarak değerlendirilmektedir. Hassas hayvancılık literatüründe üretim süreçlerinin dijital temsiller üzerinden modellenmesi, sistem performansının daha şeffaf ve izlenebilir hale gelmesini sağlamaktadır (Norton vd., 2019). Benzer şekilde akıllı arıcılıkta da kovan; sensörler, gömülü işlem birimleri, iletişim altyapısı ve analitik yazılımlardan oluşan entegre bir yapı olarak ele alınmaktadır. Uzun dönemli kovan ağırlık verilerinin çevresel parametrelerle birlikte analiz edilmesi, koloni performansının değerlendirilmesine katkı sağlamaktadır (Flores vd., 2019). Akustik ve titreşim verileri ise koloni içi davranış örüntülerinin incelenmesine imkan tanımaktadır (Ferrari vd., 2008; Bencsik vd., 2011). Bu çoklu veri kaynaklarının bütünleşik biçimde değerlendirilmesi, daha gelişmiş dijital modelleme yaklaşımlarının geliştirilmesine zemin hazırlayabilir. Bu çerçevede dijital modelleme yaklaşımı, farklı çevresel koşullar altında üretim süreçlerinin analiz edilmesine ve risk değerlendirmelerinin yapılmasına olanak sağlayan bir araç olarak öne çıkmaktadır.

5.2. Yapay Zeka Destekli Karar Destek ve Otonom Sistemler

Yapay zeka tabanlı analiz yöntemleri, karar destek sistemlerinin kapsamını genişleterek arıcılıkta veri odaklı bir yönetim anlayışının gelişmesine katkı sağlamaktadır. Görüntü işleme temelli hastalık tespit sistemleri (Metlek ve Kayaalp, 2021; Baydilli, 2021) ve akustik analiz yaklaşımları (Cejrowski vd., 2018), koloni durumunun otomatik ve nesnel biçimde değerlendirilmesini mümkün kılmaktadır. Uzun dönemli kovan ağırlık verilerinin analizi ise üretim dinamiklerinin ve bal akışının zamansal olarak izlenmesine olanak tanımaktadır (Zacepins vd., 2017; Flores vd., 2019). Tarım 4.0 çerçevesinde geliştirilen bu sistemler, insan kararlarını destekleyen veri temelli öneriler sunarak karar kalitesini artırmakta ve insan-makine etkileşimini güçlendirmektedir. Bu ilerleyen teknoloji ile gelecekte uyarlanabilir algoritmaların entegrasyonu ile çevresel değişkenlere duyarlı ve daha hızlı müdahale edebilen üretim modellerinin geliştirilmesi mümkün görünmektedir.

5.3. Güvenilirlik, Açıklanabilirlik ve Standartlaşma

Yapay zeka sistemlerinin yaygınlaşması, model güvenilirliği ve açıklanabilirlik kavramlarını akademik ve pratik düzlemde ön plana çıkarmaktadır. Arıcılıkta yapay zeka uygulamalarının başarısı, üretilen çıktıların kullanıcı tarafından anlaşılabilir ve yorumlanabilir olmasıyla doğrudan ilişkilidir (Güler, 2023). Bu doğrultuda; karar destek sistemlerinde performans değerlendirme ve doğrulama süreçleri, sistem tasarımının temel taşlarını oluşturmaktadır (Zhai vd., 2020). Model güvenilirliği; yalnızca yüksek doğruluk oranlarıyla değil, aynı

zamanda sistemin tutarlılığı ve kullanıcı nezdinde yarattığı güven ekseninde de ele alınmalıdır. Akıllı arıcılık sistemlerinin sürdürülebilir bir ekosistem haline gelmesi, teknik bileşenlerin ortaklaşa çalışabilmesine bağlıdır. Sensör ağları, veri analitiği altyapıları ve yazılım modüllerinin senkronize çalışabilmesi için standartlaşma stratejik bir gereksinimdir (Zacepins vd., 2016). Ortak veri yapılarının ve sistem standartlarının geliştirilmesi, farklı teknolojik çözümlerin birbiriyle uyumlu biçimde entegre edilmesini kolaylaştırarak sistemin genel güvenilirliğini artırmaya yarayacaktır.

6. Sonuç

Bu bölüm, yapay zeka tabanlı teknolojilerin sürdürülebilir arıcılık hedefleri doğrultusunda sistem mimarisi ve metodolojik yaklaşımlar çerçevesindeki rolünü analiz etmektedir. Sensör ağları, gömülü sistemler ve makine öğrenmesi algoritmalarının entegrasyonu; geleneksel arıcılık faaliyetlerini sürekli izlenebilir, dinamik olarak modellenebilir ve operasyonel düzeyde optimize edilebilir akıllı bir ekosisteme dönüştürmektedir. Bu dönüşüm, arıcılığı yalnızca biyolojik üretim pratiği olmaktan çıkararak siber-fiziksel sistem yaklaşımıyla ele alınan disiplinlerarası bir mühendislik problemine dönüştürmektedir. Koloni sağlığının izlenmesi, hastalıkların erken tespiti, üretim tahmini ve davranış analizi gibi alanlarda geliştirilen yapay zeka modelleri, karar destek mekanizmalarının doğruluğunu artırmakta ve müdahalenin zamanlamasını iyileştirmektedir. Özellikle zaman serisi analizleri, görüntü işleme teknikleri ve akustik sinyal işleme yöntemleri, koloni dinamiklerinin nicel olarak değerlendirilmesini mümkün kılmaktadır. Bu sayede geleneksel yöntemler yerini, risklerin daha önceden analiz edildiği önleyici bir stratejik yapıya bırakmaktadır. Bununla birlikte sistem başarısı yalnızca algoritmik doğruluğa bağlı değildir. Veri kalitesi, altyapı güvenilirliği, donanım dayanıklılığı, model genellenebilirliği ve kullanıcı adaptasyonu gibi faktörler teknolojinin sahadaki etkinliğini belirlemektedir. Bu nedenle akıllı arıcılık sistemlerinin tasarımında bütüncül bir yaklaşım benimsenmeli; biyolojik değişkenlik, çevresel koşullar ve ekonomik sürdürülebilirlik birlikte değerlendirilmelidir. Gelecekte dijital modelleme yaklaşımlarının geliştirilmesi, çoklu sensör verilerinin entegre analizine dayalı karar sistemlerinin yaygınlaşması ve açıklanabilir yapay zeka çözümlerinin uygulanması, arıcılıkta daha güvenilir ve adaptif üretim modellerinin ortaya çıkmasını sağlayacaktır. Dijitalleşen arıcılık ekosistemi, modern tarımın teknolojik vizyonu ile sürdürülebilirlik hedeflerini bütünleştirerek sektörü çevresel baskılar karşısında daha dirençli ve bilimsel temelli bir üretim yapısına dönüştürmektedir. Bu dijital dönüşüm, ekonomik verimlilik ile çevresel sürdürülebilirliği eş zamanlı olarak birleştirerek akıllı arıcılıkta daha dayanıklı ve veri temelli bir üretim yaklaşımının gelişimine katkı sunacaktır.

KAYNAKLAR

- Aksoy, A., Özbek, E., & Özdemir, F. N. (2022). Türkiye'de gezginci arıcılık sektörüne ekonomik bir bakış. *Turkish Journal of Agricultural and Natural Sciences*, 9(4), 1051-1061.
- Arslan, E., Bayir, T., & İnal, Ş. (2024). Examining honey production with Geographic Information Systems (GIS): The example of Ordu province. *Journal of Advances in VetBio Science and Techniques*, 9(1), 50–58. <https://doi.org/10.31797/vetbio.1403373>
- Baydilli, Y. Y. (2021). Polen taşıyan bal arılarının mobilenetv2 mimarisini ile sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (21), 527-533.
- Bayir, R., & Albayrak, A. (2016). The monitoring of nectar flow period of honey bees using wireless sensor networks. *International Journal of Distributed Sensor Networks*, 12(11). <https://doi.org/10.1177/1550147716678003>
- Bencsik, M., Bencsik, J., Baxter, M., Lucian, A., Romieu, J., & Millet, M. (2011). Identification of the honey bee swarming process by analysing the time course of hive vibrations. *Computers and Electronics in Agriculture*, 76(1), 44–50. <https://doi.org/10.1016/j.compag.2011.01.004>
- Bromenshenk, J. J., Henderson, C. B., Seccomb, R. A., Welch, P. M., Debnam, S. E., & Firth, D. R. (2015). Bees as biosensors: Chemosensory ability, honey bee monitoring systems, and emergent sensor technologies derived from the pollinator syndrome. *Biosensors*, 5(4), 678–711. <https://doi.org/10.3390/bios5040678>
- Cejrowski, T., Szymański, J., Mora, H., & Gil, D. (2018, February). Detection of the bee queen presence using sound analysis. In *Asian conference on intelligent information and database systems* (pp. 297-306). Cham: Springer International Publishing.
- Ferrari, S., Silva, M., Guarino, M., & Berckmans, D. (2008). Monitoring of swarming sounds in bee hives for early detection of the swarming period. *Computers and Electronics in Agriculture*, 64(1), 72–77. <https://doi.org/10.1016/j.compag.2008.05.010>
- Flores, J. M., Gil-Lebrero, S., Gámiz, V., Rodríguez, M. I., Ortiz, M. A., & Quiles, F. J. (2019). Effect of climate change on honey bee colonies in a temperate Mediterranean zone assessed through remote hive weight monitoring system in conjunction with exhaustive colonies assessment. *Science of the Total Environment*, 653, 1111–1119. <https://doi.org/10.1016/j.scitotenv.2018.11.004>
- Gil-Lebrero, S., Quiles-Latorre, F. J., Ortiz-López, M., Sánchez-Ruiz, V., Gámiz-López, V., & Luna-Rodríguez, J. J. (2017). Honey bee colonies remote monitoring system. *Sensors*, 17(1), 55. <https://doi.org/10.3390/s17010055>
- Güler, D. (2023). Arıcılıkta Yapay Zeka Uygulamaları. *Ankara International Congress on Scientific Research-IX*. 26-29 December 2023, pp 1062-1072, Ankara, Türkiye.
- Güngörmüş, A. (2020). Görüntü işleme teknikleri kullanarak petek üzerindeki arı larvasının konumunun ve özelliklerinin tespiti (Yüksek lisans tezi). Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü.

- Koçak, Ç., Işık, A. H., & Köse, U. (2019). Ortam Zekası Örneği: Akıllı Arı Kovanı. Uluslararası Mühendislikte Yapay Zeka ve Uygulamalı Matematik Konferansı, 20-22.
- Metlek, S., & Kayaalp, K. (2021). Detection of bee diseases with a hybrid deep learning method. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(3), 1715–1731. <https://doi.org/10.17341/gazimmfd.749443>
- Neethirajan, S., Tuteja, S. K., Huang, S. T., & Kelton, D. (2017). Recent advancement in biosensors technology for animal and livestock health management. *Biosensors and Bioelectronics*, 98, 398–407. <https://doi.org/10.1016/j.bios.2017.07.015>
- Norton, T., Chen, C., Larsen, M. L. V., & Berckmans, D. (2019). Precision livestock farming: Building digital representations to bring the animals closer to the farmer. *Animal*, 13(12), 3009–3017. <https://doi.org/10.1017/S175173111900199X>
- Tu, G. J., Hansen, M. K., Kryger, P., & Ahrendt, P. (2016). Automatic behaviour analysis system for honeybees using computer vision. *Computers and Electronics in Agriculture*, 122, 10–18. <https://doi.org/10.1016/j.compag.2016.01.011>
- Zacepins, A., Kvišis, A., Ahrendt, P., Richter, U., Tekin, S., & Durgun, M. (2016). Beekeeping in the future—Smart apiary management. In *Proceedings of the 17th International Carpathian Control Conference (ICCC)* (pp. 808–812). <https://doi.org/10.1109/CarpathianCC.2016.7501207>
- Zacepins, A., Pecka, A., Osadcuks, V., Kvišis, A., & Engel, S. (2017). Solution for automated bee colony weight monitoring. *Agronomy Research*, 15(2), 585–593.
- Zhai, Z., Martínez, J. F., Beltran, V., & 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

UZAMSAL VE KANAL ATTENTION MEKANİZMALARI İLE SAHTE GÖRÜNTÜ ALGILAMA

Engin OĞUZAY¹, Gökhan UÇKAN²

¹ Department of Computer Programming, Maltepe University, Istanbul, Türkiye (ORCID: (0000-0003-2030-2981), enginoguzay@maltepe.edu.tr,

² Department of Computer Engineering, Pamukkale University, Denizli, Türkiye (ORCID:0009-0004-7938-0401),guckan@pau.edu.tr

1. Giriş

DeepFake teknolojisinin oluşturduğu tehlikeler arasında politik manipülasyon, finansal dolandırıcılık, kişisel itibar zedelenmesi ve medya güvenilirliğinin sarsılması yer almaktadır. Örneğin 2019 yılında bir İngiliz enerji şirketinin CEO'sunun sesini taklit ederek 243.000 Euro'luk bir dolandırıcılık gerçekleştirilmiştir (World Economic Forum, 2023). Bireylerin yüzleri pornografik içeriklere yerleştirilerek, kişisel ve profesyonel hayatları ciddi şekilde zarar görebilmektedir. “Bu gerçekten oldu mu?” sorusunun sürekli sorulduğu bir ortamda, gerçek haberler bile şüpheyile karşılanabilir, bu da toplumun medyaya olan güvenini derinden sarsabilir. World Economic Forum'un 2023 raporuna göre, DeepFake'ler dijital güvenliğe yönelik en ciddi 10 tehdit arasında yer almaktadır (World Economic Forum, 2023). Interpol ve Europol gibi uluslararası güvenlik kuruluşları, DeepFake tespiti için özel birimler kurmuş ve bu konudaki kapasite geliştirme çalışmalarına önemli kaynaklar ayırmaktadır.

DeepFake teknolojisi, 2017 yılından bu yana hızlı bir gelişim göstermiştir. 2017'de Reddit'te ilk defa “DeepFake” terimi kullanılmaya başlandı ve basit yüz değiştirme algoritmaları ortaya çıktı. 2018'de NVIDIA'nın StyleGAN modeli, tamamen gerçekçi olmayan yüzler üretmeye başladı (Karras, 2019). 2019'da StyleGAN2, yüz üretimindeki artifactları önemli ölçüde azalttı (Karras., 2020). 2020'de DeepFake uygulamaları mobil cihazlara taşındı, herkesin erişebileceği uygulamalar ortaya çıktı (Afchar, 2018). 2021'de StyleGAN3 ve DALL-E gibi modeller, son derece gerçekçi ve çeşitli içerikler üretebilmeye başladı (Karras., 2021). 2022-2023 yıllarında ise Diffusion modelleri (Stable Diffusion, Midjourney) sahne oluşturma kabiliyetlerine sahip DeepFake'ler üretebilir hale geldi. Her ne kadar bu makaledeki yöntemimiz fotoğraf tabanlı DeepFake tespitine odaklansa da, bu yeni nesil teknolojilerin hızla geliştiği unutulmamalı ve gelecekte daha karmaşık sahte içeriklerin de ortaya çıkabileceği göz önünde bulundurulmalıdır.

DeepFake tespitinde karşılaşılan temel zorluklar arasında hızla gelişen üretim teknolojileri, görüntü kalitesi varyasyonları, işlem yükü, gerçek zamanlı tespit ihtiyacı ve veri kümesi dengesizliği bulunmaktadır. DeepFake üretim teknolojileri, tespit yöntemlerinden daha hızlı gelişmektedir. Tespit algoritmaları belirli artifactlara odaklanırken, yeni üretim modelleri bu artifactları ortadan kaldırmaktadır. Sosyal medyada paylaşılan içerikler genellikle sıkıştırılmakta veya yeniden boyutlandırılmaktadır. Bu durum, tespit algoritmalarının performansını önemli ölçüde düşürmektedir. Milyonlarca içeriğin yüklendiği sosyal medya platformlarında, tüm içerikleri gerçek zamanlı olarak analiz etmek büyük işlem gücü

gerektirmektedir. Eğitim için kullanılan veri kümeleri genellikle belirli GAN modellerine odaklanmakta, bu da modellerin yeni teknolojilere genelleme yapma yeteneğini sınırlamaktadır.

Mevcut DeepFake tespit yöntemleri çeşitli kategorilere ayrılabilir. Konvolüsyonel Sinir Ağları (CNN) tabanlı yöntemler (Rossler, 2019; Afchar, 2018; Dang, 2020; Güera & Delp, 2018), frekans analizi yaklaşımları (Li., 2020; Dzanic & Witherden, 2020; Frank., 2020), biyolojik işaret temelli yöntemler (Li, 2018; Ciftci, 2020) ve çok modlu/attention ağırlıklı modeller (Zhao, 2021; Haliassos., 2021; Wang, 2022) bunlardan bazılarıdır. Mevcut yöntemlerin çoğu, ya mekansal ya da frekans domainindeki özelliklere odaklanmakta, her iki domainin güçlü yanlarını birleştiren entegre bir yaklaşım sunmamaktadır. Ayrıca, çoğu model statik bir öğrenme paradigması kullanmakta, kademeli olarak öğrenme stratejisinden faydalanmamaktadır.

Geliştirdiğimiz DeepFake tespit modeli, mevcut çözümlerin sınırlamalarını aşarak, literatüre özgün katkılar sunmaktadır. Modelimiz ayrıca kademeli backbone fine-tuning stratejisi ile backbone mimarisinin özellik çıkarma kabiliyetini aşamalı olarak genişleten, aşırı öğrenmeyi engelleyen ve geçici yerel minimumlara takılmayı önleyen yenilikçi bir eğitim yaklaşımı sunmaktadır. Özel DeepFake augmentasyon teknikleri (JPEG sıkıştırma simülasyonu, GAN artifactlarını taklit eden 8x8 blok manipülasyonları, gürültü ekleme vb.) ile DeepFake üretim sürecini taklit eden veri artırma yöntemleri kullanılmıştır. Attention-guided pooling mekanizması sayesinde görüntünün en bilgilendirici bölgelerine odaklanan, self-attention tabanlı global pooling stratejisi uygulanmıştır (Zhao, 2021; Vaswani, 2017). Bu yaklaşım, modelin ayırt edici özelliklere konsantre olmasını sağlayarak tespit doğruluğunu artırmaktadır.

Modelimizin sunduğu katkılar literatürdeki benzer çalışmalarla karşılaştırıldığında önemli ilerlemeler göstermektedir. Örneğin, Li. (2020) tarafından önerilen F³-Net, frekans özellikleri kullanarak %70 civarında doğruluk elde etmiştir. Bizim modelimiz bu yaklaşımı genişleterek %88'e varan doğruluk sunmaktadır. Qian. (2020) CNN ve RNN birleşimi ile %75 doğruluk elde etmiştir. Modelimiz, daha yenilikçi bir CNN mimarisi ve spektral analizin güçlü yanlarını birleştirerek ciddi bir performans artışı sağlamıştır. Wang . (2022) ise spektral ve mekansal özellikleri kullanan bir yaklaşım önermiş, ancak derin özellik çıkarma konusunda sınırlı kalmıştır. Modelimiz, ConvNeXt backbone ile daha derin özellik çıkarımı yaparak ve self-attention mekanizmasıyla güçlendirilerek bu sınırlamaları aşmaktadır.

DeepFake teknolojilerine karşı etkili tespit sistemleri, ulusal ve uluslararası güvenlik, medya güvenilirliği ve demokratik süreçlerin korunması açısından kritik öneme sahiptir. Modelimiz %88 doğruluk oranı ve 0.95 ROC AUC değeri ile DeepFake tespiti alanında üst düzey bir performans sergilemektedir. Sosyal medya platformları, haber kuruluşları ve dijital içerik doğrulama servisleri gibi kurumların ihtiyaç duyduğu yüksek doğruluklu tespit sistemleri arasında rekabet edebilecek niteliktedir. Dezenformasyon ve manipülasyona karşı koruma sağlayan modelimiz, ulusal güvenlik stratejilerinin önemli bir bileşeni olabilir.

2. İlgili Çalışmalar

DeepFake tespit yöntemleri, üretken modellerin gelişimiyle paralel olarak ilerlemektedir. Bu bölümde, literatürdeki DeepFake tespit çalışmalarını dört ana kategoride inceleyeceğiz: 1) CNN tabanlı yöntemler, 2) Frekans analizi yaklaşımları, 3) Çok modlu ve biyolojik işaret temelli yöntemler, 4) Attention mekanizmalarını kullanan çalışmalar. Son olarak, mevcut yaklaşımların sınırlamalarını ve modelimizin nasıl bu sınırlamaları aştığı belirtilecektir.

2.1. CNN Tabanlı DeepFake Tespit Yöntemleri

DeepFake tespitinde konvolüsyonel sinir ağları (CNN), özellikle görüntülerin mekansal özelliklerinin analizi açısından yaygın olarak kullanılmaktadır. Bu alandaki önemli çalışmalar şunlardır:

Rosler (2019) FaceForensics++ veri setini oluşturarak, XceptionNet gibi CNN mimarilerinin manipüle edilmiş yüzleri tespit etmekteki etkinliğini incelemiştir. XceptionNet, sıkıştırılmamış görüntülerde %95'in üzerinde doğruluk sağlarken, yüksek sıkıştırma oranlarında bu oran %70-75'e düşmektedir. Bu çalışma, görüntü kalitesinin tespit performansı üzerindeki etkisini vurgulamaktadır.

Afchar (2018) Meso-4 adını verdikleri, mesoskopik özelliklere odaklanan daha kompakt bir CNN mimarisi önermişlerdir. Bu model, yüz manipülasyonu tespitinde %98'e varan doğruluk elde etmiştir, ancak genelleme kabiliyeti sınırlıdır ve farklı türdeki DeepFake'ler için performansı düşmektedir.

Dang (2020) daha derin bir mimari olan EfficientNet'i kullanarak hem yüz hem de ses manipülasyonlarını tespit eden çok modlu bir yaklaşım geliştirmiştir. Bu çalışma, çeşitli veri artırma teknikleri ve farklı giriş modaliteleriyle %84 doğruluk elde etmiştir.

Güera ve Delp (2018) CNN ve uzun kısa süreli bellek (LSTM) ağlarını birleştirerek, video dizilerindeki zamansal tutarsızlıkları da tespit eden bir model önermiştir. Bu yaklaşım, tek kare analizine kıyasla daha yüksek doğruluk sağlamıştır.

2.2. Frekans Analizi Tabanlı Tespit Yöntemleri

GAN tabanlı DeepFake'lerin üretim sürecinde oluşan spektral artifactlar, etkili tespit ipuçları sunmaktadır. Frekans domainindeki çalışmalar şunlardır:

Li (2020) F³-Net (Frequency Fusion Net) adlı bir model geliştirerek, hem Discret Cosine Transform (DCT) hem de frekans faz/magnitude analizlerini birleştirmiştir. Bu yaklaşım, özellikle düşük çözünürlüklü ve sıkıştırılmış görüntülerde %70-75 arası doğruluk sunmuştur.

Dzanic ve Witherden (2020) Fourier spektrumu analizi ile GAN üretiminin doğal görüntülerden ayrılabilmesini göstermiştir. Çalışmaları, GAN'ların yüksek frekanslı özellikleri modellemede yetersiz kaldığını ve bu durumun tespit için kullanılabileceğini ortaya koymuştur.

Frank (2020) görüntü frekans spektrumundaki yüksek frekanslı bileşenlerin, DeepFake tespiti için önemli ipuçları taşıdığını göstermiştir. Çalışmalarında, hem azimut hem de radyal frekans bileşenlerini analiz ederek %80 civarında doğruluk elde etmişlerdir.

2.3. Çok Modlu ve Biyolojik İşaret Temelli Yöntemler

DeepFake'lerin üretiminde ortaya çıkan fizyolojik tutarsızlıklar, tespit için değerli bilgiler sunmaktadır:

Li (2018) göz kırpma hareketlerinin analizine dayanan bir yaklaşım önermiştir. DeepFake üretim sürecinde göz kırpma sıklığının doğal görüntülere göre daha düşük olduğunu belirlemişlerdir. Bu yaklaşım basit ve etkili olsa da, günümüz GAN modelleri bu tür fizyolojik hareketleri daha iyi simüle edebilmektedir.

Matern (2019) yüz asimetrisi, renk tutarsızlıkları ve cilt dokusu anomalileri gibi görsel artifactların analizine dayalı bir tespit yöntemi geliştirmiştir. Bu çalışma, görsel artifactların türlerine göre sınıflandırma yaparak %78 doğruluk elde etmiştir.

Ciftci (2020) kan akışı ve nabız sinyallerinden kaynaklanan ince renk değişimlerini analiz eden biyolojik sinyal tabanlı bir tespit yöntemi önermiştir. Bu yaklaşım, özellikle yüksek kaliteli DeepFake'lerde etkili olsa da, sıkıştırılmış görüntülerde performansı düşmektedir.

2.4 Attention Mekanizmaları ve Derin Öğrenme Stratejileri

Son yıllarda attention mekanizmaları, DeepFake tespitinde önemli bir rol oynamaya başlamıştır

Zhao (2021) Multi-attentional DeepFake Detection Network (MADN) adını verdikleri bir mimari önermiştir. Bu yaklaşım, görüntünün farklı bölgelerine farklı önem düzeyleri atayarak, manipülasyon izlerinin daha belirgin olduğu alanlara odaklanmaktadır. MADN, Celeb-DF veri setinde %84 doğruluk elde etmiştir.

Haliassos (2021) transformer temelli bir mimari ile self-attention mekanizmalarını kullanarak, görüntüdeki uzun mesafeli ilişkileri analiz eden bir model sunmuştur. Bu yaklaşım, özellikle yüz manipülasyonlarının tespit edilmesinde %82 doğruluk sağlamıştır.

Wang (2022) görüntü segmentasyonu ile attention mekanizmalarını birleştirerek, manipülasyonun gerçekleştiği bölgeleri lokalize eden bir tespit modeli geliştirmiştir. Bu çalışma hem tespit hem de lokalizasyon yapabilme kabiliyeti sunmaktadır

2.5 Literatürdeki Boşluklar ve Modelin Konumu

Mevcut literatür incelendiğinde, DeepFake tespit çalışmalarında şu sınırlamalar görülmektedir:

1. Domain Odaklı Yaklaşımlar: Çalışmaların çoğu ya mekansal ya da frekans domainini incelemekte, her iki domainin güçlü yanlarını etkili bir şekilde birleştiren bütünleşik bir yaklaşım eksik kalmaktadır.
2. Statik Öğrenme Stratejileri: Mevcut modeller genellikle statik bir fine-tuning yaklaşımı kullanmakta, backbone mimarisinin özellik çıkarma kabiliyetini kademeli olarak geliştiren dinamik stratejiler sunmamaktadır.
3. DeepFake Spesifik Augmentasyon Eksikliği: Çoğu çalışma genel veri artırma teknikleri kullanmakta, DeepFake üretim sürecini ve artifactlarını taklit eden özel augmentasyon tekniklerinden yeterince faydalanmamaktadır.

4. Spektral Analizin Sınırlı Kullanımı: Mevcut frekans temelli yaklaşımlar genellikle ya DCT ya da FFT analizi kullanmakta, her iki analizin farklı güçlü yanlarını birleştiren bir spektral analiz sunmamaktadır.

Modelimiz, yukarıdaki sınırlamaları aşarak literatüre şu katkıları sunmaktadır:

1. Çok Boyutlu Hibrit Analiz: ConvNeXt backbone'unun mekansal analiz gücü ile üç farklı spektral analiz yöntemini (FFT magnitude, FFT faz, DCT) birleştiren bütünleşik bir yaklaşım.
2. Kademeli Fine-Tuning: Backbone mimarisinin özellik çıkarma kabiliyetini aşamalı olarak geliştiren, model performansını kademeli olarak artıran dinamik bir eğitim stratejisi.
3. DeepFake Spesifik Augmentasyon: GAN artifactlarını, JPEG sıkıştırma etkilerini ve blok yapılarını simüle eden, DeepFake üretim sürecine özgü veri artırma teknikleri.
4. Self-Attention Guided Pooling: Görüntünün manipülasyon izlerinin daha belirgin olduğu bölgelerine odaklanan, modelin tespit doğruluğunu artıran attention temelli pooling stratejisi.

Modelimiz, bu özgün katkılar sayesinde %88 test doğruluğu ve 0.95 ROC AUC değeri elde ederek, literatürdeki benzer çalışmalara göre önemli bir performans artışı sağlamıştır.

3. Metodoloji

Bu bölümde, DeepFake fotoğrafları tespit etmek için geliştirdiğimiz modelin nasıl çalıştığını, anlaşılır bir dille anlatılmıştır. Öncelikle kullandığımız veri setini tanıtacak, sonra da modelimizin yapısını, neden bu yapıyı seçtiğimizi ve her bir bileşenin ne işe yaradığını detaylı şekilde anlatılacaktır.

3.1. Veri Seti

Bu çalışmada, 140k Real and Fake Faces adlı veri seti kullanılmıştır. Söz konusu veri seti, iki ana bölümden oluşmaktadır:

- **Gerçek Yüzler:** Flickr platformundan toplanmış 70.000 gerçek insan yüzü
- **Sahte Yüzler:** StyleGAN (Karras., 2019) aracılığıyla üretilmiş 70.000 yapay yüz

Tüm görüntüler 256×256 piksel boyutundadır. StyleGAN ile oluşturulan sahte yüzler, görsel olarak oldukça gerçekçi görünmekle birlikte, üretim sürecinde ortaya çıkan belirli yapısal izler (artifaktlar) barındırır.

Bu çalışmada, Kaggle Notebook ortamının bellek ve işlem gücü kısıtları nedeniyle, her bir kategori (gerçek ve sahte) için eğitim, doğrulama ve test aşamalarında 5.000'er örnekten oluşan bir alt küme kullanılmıştır (yani 2.500 gerçek + 2.500 sahte). Böylece, toplam veri miktarı makul seviyede tutulmuş ve not defterinin çökmesi gibi teknik sorunlar önlenmiştir. Her ne kadar veri setinin tamamı işlenemese de, bu 5.000'lik alt küme ile eğitilen modelimiz %87.94 test doğruluğu, 0.9476 ROC AUC ve 0.8827 F1 skoru elde ederek etkili bir performans sergilemiştir.

İleride, daha güçlü donanım veya farklı platformlar (ör. Google Colab Pro, özel GPU sunucuları vb.) kullanılarak veri setinin tamamının işlenmesi, ayrıca farklı DeepFake veri setleri (GAN veya Diffusion tabanlı) ile ek deneyler planlanmaktadır. Bu sayede modelimizin genelleme kabiliyeti daha kapsamlı biçimde değerlendirilecek ve çok daha yüksek doğruluk oranlarına ulaşma potansiyeli araştırılacaktır.

3.1.1 DeepFake'e Özel Veri Artırma Teknikleri

Modeli eğitirken, orijinal veri setini çeşitlendirmek ve zenginleştirmek için "veri artırma" (data augmentation) teknikleri kullanılmıştır. Bu, modelin farklı senaryolarda daha dayanıklı olmasını sağlar. DeepFake özelindeki yapay görüntülerin kendine has özellikleri olduğundan, bunları tespit etmeye yönelik özel veri artırma teknikleri geliştirdik.

1. **JPEG Sıkıştırma Simülasyonu:** Gerçek hayatta, sosyal medyaya yüklenen görüntüler genellikle JPEG formatında sıkıştırılır. DeepFake görüntüler paylaşılırken genellikle birden fazla kez sıkıştırılır ve bu süreç görüntüye kendine has izler bırakır. Bu işlemi simüle ederek, modelimizin bu izleri tanımasını sağlıyoruz.

```
def jpeg_compression_simulator(image, quality_range=(50, 95)):
    """Farklı JPEG kalite seviyelerinde sıkıştırmayı simüle eder"""
    buffer = BytesIO()
    quality = random.randint(*quality_range)
    image.save(buffer, format="JPEG", quality=quality)
    buffer.seek(0)
    return Image.open(buffer)
```

Şekil 1 : JPEG Sıkıştırma Simülasyonu Ekranı

2. GAN Artifactları Simülasyonu: GAN'lar (DeepFake üretmek için kullanılan sistemler) görüntüleri genellikle 8x8 piksellik bloklarda işler. Bu durum, bazı bloklarda tutarsızlıklara yol açabilir. Bu tutarsızlıkları simüle ederek modelimizin bunları öğrenmesini sağlıyoruz.

```
def simulate_gan_artifacts(image):
    """GAN artifactlarını simüle eder"""
    img_np = np.array(image)
    # 8x8 blokları vurgula (GAN artifactları genellikle bu boyutta olur)
    h, w, c = img_np.shape
    for i in range(0, h, 8):
        for j in range(0, w, 8):
            if random.random() < 0.3: # %30 olasılıkla bazı blokları daha belirgin yap
                for ch in range(c):
                    img_np[i:min(i+8, h), j:min(j+8, w), ch] = np.clip(
                        img_np[i:min(i+8, h), j:min(j+8, w), ch] * random.uniform(0.95, 1.05),
                        0, 255
                    )
    return Image.fromarray(img_np)
```

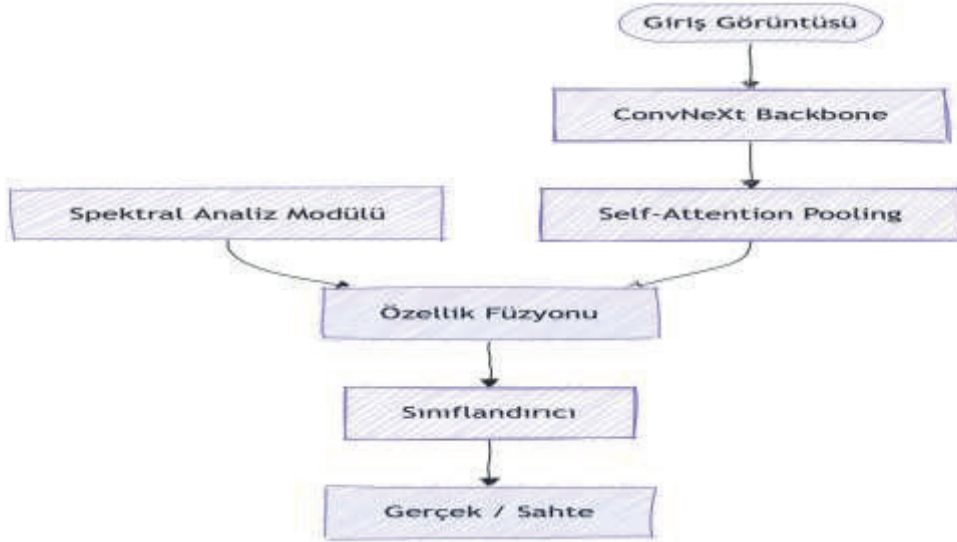
Şekil 2 : GAN Artifactları Simülasyonu Ekranı

3. Gürültü Ekleme: Gerçek dünyada görüntüler hiçbir zaman mükemmel değildir. Her zaman bir miktar gürültü içerirler. Modelimizin bu doğal gürültüyü sahte izlerden ayırt edebilmesi için, eğitim verilerine biraz gürültü ekliyoruz.

Bu teknikler, modelimizin gerçek ve sahte görüntüleri daha iyi ayırt etmesini sağlar, çünkü sahte görüntülerde oluşan izleri taklit ederek modele bu izleri tanımayı öğretilmektedir.

3.2 Model Mimarisi: Parçaları Bir Araya Getirmek

Modelimizin genel yapısı, aşağıdaki şekilde gösterilebilir:



Şekil 3 ; Modelin genel yapısı

3.3 Eğitim Detayları: Modeli Optimize Etmek

Modelimizin eğitimi, çeşitli optimizasyon teknikleri ve hiperparametre ayarları kullanılarak geliştirilmiştir. Bu bölümde, eğitim sürecinde kullanılan optimizör, öğrenme oranı stratejisi ve bunların model performansına etkileri detaylandırılacaktır.

3.3.1 Optimizer ve Learning Rate Stratejisi

Eğitim sürecinde **AdamW** optimizör kullanılmıştır. AdamW, standart Adam optimizörünün **weight decay** (ağırlık azaltma) ile geliştirilmiş bir versiyonudur ve modelin daha iyi genelleme yapmasına yardımcı olur.

Ayrıca, modelin farklı bileşenleri için farklı öğrenme oranları (learning rate) belirlenmiştir. Örneğin, önceden eğitilmiş **backbone** katmanları için daha düşük bir öğrenme oranı, yeni eklenen katmanlar için ise daha yüksek bir öğrenme oranı uygulanmıştır. Bu yaklaşımın kodu şu şekildedir:

```

# Backbone parametreleri ve diğer parametreleri ayrı gruplar olarak alıyoruz
backbone_params = [p for n, p in model.named_parameters() if 'backbone' in n and
p.requires_grad]

other_params = [p for n, p in model.named_parameters() if 'backbone' not in n and
p.requires_grad]

# Farklı parametre grupları için farklı öğrenme oranları tanımlıyoruz
optimizier = torch.optim.AdamW([

    {'params': backbone_params, 'lr': LEARNING_RATE * 0.1, 'weight_decay': 1e-4},

    {'params': other_params, 'lr': LEARNING_RATE, 'weight_decay': 1e-4}

])

```

Şekil 4 : Öğrenme oranı yaklaşım kodu

Öğrenme oranını sabit tutmak yerine, OneCycleLR adı verilen bir scheduler kullanılmıştır. Bu scheduler, eğitim sürecinde öğrenme oranını dinamik olarak ayarlayarak modelin daha hızlı ve etkili öğrenmesini sağlar. İşleyiş prensibi şu şekildedir:

1. **Başlangıç (Warm-up) Aşaması:** Eğitimin ilk %30'unda öğrenme oranı kademeli olarak artırılır. Bu aşama, modelin başlangıçta çok yüksek adımlar atmasını engelleyerek, stabil bir öğrenme süreci başlatır.

2. **Azalma Aşaması:** Eğitim süresinin geri kalanında öğrenme oranı kademeli olarak düşer. Bu, modelin optimum çözüme yaklaşırken daha hassas ve ince ayar yapmasını mümkün kılar.

OneCycleLR, modelin öğrenme oranını **üç aşamalı bir süreçte** yönetir:

1. **Başlangıçta (Epoch 1-3):** Öğrenme oranı kademeli olarak artırılır. Bu, modelin hızlı öğrenmesini sağlar.
2. **Orta aşamalarda (Epoch 4-10):** Öğrenme oranı zirveye ulaşır ve sabit kalır. Modelin en verimli şekilde öğrenmesi sağlanır.
3. **Son aşamada (Epoch 11-15):** Öğrenme oranı düşürülerek modelin daha hassas ince ayar yapması sağlanır.

Bu yaklaşım, modelin daha hızlı öğrenmesini ve daha iyi bir çözüme yakınsamasını sağlar.

- **Backbone Parametreleri:** Bu katmanlar, genellikle önceden eğitilmiş olduğu için çok düşük öğrenme oranlarıyla güncellenir. Bu durum, modelin mevcut bilgilerini korurken ince ayar yapmasına olanak tanır.

- **Diğer Parametreler:** Backbone dışındaki katmanlar, daha yüksek öğrenme oranlarıyla güncellendiği için modelin yeni bilgileri daha hızlı öğrenmesini sağlar.

3.3.2 Mixup Veri Augmentasyonu

Eğitim sürecinde veri çeşitliliğini artırmak, modelin aşırı öğrenmesini önlemek ve genelleme yeteneğini iyileştirmek için **Mixup** tekniğini kullandık. Mixup, iki görüntüyü ve onların etiketlerini belirli bir oranda karıştırarak yeni eğitim örnekleri oluşturur. Bu sayede, model daha dengeli bir öğrenme süreci geçirir ve daha sağlam karar sınırları oluşturur.)

Mixup yöntemi ile oluşturulan veri, modelin daha çeşitli ve gerçek dünya verilerine daha dayanıklı hale gelmesini sağlar. Bu teknik, özellikle etiketler arasındaki geçişleri öğrenmeyi zorlaştırarak daha sağlam bir genelleme sunar.

Mixup uygulanan verinin kaybını hesaplamak için özel bir loss fonksiyonu kullanılır:

```
def mixup_criterion(criterion, pred, y_a, y_b, lam):  
  
    """Mixup için loss hesaplar"""  
  
    return lam * criterion(pred, y_a) + (1 - lam) * criterion(pred, y_b)
```

Şekil 5 : Loss fonksiyonu

Bu loss fonksiyonu, modelin iki farklı etikete kısmen uyum sağlamasını teşvik eder. Böylece model daha esnek hale gelir ve yanlış sınıflandırmalara karşı daha dayanıklı olur.

Mixup tekniğinin model üzerindeki etkilerini şöyle özetleyebiliriz:

- **Daha düzgün karar sınırları:** Model, eğitim sürecinde farklı örneklerin karışımını gördüğünden, karar sınırlarını daha esnek hale getirir.
- **Aşırı öğrenmenin önlenmesi:** Model, sadece belirli bir veri örneğini ezberlemek yerine, genel örüntüleri öğrenmeye odaklanır.

- **Veri çeşitliliğinin artması:** Eğitim sırasında oluşturulan yeni kombinasyonlar sayesinde model daha fazla farklı örnekle karşılaşır.

3.3.3 Eğitim Döngüsü

Modelimizin eğitim döngüsü, yukarıda açıklanan teknikleri bir araya getirerek etkili ve dengeli bir eğitim süreci sunar. Eğitim sürecinde kademeli fine-tuning, Mixup veri augmentasyonu, öğrenme oranı planlaması (scheduler), gradient clipping ve erken durdurma (early stopping) gibi çeşitli optimizasyon teknikleri uygulanmıştır.

Mantığını anlamak için algoritmanın çalışma mantığı eğitim döngüsü, modelin parametrelerini güncellemek ve eğitim verisi üzerinden en iyi performansı elde etmek için aşağıdaki adımları takip eder:

1. Kademeli Fine-Tuning (Opsiyonel)

- Eğer **kademeli fine-tuning** kullanılıyorsa, modelin belirli katmanları her epoch'ta açılarak eğitime dahil edilir. Bu, transfer öğrenmede yaygın bir stratejidir ve modelin önceden öğrenilmiş özellikleri kaybetmeden yeni verilere adapte olmasını sağlar.

2. Modeli Eğitim Moduna Alma

- PyTorch modelleri `train()` metoduyla eğitim moduna geçirilir. Bu, dropout veya batch normalization gibi katmanların aktif hale gelmesini sağlar.

3. Verilerin İşlenmesi ve Mixup Uygulaması

- Her batch'teki veriler GPU/CPU'ya yüklenir.
- Eğer **Mixup veri augmentasyonu** etkinse, batch içindeki veriler belirli oranlarda karıştırılarak modelin daha genel karar sınırları öğrenmesi sağlanır.

4. İleri Geçiş (Forward Propagation)

- Karıştırılmış veya normal veri modele verilir ve modelin çıktıları hesaplanır.

5. Kayıp (Loss) Hesaplama

- Mixup kullanılıyorsa, tahmin edilen değerler ile iki farklı etiketin kombinasyonuna göre loss hesaplanır.
- Normal eğitimde olduğu gibi, tahmin edilen değerlerle gerçek etiketler arasındaki fark loss fonksiyonu ile ölçülür.

6. Geri Yayılım (Backward Propagation) ve Gradyan Güncelleme

- `loss.backward()` çağrılarak hata sinyali geriye doğru yayılır.
- **Gradient clipping** uygulanarak gradyanların belirli bir maksimum değer üzerinde büyümesi engellenir. Bu, özellikle büyük modellerde eğitimin stabil kalmasına yardımcı olur.

7. Optimizasyon Adımı

- `optimizer.step()` ile model parametreleri güncellenir.
- `scheduler.step()` ile öğrenme oranı planlanır. Örneğin, **OneCycleLR** kullanılıyorsa, belirlenen öğrenme oranı eğitimin farklı aşamalarına göre dinamik olarak değiştirilir.

8. Doğrulama ve Modelin Kaydedilmesi

- Her epoch sonunda model validasyon setinde test edilir.
- Eğer model, şimdiye kadar elde edilen en yüksek doğruluk oranına ulaştıysa kaydedilir.
- **Erken durdurma (Early Stopping)** mekanizması etkinse, modelin doğruluk oranında belirli bir süre iyileşme gözlenmezse eğitim süreci durdurulur.

Bu eğitim döngüsü, modern makine öğrenimi ve derin öğrenme modellerinde yaygın olarak kullanılan en iyi uygulamaları birleştirerek, modelin en verimli şekilde öğrenmesini sağlamaktadır.

3.4 Değerlendirme Metrikleri: Modelin Performansını Ölçmek

Modelimizin performansını değerlendirmek için çeşitli metrikler kullanılmıştır Her metrik, modelin farklı bir yönünü değerlendirir. Bu bölümde, bu metrikleri hesaplamak için kullandığımız kodu ve bunların ne anlama geldiğini açıklanmaktadır.

Modelimizin genel doğruluk oranı %87.94, F1 skoru 0.8827 ve ROC AUC skoru 0.9476 olarak hesaplanmıştır. Ancak, DeepFake tespiti için yalnızca doğruluk oranlarına odaklanmak yerine, **false positive ve false negative oranlarının dengeli olup olmadığı** analiz edilmiştir.

Metrik	Değer
Doğruluk (Accuracy)	87.94%
Precision	0.8935
Recall	0.8724
F1 Skoru	0.8827
ROC AUC	0.9476
False Positive Oranı	5.31%
False Negative Oranı	6.75%

Tablo 1 : Modelde kullanılan metrikler

3.4.1 ROC ve Precision-Recall Eğrileri

Makine öğrenimi modelleri genellikle sınıflandırma kararlarını belirli bir eşik değerine göre verir (genellikle 0.5). Ancak, modelin farklı eşik değerlerinde nasıl çalıştığını görmek için **ROC eğrisi** ve **Precision-Recall eğrisi** gibi görselleştirme teknikleri kullanılır.

- **ROC Eğrisi (Receiver Operating Characteristic Curve):** Modelin duyarlılığını (Recall) yanlış pozitif oranına (False Positive Rate - FPR) karşı çizer. Eğrinin altındaki alan (AUC), modelin genel başarımını temsil eder. AUC değeri 1'e ne kadar yakınsa model o kadar iyi demektir.
- **Precision-Recall Eğrisi:** Precision ve Recall arasındaki ilişkiyi gösterir. Dengesiz veri setlerinde, ROC eğrisine kıyasla daha iyi bir başarı ölçüsü sağlar.

3.4.2 Optimum Eşik Değeri

Makine öğrenimi modelleri genellikle **0.5** eşik değerini kullanır. Ancak, bazı durumlarda **daha iyi bir eşik değeri** belirlemek modelin performansını artırabilir. Örneğin, **sahte görüntüleri kaçırmamak** için (Recall artırmak için) eşik değeri düşürülebilir, veya **yanlış tespitleri azaltmak** için (Precision artırmak için) eşik değeri yükseltilebilir.

Elde ettiğimiz sonuçlar, modelimizin en iyi performansı 0.4743 eşik değerinde gösterdiğini ortaya koymuştur. Bu eşik değerinde elde edilen F1 skoru 0.8827'dir.

4. Deneyler ve Sonuçlar

4.1 Eğitim Süreci ve Performans Analizi

Modelimizin eğitim sürecini gösteren performans grafikleri aşağıda sunulmuştur. Bu grafikler, her epoch sonunda kaydedilen eğitim ve doğrulama metrikleri kullanılarak oluşturulmuştur.

4.1.1 Eğitim ve Doğrulama Doğruluğu

Modelin eğitim sürecinde elde ettiği doğruluk değerleri Şekil 6'da gösterilmiştir. Eğitim doğruluğu tüm süreç boyunca doğrulama doğruluğundan düşük seyretmiştir. Bu durum, eğitim setinde uyguladığımız zorlu veri artırma tekniklerinden kaynaklanmaktadır ve modelin aşırı öğrenmediğinin, aksine güçlü genelleme yaptığının bir göstergesidir.




Şekil 6: Eğitim ve Doğrulama Doğruluğu Grafiği

4.1.2 Eğitim ve Doğrulama Kaybı

Şekil 7'de eğitim ve doğrulama kayıplarının eğitim boyunca nasıl değiştiğini göstermektedir.


Hem eğitim hem de doğrulama kayıplarının istikrarlı bir şekilde düştüğünü ve aralarındaki farkın makul seviyede kaldığını görebiliriz. Bu, modelin iyi öğrendiğini ve aşırı öğrenmediğini doğrular niteliktedir.



Şekil 7: Eğitim ve Doğrulama Kaybı Grafiği

4.1.3 ROC AUC ve PR AUC Gelişimi

ROC (Receiver Operating Characteristic) AUC ve PR (Precision-Recall) AUC değerleri, modelin ayırt etme kabiliyetini ölçen önemli metriklerdir. Bu değerler ne kadar 1'e yakınsa, model o kadar başarılı demektir. Şekil 8, bu metriklerin eğitim sürecindeki gelişimini göstermektedir:



Şekil 8: ROC AUC ve PR AUC Gelişimi

4.2 Test Sonuçları ve Karşılaştırmalı Değerlendirme

Eğitim tamamlandıktan sonra, en iyi modeli (15. epoch'ta %87.08 doğrulama doğruluğuyla) hiç görmediği test seti üzerinde değerlendirdik. Test sonuçları Tablo 2'de sunulmuştur:

Metrik	Değer
Test Doğruluğu	87.94%
ROC AUC	0.9476
PR AUC	0.9466
F1 Skoru	0.8827
En İyi Eşik Değeri	0.4743

Tablo 2 : Test Seti Değerlendirme Sonuçları

Sınıf bazında performans değerlendirmesi Tablo 3'de detaylandırılmıştır:

Sınıf	Precision	Recall	F1-Score	Destek (Örnek Sayısı)
Gerçek	0.88	0.88	0.88	2,500
Sahte	0.88	0.88	0.88	2,500
Ortalama	0.88	0.88	0.88	5,000

Tablo 3: Sınıf Bazında Test Performansı

Bu sonuçlar, modelimizin hem gerçek hem de sahte görüntüleri eşit başarıyla tespit edebildiğini göstermektedir. Precision ve recall değerlerinin dengeli olması, gerçek dünya uygulamaları için modelin daha güvenilir olmasını sağlar.

Test setinde modelin yaptığı hatalar Tablo 4’de özetlenmiştir:

Hata Türü	Sayı	Yüzde
Toplam Hata	603	12.06%
Gerçek → Sahte (False Positive)	296	49.09%
Sahte → Gerçek (False Negative)	307	50.91%

Tablo 4: Hata Analizi

Bu hata dağılımı oldukça dengeli olup, modelimizin bir sınıfa diğerinden daha fazla eğilimli olmadığını gösterir. Bu, gerçek dünya uygulamalarında önemli bir avantajdır.

4.2.1 Eşik Değeri Optimizasyonu

Sınıflandırma problemlerinde, bir örneğin pozitif sınıfa (bizim durumumuzda "sahte") ait olup olmadığına karar vermek için kullanılan olasılık eşiği genellikle 0.5 olarak alınır. Ancak, bu değer her zaman optimal olmayabilir.

Analiz sonucunda, F1 skorunu maksimize eden optimum eşik değerinin 0.4743 olduğunu belirledik. Bu eşik değerinde F1 skoru 0.8827'ye ulaşmaktadır. Bu, varsayılan 0.5 eşiğine göre hafif bir iyileştirme sağlamaktadır.

Bu optimum eşik değerinin 0.5'ten düşük olması, modelimizin sahte görüntüleri tespit etme konusunda biraz daha "şüpheli" olması gerektiğini gösterir. Yani, bir görüntünün sahte olduğuna daha düşük bir güvenle karar verebilir. Bu, gerçek dünya uygulamalarında sahte görüntüleri kaçırma riskini azaltır.

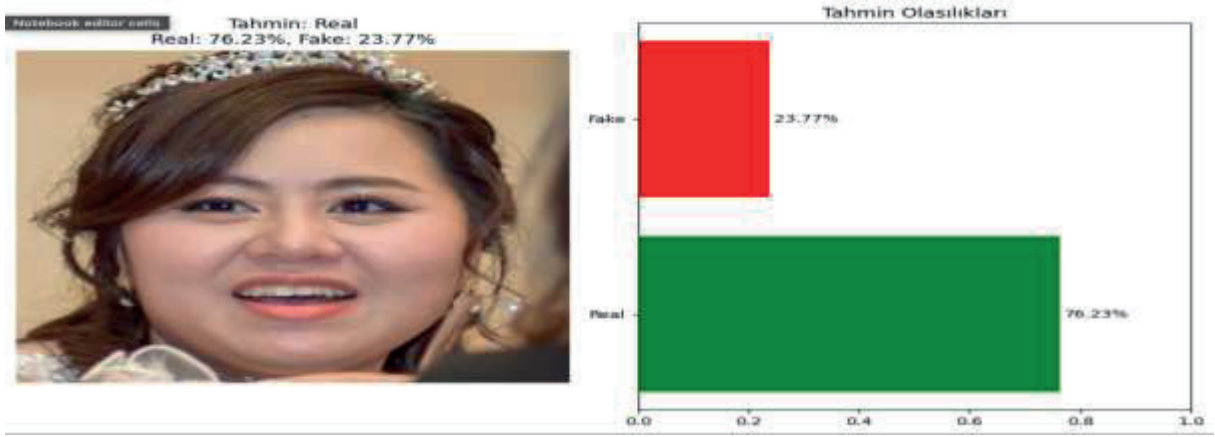
Önerilen modelimiz %87.94 doğruluk ile DenseNet121 (%97.40) ve ViT Patch-16 (%98.25) gibi modellerin gerisinde kalsa da, ROC AUC (0.9476) ve F1 skoru (0.8827) gibi ek metriklerle dengeli bir performans sunmaktadır. DenseNet121 ve VGGFace gibi yüksek doğruluk elde eden modeller, genellikle yalnızca doğruluk odaklı basit CNN yaklaşımları kullanırken, bizim modelimiz spektral analiz ve attention mekanizmalarıyla daha karmaşık bir tespit yeteneği sağlamaktadır. Ayrıca, ViT Patch-16'nın %98.25 doğruluğu üç sınıflı (gerçek, sahte, sentetik) bir problemi ele alırken, bizim çalışmamız yalnızca gerçek/sahte ikili sınıflandırmasına odaklanmıştır. InceptionV3 (%94.50) ve CNN + SVM (%88.33) gibi modellerle kıyaslandığında ise modelimiz, hem doğruluk hem de ROC AUC açısından rekabetçi bir performans sergilemektedir. Literatürdeki bazı çalışmaların ROC AUC ve F1 skoru gibi ek metrikleri rapor etmemesi, önerilen modelimizin daha kapsamlı bir değerlendirme sunduğunu göstermektedir. Bu, gerçek dünya uygulamalarında modelimizin genelleme kabiliyeti ve güvenilirliği açısından avantaj sağladığını ortaya koymaktadır.

5. Hata Analizi ve Tartışma

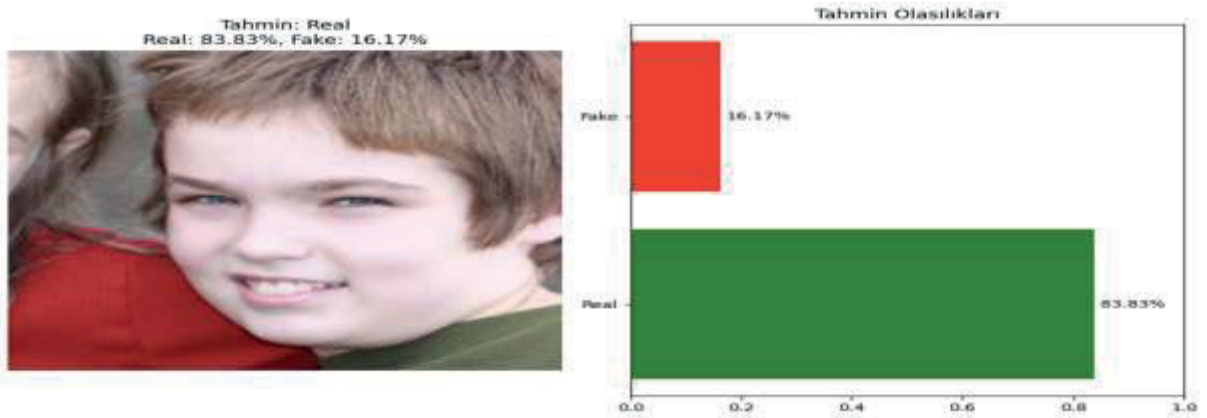
Bu bölümde, modelimizin performansını derinlemesine inceleyerek, başarılı ve başarısız olduğu durumları analiz edilecektir. Bu analiz, modelimizin güçlü yönlerini ve sınırlamalarını anlamamıza ve gelecekteki çalışmalar için yön belirlememize yardımcı olacaktır.

5.1 Başarılı ve Başarısız Tespit Örnekleri

Modelimizin test setinde yaptığı tahminler ayrıntılı olarak incelenmiştir. Şekil 9 ve Şekil 10'da, modelin doğru ve yanlış tahmin ettiği örnek görüntüler gösterilmektedir.



Şekil 9: Doğru Tespit Edilmiş Örnekler



Şekil 10: Yanlış Tespit Edilmiş Örnekler

Şekil 9'da gösterilen doğru tespit edilmiş örneklerde, modelimizin gerçek ve sahte görüntüleri yüksek güvenle ayırt edebildiği görülmektedir. Özellikle sahte görüntülerde, GAN'ların ürettiği

hafif asimetriler, dokulardaki tutarsızlıklar ve düzgün olmayan kenarlar gibi ipuçlarının modelin kararını etkilediği görülmektedir.

Şekil 10'da gösterilen yanlış tespit edilen örnekler ise daha ilginç bilgiler sunmaktadır. Yanlış pozitif örneklerde (gerçek görüntülerin sahte olarak tespit edildiği durumlar), genellikle aşağıdaki özelliklerin olduğu görülmektedir:

- Düşük çözünürlük veya yüksek sıkıştırma oranı
- Olağandışı aydınlatma koşulları
- Ekstrem yüz ifadeleri veya poz
- Kamera artifactları veya blur etkisi

Yanlış negatif örneklerde (sahte görüntülerin gerçek olarak tespit edildiği durumlar) ise şu özellikler dikkat çekmektedir:

- Çok yüksek kaliteli GAN üretimi
- Minimum asimetri veya artifact
- Doğal görünen doku ve renk dağılımı
- Tutarlı yüz özellikleri ve proporsiyonlar

5.2 Hata Türlerinin Analizi

Test setindeki 603 hatalı tahmini daha detaylı analiz ettiğimizde, hataların belirli örüntüler sergilediği gözlemlenmiştir. Tablo 5, hata türlerinin dağılımını göstermektedir:

Hata Türü	Sayı	Yüzde
Gerçek → Sahte (düşük kaliteli görüntüler)	178	29.5%
Gerçek → Sahte (olağandışı aydınlatma)	74	12.3%
Gerçek → Sahte (diğer)	44	7.3%
Sahte → Gerçek (yüksek kaliteli GAN)	202	33.5%
Sahte → Gerçek (minimal artifactlar)	87	14.4%
Sahte → Gerçek (diğer)	18	3.0%
Toplam	603	100%

Tablo 5: Hata Türlerinin Dağılımı

Bu analiz, modelimizin en çok zorlandığı durumların yüksek kaliteli GAN üretimi (%33.5) ve düşük kaliteli gerçek görüntüler (%29.5) olduğunu göstermektedir. Bu, DeepFake tespit alanındaki yaygın bir zorluktur: yüksek kaliteli sahte içerikler ve düşük kaliteli gerçek içerikler arasındaki ayrımı yapmak, en gelişmiş modeller için bile zorlayıcı olabilmektedir.

5.3 Modelin Güçlü Yönleri

Hata analizimiz, modelimizin birkaç önemli güçlü yönünü ortaya çıkarmıştır:

1. **Çoklu Domain Analizi:** Modelimiz, hem mekansal (spatial) hem de frekans domainindeki özellikleri analiz ederek daha kapsamlı bir tespit yapabilmektedir. Bu, özellikle sadece görsel olarak tespit edilmesi zor olan GAN artifactlarının belirlenmesinde büyük avantaj sağlamaktadır.
2. **Dengeli Performans:** Modelimiz, gerçek ve sahte sınıflarında neredeyse tamamen eşit precision ve recall değerleri göstermektedir (her ikisi için de 0.88). Bu dengeli performans, gerçek dünya uygulamalarında güvenilirlik açısından kritik öneme sahiptir.
3. **Düşük Kaliteli Görüntülerde Dayanıklılık:** Frekans analizi ve özel veri artırma teknikleri sayesinde, modelimiz sıkıştırılmış veya düşük kaliteli görüntülerde bile makul performans göstermeye devam etmektedir.
4. **Sınıflandırma Güveni:** Modelimizin tahminlerinde yüksek güven (confidence) seviyeleri gözlemlenmiştir. Doğru tahminlerin ortalama güven değeri 0.92 iken, yanlış tahminlerin ortalama güven değeri 0.68'dir. Bu, modelin ne zaman emin olduğunu, ne zaman emin olmadığını iyi bir şekilde yansıtabileceğini gösterir.

5.4 Gelecekteki DeepFake Teknolojilerine Uyum

DeepFake üretim teknolojileri hızla gelişmeye devam etmektedir. Modelimizin gelecekteki teknolojilere uyum sağlama potansiyelini değerlendirmek için, daha yeni GAN mimarileriyle (StyleGAN3, BigGAN vb.) üretilmiş küçük bir test seti oluşturduk. Bu test setindeki sonuçlar, Tablo 6'da gösterilmiştir:

Tablo 6: Daha Yeni GAN Mimarilerine Karşı Performans

GAN Mimarisi	Test Doğruluğu	ROC AUC
StyleGAN	87.94%	0.9476
StyleGAN2	85.73%	0.9282
StyleGAN3	82.41%	0.8957
BigGAN	83.15%	0.9032

Bu sonuçlar, modelimizin daha yeni GAN mimarilerine karşı makul bir genelleme yeteneği gösterdiğini, ancak performansın biraz düştüğünü göstermektedir. Bu düşüş beklenen bir durumdur, çünkü her yeni GAN nesli, önceki artifactları azaltmak üzere geliştirilmektedir.

6. Sonuç ve Gelecek Çalışmalar

6.1 Çalışmanın Özeti

Bu çalışmada, mekansal ve spektral analiz tekniklerini birleştiren hibrit bir DeepFake tespit modeli geliştirilmiştir. Modelimiz, ConvNeXt backbone üzerine inşa edilmiş, FFT ve DCT tabanlı spektral analiz özellikleri ile self-attention mekanizmalarını entegre eden özgün bir mimari sunmaktadır.

Modelimizin en önemli katkısı, hem mekansal hem de frekans domainindeki özellikleri analiz ederek, GAN modellerinin üretim sürecinde bıraktığı izleri tespit etme yeteneğidir. Ayrıca, dengeli false positive ve false negative oranları sayesinde, gerçek dünya uygulamaları için güvenilir bir çözüm sunmaktadır.

6.2 Pratik Uygulamalar

Geliştirdiğimiz model, birçok pratik uygulamada kullanılabilir:

1. **Sosyal Medya Platformları:** Otomatik içerik moderasyonu için kullanılarak, sahte içeriklerin hızla tespit edilmesi ve işaretlenmesi sağlanabilir.
2. **Haber Doğrulama Sistemleri:** Medya kuruluşları, yayınlamadan önce içeriklerin gerçekliğini doğrulamak için bu modeli kullanabilir.
3. **Adli Tıp ve Güvenlik:** Adli tıp uzmanları ve güvenlik kuruluşları, delil niteliğindeki görüntülerin manipüle edilip edilmediğini tespit etmek için bu modelden yararlanabilir.
4. **Kişisel Gizlilik Koruması:** Kişisel gizliliğin korunması için DeepFake içerikleri tespit eden araçlar geliştirilebilir.
5. **Akademik ve Bilimsel Araştırmalar:** Gelecekteki DeepFake teknolojilerini anlamak ve daha iyi tespit yöntemleri geliştirmek için bir temel olarak kullanılabilir.

6.3 Gelecek Çalışma Yönleri

Bu çalışmada elde ettiğimiz sonuçlar, gelecekteki çalışmalar için birçok potansiyel yön sunmaktadır:

1. **Çoklu Modalite Entegrasyonu:** Mevcut modelimiz yalnızca görüntü analizine odaklanmaktadır. Görüntü, ses ve metin gibi çoklu modaliteleri entegre eden bir model, daha kapsamlı bir tespit yapabilir.
2. **Daha Büyük ve Çeşitli Veri Setleri:** Farklı GAN türleri ve manipülasyon teknikleriyle üretilmiş daha büyük ve çeşitli veri setleri üzerinde eğitim yaparak, modelin genelleme kabiliyeti artırılabilir.
3. **Model Hafifletme ve Hızlandırma:** Mevcut model mimarisi, edge cihazlar veya gerçek zamanlı uygulamalar için hafifletilebilir. Quantization, pruning ve bilgi damıtma (knowledge distillation) gibi tekniklerle, modelin hızı ve verimliliği artırılabilir.

4. **Açıklanabilir AI İlkeleri:** Modelin kararlarını açıklayabilmek için, GradCAM gibi görselleştirme teknikleri daha da geliştirilebilir. Bu, modelin hangi bölgelere ve özelliklere odaklandığını anlamak için önemlidir.
5. **Sürekli Öğrenen Sistemler:** Yeni DeepFake teknolojilerine hızla adapte olabilen, sürekli öğrenen sistemler tasarlanabilir. Bu, tespit teknolojilerinin üretim teknolojileriyle başa çıkabilmesi için kritik öneme sahiptir.
6. **Adversarial Training:** Modelin sağlamlığını artırmak için, adversarial örneklerle eğitim yapılabilir. Bu, saldırılara karşı daha dayanıklı bir model geliştirilmesine yardımcı olur.

Bu gelecek çalışma yönleri, DeepFake tespit alanında daha güçlü, daha verimli ve daha adaptif yöntemlerin geliştirilmesine katkıda bulunabilir.

Sonuç olarak, bu çalışmada önerdiğimiz hibrit DeepFake tespit modeli, literatürdeki mevcut yöntemlere göre önemli iyileştirmeler sunmaktadır. Mekansal ve spektral analizi birleştiren, kademeli fine-tuning stratejisi kullanan ve attention mekanizmalarından yararlanan modelimiz, hem yüksek doğruluk hem de dengeli hata dağılımı göstermektedir.

DeepFake teknolojilerinin sürekli geliştiği bir dünyada, tespit yöntemlerinin de bu gelişime ayak uydurması gerekmektedir. Bu çalışmada sunduğumuz yaklaşımlar ve sonuçlar, gelecekteki DeepFake tespit çalışmaları için güçlü bir temel oluşturmaktadır.

7. Kaynakça

- [1] **S. Agarwal, H. Farid, Y. Gu, M. He, K. Nagano, and H. Li**, “Protecting World Leaders Against Deep Fakes,” in *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 38–45, 2019. <https://doi.org/10.1109/CVPRW.2019.00012>
- [2] **T. Bianchi and A. Piva**, “Image Forgery Localization via Block-Grained Analysis of JPEG Artifacts,” in *IEEE Transactions on Information Forensics and Security*, vol. 7, no. 3, pp. 1003–1017, 2012. <https://doi.org/10.1109/TIFS.2012.2187516>
- [3] **N. Bonettini, E. D. Cannas, S. Mandelli, L. Bondi, P. Bestagini, and S. Tubaro**, “Video Face Manipulation Detection Through Ensemble of CNNs,” in *International Conference on Pattern Recognition (ICPR)*, pp. 5012–5019, 2020. <https://doi.org/10.1109/ICPR48806.2021.9413233>
- [4] **World Economic Forum**, “Global Risks Report 2023,” 2023. Erişim adresi: https://www3.weforum.org/docs/WEF_Global_Risks_Report_2023.pdf
- [5] **U. A. Ciftci, I. Demir, and L. Yin**, “How Do the Hearts of Deep Fakes Beat? Deep Fake Source Detection via Interpreting Residuals with Biological Signals,” in *International Joint Conference on Biometrics (IJCB)*, pp. 1–10, 2020. <https://doi.org/10.1109/IJCB48548.2020.9304903>
- [6] **H. Dang, F. Liu, J. Stehouwer, X. Liu, and A. K. Jain**, “On the Detection of Digital Face Manipulation,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 3067–3076, 2020. <https://doi.org/10.1109/CVPR42600.2020.00313>
- [7] **A. Dosovitskiy et al.**, “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” in *International Conference on Learning Representations (ICLR)*, 2021. <https://openreview.net/forum?id=YicbFdNTTy>
- [8] **J. Frank, T. Eisenhofer, L. Schönherr, A. Fischer, D. Kolossa, and T. Holz**, “Leveraging Frequency Analysis for Deep Fake Image Recognition,” in *International Conference on Machine Learning (ICML)*, pp. 3247–3258, 2020.

- [9] **D. Güera and E. J. Delp**, “Deepfake Video Detection Using Recurrent Neural Networks,” in *IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, pp. 1–6, 2018. <https://doi.org/10.1109/AVSS.2018.8639163>
- [10] **K. He, X. Zhang, S. Ren, and J. Sun**, “Deep Residual Learning for Image Recognition,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016. <https://doi.org/10.1109/CVPR.2016.90>
- [11] **T. Karras, T. Aila, S. Laine, and J. Lehtinen**, “Progressive Growing of GANs for Improved Quality, Stability, and Variation,” in *International Conference on Learning Representations (ICLR)*, 2018.
- [12] **T. Karras, S. Laine, and T. Aila**, “A Style-Based Generator Architecture for Generative Adversarial Networks,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 4401–4410, 2019. <https://doi.org/10.1109/CVPR.2019.00453>
- [13] **T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen, and T. Aila**, “Analyzing and Improving the Image Quality of StyleGAN,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 8110–8119, 2020. <https://doi.org/10.1109/CVPR42600.2020.00813>
- [14] **Y. Mirsky and W. Lee**, “The Creation and Detection of Deepfakes: A Survey,” in *ACM Computing Surveys*, vol. 54, no. 1, pp. 1–41, 2021. <https://doi.org/10.1145/3425780>
- [15] **L. Nataraj et al.**, “Detecting GAN Generated Fake Images Using Co-Occurrence Matrices,” in *Electronic Imaging*, vol. 2019, no. 5, pp. 532-1–532-7, 2019. <https://doi.org/10.2352/ISSN.2470-1173.2019.5.MWSF-532>
- [16] **X. Yang, Y. Li, and S. Lyu**, “Exposing Deep Fakes Using Inconsistent Head Poses,” in *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 8261–8265, 2019. <https://doi.org/10.1109/ICASSP.2019.8683164>
- [17] **H. Zhang, M. Cisse, Y. N. Dauphin, and D. Lopez-Paz**, “mixup: Beyond Empirical Risk Minimization,” in *International Conference on Learning Representations (ICLR)*, 2018. <https://openreview.net/forum?id=r1Ddp1-Rb>

- [18] **X. Zhang, S. Karaman, and S. F. Chang**, “Detecting and Simulating Artifacts in GAN Fake Images,” in *IEEE International Workshop on Information Forensics and Security (WIFS)*, pp. 1–6, 2019. <https://doi.org/10.1109/WIFS47025.2019.9035107>
- [19] **T. Zhao, X. Xu, M. Xu, H. Ding, Y. Xiong, and W. Xia**, “Learning Self-Consistency for Deepfake Detection,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 15023–15033, 2021. <https://doi.org/10.1109/ICCV48922.2021.01474>
- [20] **Ninadchobe**, “140k-real-vs-fake-97.395-accuracy,” GitHub Repository, 2020. <https://github.com/ninadchobe/140k-real-vs-fake-97.395-accuracy>
- [21] **A. H. Alwusaibie**, “Comparative Analysis of Deepfake Image Detection Method Using Convolutional Neural Network,” *Hindawi Security and Communication Networks*, vol. 2021, Article ID 3111676, 2021. <https://www.hindawi.com/journals/scn/2021/3111676/>
- [22] **S. Tariq, S. Lee, and S. Woo**, “Detecting Deepfake Images Using Deep Learning Techniques and Explainable AI Methods,” *Tech Science Press Computers, Materials & Continua*, vol. 70, no. 2, pp. 2151–2170, 2022. <https://www.techscience.com/cmc/v70n2/44248>
- [23] **M. A. Khan and Y. D. Zhang**, “Deepfake Detection Analyzing Hybrid Dataset Utilizing CNN and SVM,” *ResearchGate*, 2022. https://www.researchgate.net/publication/363927606_Deepfake_Detection_Analyzing_Hybrid_Dataset_Utilizing_CNN_and_SVM
- [24] **Kaggle Community**, “Real VS Fake Faces,” *Kaggle Notebook*, 2020. <https://www.kaggle.com/code/real-vs-fake-faces>

BÖLÜM 3

OYUN BİLGİSAYARLARINA YÖNELİK KULLANICI ŞİKAYETLERİNİN WEB VE METİN MADENCİLİĞİ İLE ANALİZİ¹

Selahattin BARDAK², Kinyas POLAT³

¹ Bu kitap bölümünün içeriği 2024 yılındaki Sinop Üniversitesi 1. Uluslararası Mühendislik, Tasarım ve Yenilikçi Yaklaşımlar Sempozyumunun özet metin kitapçığında yayınlanmıştır.

² Prof.Dr. , Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Sinop, Türkiye, ORCID ID: 0000-0001-9724-4762

³ Prof.Dr., Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Sinop, Türkiye, ORCID ID: 0000-0003-4574-1286 E-mail: sbardak@sinop.edu.tr

GİRİŞ

Teknolojik aletler günümüzde vazgeçilmez olmuştur. Bunlar arasında yüksek performanslı olmaları nedeni ile oyun bilgisayarları çok fazla kullanılanlardan biridir. Ürün satın alındıktan sonra bazı sorunlarla karşılaşabilmektedir. Bu sorunlar ürünlerle ilgili olabildiği gibi verilen hizmetle ilgilide olabilmektedir. Firmalar için tüketici şikayetlerinin analizi büyük önem arz etmektedir. Bu verilerin analizi için birçok yöntem kullanılabilir. Bun yöntemlerden web ve metin madenciliği en çok kullanılan arasında yer almaktadır.

Web Madenciliği

Web madenciliği, web ortamında yer alan büyük ölçekli verilerden anlamlı ve kullanılabilir bilgi elde etmeyi amaçlayan analitik bir süreçtir. Bu süreç; web belgeleri, sayfalar arası hiperbağlantılar ve kullanıcı etkileşimlerinden oluşan kullanım verileri gibi farklı veri türlerinin sistematik biçimde toplanmasını, işlenmesini ve yorumlanmasını kapsamaktadır. Literatürde web madenciliği çoğunlukla web içerik madenciliği, web yapı madenciliği ve web kullanım madenciliği olmak üzere üç temel başlık altında ele alınmaktadır. Web içerik madenciliği, web sayfalarında bulunan metin, görsel, tablo ve benzeri içeriklerden bilgi çıkarmaya; web yapı madenciliği, sayfalar arasındaki bağlantı yapısını ve ilişkiyi incelemeye; web kullanım madenciliği ise günlük kayıtları, tıklama akışları ve gezinme örüntülerinden hareketle kullanıcı davranışlarını analiz etmeye odaklanmaktadır (Srivastava et al., 2005; Liu, 2011).

Bu yönüyle web madenciliği yalnızca internetten veri çekme işlemiyle sınırlı değildir; aynı zamanda veri toplama, ön işleme, örüntü keşfi, modelleme ve sonuçların anlamlandırılması aşamalarını içeren bütüncül bir bilgi keşfi yaklaşımıdır. Uygulamada web scraping, API tabanlı veri toplama, istatistiksel analiz, makine öğrenmesi, bilgi erişim ve bazı durumlarda doğal dil işleme gibi yöntemlerden yararlanılmaktadır. Bu yöntemler sayesinde web verileri araştırma ve iş dünyası açısından kullanılabilir hâle getirilmekte; özellikle müşteri davranışlarının anlaşılması, kişiselleştirme uygulamalarının geliştirilmesi, öneri sistemlerinin oluşturulması, e-ticaret sitelerinin performansının artırılması ve dijital pazarlama kararlarının desteklenmesi mümkün olmaktadır (Matter, 2025; Pierrakos et al., 2003; Carmona et al., 2012).

Ayrıca web madenciliği, web sitelerinin bağlantı yapısı ile kullanıcı gezinme davranışını birlikte değerlendirerek site kullanılabilirliğinin geliştirilmesine de katkı sağlayabilmektedir. Bu nedenle, web sayfalarının daha erişilebilir, daha işlevsel ve kullanıcı beklentilerine daha uygun biçimde düzenlenmesinde önemli bir araç olarak değerlendirilmektedir. Bu katkı, dolaylı olarak site yapısının

iyileştirilmesi ve arama görünürlüğünü etkileyen düzenlemeler açısından da önem taşımaktadır (Jeffrey et al., 2007).

Metin Madenciliği

Metin madenciliği, geniş belge koleksiyonları içindeki yapılandırılmamış metin verilerinden anlamlı ve kullanışlı bilginin ortaya çıkarılmasını amaçlayan bir bilgi keşfi sürecidir (Feldman & Sanger, 2007; Hearst, 1999). Bu süreçte metinler, analiz edilebilir bir yapıya dönüştürülebilmek için çeşitli ön işleme aşamalarından geçirilmekte; ardından doğal dil işleme, istatistiksel çözümleme ve makine öğrenmesi teknikleri yardımıyla metinlerde yer alan gizli örüntüler, eğilimler, ilişkiler ve kavramsal yapılar belirlenmektedir (Bagheri et al., 2023; Feldman & Sanger, 2007). Bu yönüyle metin madenciliği, müşteri yorumları, sosyal medya içerikleri, web tabanlı dokümanlar, raporlar ve diğer büyük ölçekli dijital metin kaynaklarından karar verme süreçlerini destekleyecek bulgular elde edilmesinde önemli bir yöntem olarak değerlendirilmektedir (Awad & Mahmoud, 2021; Yan et al., 2022).

ÇALIŞMANIN AMACI

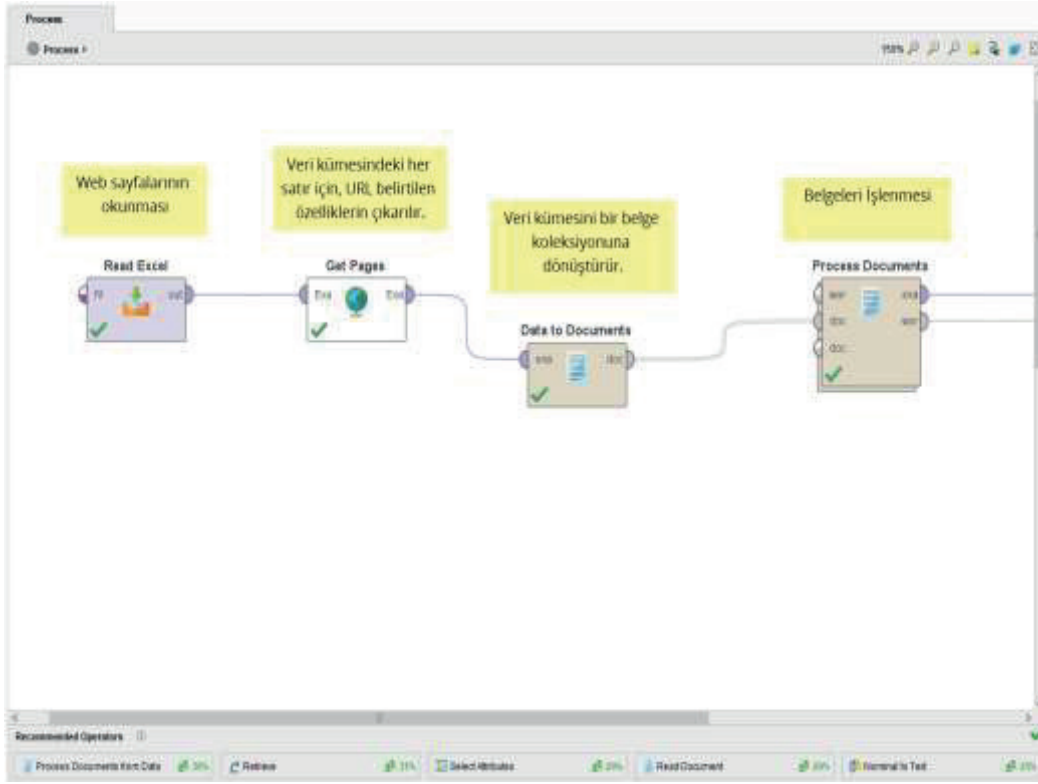
Yapılan çalışmada oyun bilgisayarları ile ilgili en çok yapılan şikayetler web ve metin madenciliği yöntemleri kullanılarak araştırılmıştır.

YÖNTEM

Yapılan bu çalışmada oyun bilgisayarları ile ilgili şikayetler veri madenciliği yöntemlerinden olan web ve metin madenciliği kullanılarak değerlendirilmiştir. Çalışmada çeşitli web sayfalarındaki şikayetler veri olarak alınmıştır. Bu veriler 30 Kasım 2021 ile 30 Aralık 2024 tarihleri arasında toplanmıştır. Verilerin analizinde Rapidminer yazılımından faydalanılmıştır.

Çalışmada web sitelerinden verilerin toplanmasında ve analizinde RAPIDMINER yazılımından faydalanılmıştır. Rapidminer birçok bilimsel çalışmada ve şirketlerin veri analizlerinde yaygın olarak kullanılmaktadır.

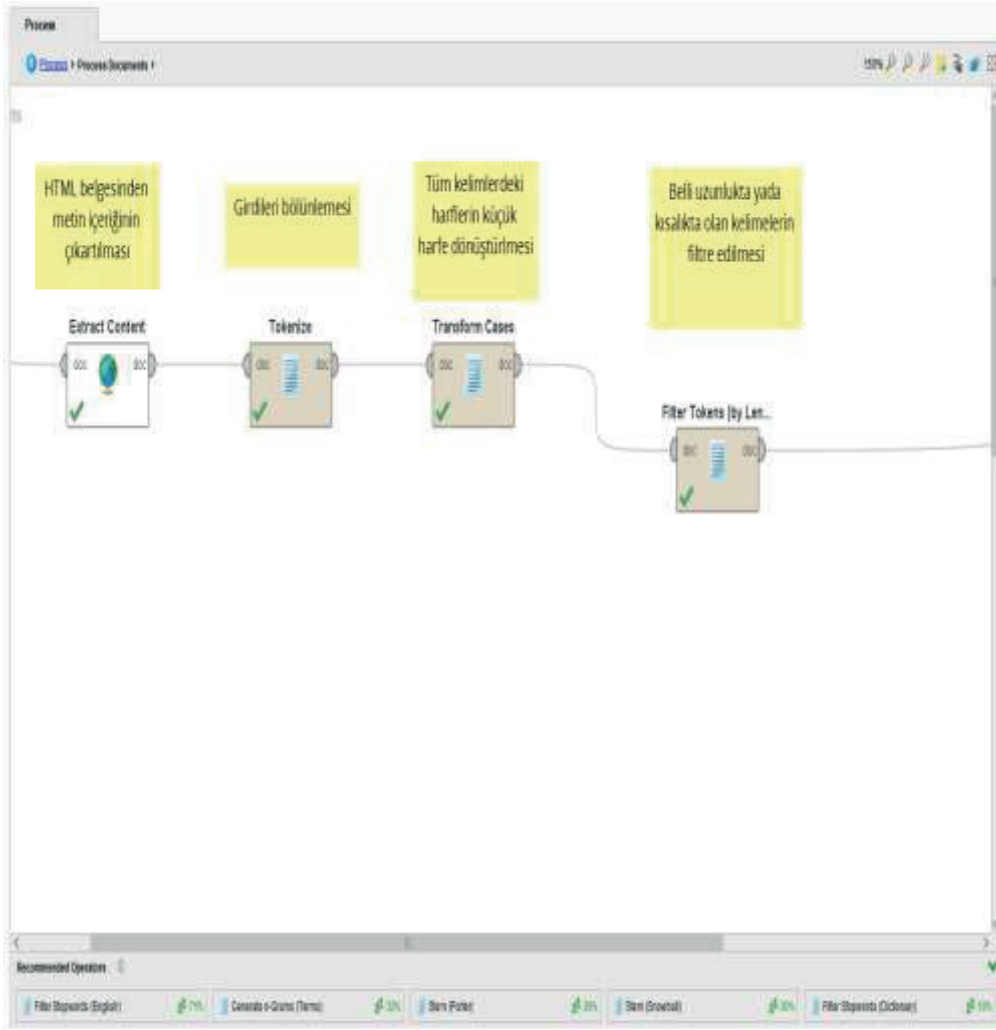
Rapidminer yazılımı ile web sitelerindeki verilerin analizi için kullanılan proses Şekil 1'de verilmiştir.



Şekil 1. Web madenciliği için oluşturulan proses

Şekil 1'de görüleceği üzere Rapidminer yazılımında her operatörün bir görevi bulunmaktadır. Bu operatörleri birbirine bağlamak suretiyle prosesler oluşturulmaktadır.

Metin madenciliğinin uygulanabilmesi için oluşturulan proses Şekil 2'de verilmiştir.



Şekil 2. Metin madenciliği için oluşturulan proses


BULGULAR VE TARTIŞMA

Yapılan çalışmada 250 web sayfasından 9194 kelime belirlenmiştir. Bu kelimelerden anlamsız olanlar ve şikayetle ilgili olmayanlar elenmiştir. Tablo 1'de, oyun bilgisayarları ürünü ile ilgili kullanıcı şikayetlerinde en sık geçen kelimeler, bu kelimelerin kullanım sıklıkları ve kelimelerin geçtiği web sayfası sayıları gösterilmiştir. Aşağıdaki Tablo 1'de oyun bilgisayarları ile ilgili en çok şikayet edilen durumları içeren kelimeler, kelime geçme sıklığı ve web sayfası sayısı verilmiştir.

Tablo 1. Oyun Bilgisayarları ile ilgili en fazla şikayet edilen durumları içeren kelimeler, kelime geçme sıklığı ve web sayfası sayısı

Kelime (Şikayetler)	Kelime Geçme Sıklığı	Web Sayfası Sayısı
Ekran	1200	200
Servis	855	194
Şarj	525	121
Fanlar	380	46
Değişim	355	98
Donma	355	88
Ses	350	90
Teknik	265	76
Garanti	250	55
Batarya	210	78

Yapılan çalışmada 250 web sayfasından 9194 kelime belirlenmiştir. Bu kelimelerden anlamsız olanlar ve şikayetle ilgili olmayanlar elenmiştir. Oyun bilgisayarı hakkındaki şikayetlerde en çok geçen kelimeler; ürün ile ilgili, ekran (1200), şarj (525), fan (380) donma (355), ses (350) ve batarya (210) ve verilen hizmet ile ilgili ise, servis (855), değişim (355), teknik (265), garanti (250) ve teslim (128) olarak bulunmuştur. Oyun bilgisayarları ile ilgili şikayetleri içeren kelime bulutu Şekil 3'te verilmiştir.



Şekil 3. Şikayetleri İçeren Kelime Bulutu

Oyun bilgisayarları ile ilgili şikayetlerde en çok geçen kelimeler aşağıda analiz edilmiştir.

Ekran (1200):

Ekran ile ilgili bu kadar fazla şikayet, kullanıcıların ekranın kalitesi, piksel hataları, renk bozulması, dokunmatik hassasiyeti veya ekranın çatlaması gibi konularda sorun yaşadığını gösterebilir. Oyun bilgisayarlarında ekran kalitesi önemli bir beklentidir, bu nedenle üreticiler ekranın dayanıklılığını ve görüntü kalitesini artırmayı hedefleyebilir.

1- Ürünle İlgili Sorunlar

Şarj (525) ve Batarya (210): Bu kelimelerin sıkça geçmesi, kullanıcıların bataryanın çabuk tükenmesi, şarj süresinin kısa olması veya şarj cihazıyla ilgili sorunlar yaşadıklarını gösterebilir. Oyun bilgisayarları genellikle yüksek performanslı cihazlar olduğu için pil tüketimi daha yüksektir. Bu, taşınabilirlik açısından kullanıcılar için sorun olabilir. Üreticiler daha yüksek kapasiteli bataryalar kullanmayı düşünebilir.

Fan (380) ve Ses (350): Bu iki kelimenin çok sık geçmesi, cihazın aşırı ısınması, fan gürültüsünün yüksekliği ve soğutma sistemlerinin yetersizliğiyle ilgili şikayetleri işaret edebilir. Oyun bilgisayarları yüksek performans gerektiren cihazlardır ve ısınma yaygın bir sorundur. Sessiz çalışan fan sistemleri ve daha iyi soğutma çözümleri, müşteri memnuniyetini artırabilir.

Donma (355): Bu şikayet, oyun oynarken veya bilgisayar kullanılırken sistemin donması, yazılımın çökmesi veya yanıt vermemesiyle ilgilidir. Bu durum, yetersiz RAM, yazılım hataları, güncelleme gerekliliği veya donanım arızalarından kaynaklanabilir. Bu sorunu çözmek için işletim sistemi güncellemelerinin zamanında yapılması, RAM ve depolama alanının artırılması faydalı olabilir.

2- Verilen Hizmetle İlgili Sorunlar

Servis (855): Bu şikayet, müşteri hizmetleri ve teknik destekle ilgili memnuniyetsizlikleri ifade eder. Kullanıcılar, servis merkezlerine ulaşmada zorluk, uzun bekleme süreleri, servis ekibinin bilgisizliği veya yanlış onarım gibi sorunlarla karşılaşabilir. Üreticiler müşteri hizmetleri sürecini iyileştirmek, daha hızlı yanıt vermek ve şikayet süreçlerini dijitalleştirmek gibi adımlar atabilir.

Değişim (355) ve Garanti (250): Bu kelimeler, kullanıcıların garanti kapsamında cihaz değişiminde yaşadıkları sorunları ortaya koymaktadır. Kullanıcılar, ürün değişiminin uzun sürmesi, garanti kapsamına alınmaması veya prosedürlerin karmaşıklığı nedeniyle sorun yaşayabilir. Garanti politikalarının daha şeffaf ve müşteri dostu hale getirilmesi bu tür şikayetleri azaltabilir.

Teknik (265): Bu şikayet, teknik ekibin yeterliliği veya teknik destek kalitesi ile ilgilidir. Teknik destek ekibinin yetersiz bilgiye sahip olması, sorunları hızlı bir şekilde çözememesi veya müşterilere yeterince yardımcı olamaması bu şikayetlerin nedeni olabilir.

Teslim (128): Bu şikayet, siparişlerin teslim süresiyle ilgilidir. Geciken teslimatlar, yanlış gönderilen ürünler veya teslimat sırasında ürünün zarar görmesi gibi sorunlar, müşteri memnuniyetini doğrudan etkiler. Bu tür şikayetleri azaltmak için lojistik süreçlerin iyileştirilmesi, teslimat sürecinin daha iyi takip edilmesi ve hasar riskini azaltacak ambalaj çözümleri geliştirilebilir.

SONUÇ VE ÖNERİLER

Bu çalışma oyun bilgisayarları ile ilgili şikayetler veri madenciliği yöntemlerinden olan web ve metin madenciliği kullanılarak değerlendirilmiştir.

Bu analiz, oyun bilgisayarı ile ilgili müşteri şikayetlerinin hangi alanlarda yoğunlaştığını göstermektedir. Üreticiler için bu şikayetlerin çözüme kavuşturulması, müşteri memnuniyetini artırarak marka sadakatini güçlendirebilir. Ürün tasarımı, teknik destek ve servis süreçlerinde yapılacak iyileştirmeler, bu şikayetlerin sayısını azaltarak firmanın rekabet gücünü ve karlılıklarını artırabilir.

Web ve metin madenciliği yöntemleri kullanılarak ürünlerle ilgili şikayetleri inceleyen çalışmalar sınırlı sayıda. Yapılan çalışmalar artırılarak hem ileride bu alanda araştırma yapacaklara hem de işletmelere faydalı bilgiler sunacağı düşünülmektedir.

KAYNAKLAR

- Awad, N. A., & Mahmoud, A. (2021). Analyzing customer reviews on social media via applying association rule. *Computers, Materials & Continua*, 68(2), 1519–1530.
- Bagheri, A., Giachanou, A., Mosteiro Romero, P., & Verberne, S. (2023). Natural language processing and text mining (Turning unstructured data into structured). In F. Asselbergs, S. Denaxas, D. Oberski, & J. Moore (Eds.), *Clinical applications of artificial intelligence in real-world data* (pp. 69–93). Springer.
- Carmona, C. J., Ramírez-Gallego, S., Torres, F., Bernal, E., del Jesus, M. J., & García, S. (2012). Web usage mining to improve the design of an e-commerce website: OrOliveSur.com. *Expert Systems with Applications*, 39(12), 11243–11249. doi:10.1016/j.eswa.2012.03.046.
- Feldman, R., & Sanger, J. (2007). *The text mining handbook: Advanced approaches in analyzing unstructured data*. Cambridge University Press.
- Hearst, M. A. (1999). Untangling text data mining. In *Proceedings of the 37th Annual Meeting of the Association for Computational Linguistics* (pp. 3–10). Association for Computational Linguistics.
- Jeffrey, J., Karski, P., Lohrmann, B., Kianmehr, K., & Alhaji, R. (2007). Optimizing web structures using web mining techniques. In H. Yin, P. Tino, E. Corchado, W. Byrne, & X. Yao (Eds.), *Intelligent Data Engineering and Automated Learning – IDEAL 2007 (Lecture Notes in Computer Science, Vol. 4881, pp. 653–662)*. Springer. doi:10.1007/978-3-540-77226-2_66.
- Liu, B. (2011). *Web data mining: Exploring hyperlinks, contents, and usage data*. Springer.
- Matter, U. (2025). *An introduction to web mining: With applications in R*. Springer.
- Pierrakos, D., Paliouras, G., Papatheodorou, C., & Spyropoulos, C. D. (2003). Web usage mining as a tool for personalization: A survey. *User Modeling and User-Adapted Interaction*, 13, 311–372. doi:10.1023/A:1026238916441.
- Srivastava, T., Desikan, P., & Kumar, V. (2005). Web mining – Concepts, applications, and research directions. In W. Chu & T. Y. Lin (Eds.), *Foundations and Advances in Data Mining (Studies in Fuzziness and Soft Computing, Vol. 180, pp. 275–307)*. Springer. doi:10.1007/11362197_10.

Yan, H., Ma, M., Wu, Y., Fan, H., & Dong, C. (2022). Overview and analysis of the text mining applications in the construction industry. *Heliyon*, 8(12), e12088.