

Yapay Zekâ ve Görüntü İşleme 8

Nur Kuban Torun¹

Merve Önalın²

Özet

Günümüzde teknoloji hızlı bir evrim sürecinden geçmekte olup, bilgisayar bilimleri bu dönüşümün merkezinde yer almaktadır. Özellikle yapay zekâ (YZ) ve görüntü işleme disiplinleri hem akademik araştırmalarda hem de endüstriyel uygulamalarda giderek artan bir öneme sahiptir. Görüntü işleme, bir görüntüyü alıp sayısal, optik veya analog yöntemlerle üzerinde işlem yaparak geliştirilmiş bir görüntü elde etme veya görüntüye ait çeşitli özellik ve verileri çıkarma süreci olarak tanımlanmaktadır. Yapay zekâ ise bilgisayarların insan benzeri öğrenme, çıkarım ve problem çözme yeteneklerini geliştirmeyi amaçlayan bir teknoloji olarak ön plana çıkmaktadır. Yapay zekâ ile desteklenen görüntü işleme sistemleri, geleneksel yöntemlere kıyasla daha yüksek doğruluk ve işlem hızı sunmakta; nesne tanıma, tıbbi görüntü analizi, güvenlik uygulamaları ve uzay araştırmaları gibi birçok alanda kritik rol oynamaktadır.

Bu çalışmada, yapay zekâ ve görüntü işlemenin kavramsal çerçevesi ile tarihsel gelişimi incelenmiş, ardından sağlık, ulaşım, güvenlik ve uzay alanlarındaki uygulamalara değinilmiştir. Örnekler arasında Google LYNA algoritması ile kanser hücrelerinin tespiti, SkinVision ile cilt lezyon analizi, Tesla'nın otonom sürüş sistemi, Apple Face ID ve Surya modeli ile güneş aktivitelerinin tahmini yer almaktadır. Literatür incelemesinde derin öğrenme tabanlı yöntemlerin etkinliği, YOLO, R-CNN türevleri ve SSD gibi nesne tespiti ve sınıflandırma algoritmaları üzerinden değerlendirilmiş; çalışma, YZ destekli görüntü işleme yöntemlerinin teknik altyapısını açıklarken, teorik bilginin güncel uygulamalara nasıl dönüştüğünü göstermeyi amaçlamaktadır.

- 1 Doç. Dr., Bilecik Şeyh Edebali Üniversitesi İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri, nurkuban.akdemir@bilecik.edu.tr, ORCID ID: 0000-0002-9115-5838
- 2 Yönetim Bilişim Sistemleri Bölümü Lisans Öğrencisi, Bilecik Şeyh Edebali Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, merveonalan23@gmail.com, ORCID ID: 0009-0002-0544-6530

1. GİRİŞ

Yapay zekâ ve görüntü işleme teknolojileri, günümüz bilgisayar bilimlerinin dinamik ve hızla gelişen disiplinleri arasında yer almaktadır. Görüntü işleme, 1960'larda temel filtreleme, kenar tespiti ve basit segmentasyon yöntemleriyle başlayan dijital görüntü işleme çalışmaları sayesinde evrilmiş; zamanla üç boyutlu modelleme, hareket analizi ve nesne tanıma gibi daha karmaşık ve yüksek düzeyli görevleri kapsamaya başlamıştır (Szeliski, 2010). Bu teknoloji, analog, optik veya dijital formatta elde edilen görüntü verilerinin belirli algoritmalar ve sinyal işleme yöntemleri kullanılarak iyileştirilmesi, dönüştürülmesi ve bu verilerden anlamlı bilgilerin çıkarılması sürecini ifade eder. Süreç, ham görüntülerin sayısal hale getirilmesiyle başlayıp, gürültü azaltma, kontrast artırma, segmentasyon, nesne tanıma ve sınıflandırma gibi aşamaları içerir.

Görüntü işlemenin sunduğu bu çok yönlü imkânlar, teknolojinin tasarım, üretim, güvenlik, sağlık, elektronik, makine mühendisliği ve mimarlık gibi farklı disiplinlerde geniş uygulama alanı bulmasını sağlamıştır. Ayrıca, uygulama yelpazesinin genişlemesi, alandaki araştırma ve geliştirmenin hızla artmasına olanak tanımaktadır (Samtaş ve Gülesin, 2012).

Yapay zekânın felsefi temelleri 17. yüzyıla kadar uzanmakla birlikte, bilimsel temelleri 1950'lerde atılmıştır. İnsan zekâsı gerektiren görevleri otomatik olarak gerçekleştirebilen sistemlerin geliştirilmesini amaçlayan yapay zekâ, basit veri işleme faaliyetlerinin ötesinde; öğrenme, problem çözme, algılama ve karar alma gibi karmaşık bilişsel süreçlerin makineler tarafından taklit edilmesini kapsayan bir bilgisayar bilimi ve mühendisliği disiplini (Russell ve Norvig, 2020). Yapay zekânın görüntü işleme ile entegrasyonu, sağlık alanında tıbbi görüntülerin otomatik analizinden, güvenlik sektöründe gerçek zamanlı yüz ve nesne tanımaya, endüstride kalite kontrol uygulamalarından tarımda hastalık tespitine kadar çok çeşitli alanlarda uygulama bulmuştur (Goodfellow, Bengio ve Courville, 2016). Bu noktada yapay zekâ ve özellikle derin öğrenme yaklaşımları, görüntü işleme alanında devrim niteliğinde gelişmeler sağlamıştır (LeCun, Bengio ve Hinton, 2015). Bununla birlikte, yapay zekânın hızla yaygınlaşması etik kaygıları ve toplumsal sorumlulukları da beraberinde getirmektedir (Jobin, Ienca ve Vayena, 2019).

Bu bölümde, öncelikle yapay zekâ ve görüntü işlemenin tarihsel evrimi sistematik biçimde ele alınacak; ardından farklı uygulama alanlarındaki güncel kullanım örnekleri sunulacaktır. Görüntü işleme süreçlerinde öne çıkan derin öğrenme tabanlı yöntemler, YOLO, R-CNN türevleri ve SSD gibi nesne tespiti ve sınıflandırma algoritmaları kapsamında incelenecek ve

literatürdeki seçili örnek çalışmalar aracılığıyla bu yöntemlerin uygulama alanları ile araştırma eğilimleri ortaya konulacaktır.

2. YAPAY ZEKÂ KAVRAMI

Yapay zekâ (YZ), algoritmik süreçler aracılığı ile insanın bilişsel ve entelektüel yeteneklerini modelleyen, karmaşık görevleri özerk (insan müdahalesi olmadan) veya yarı özerk (kısmen insan müdahalesi ile) biçimde yerine getirebilen ve çevresine uyum sağlayarak olası durumları öngörüp tepki verebilen bir yazılım ve algoritmik sistemler bütünüdür (Sheikh, Prins, ve Schrijvers, 2023). Yapay zekânın kullanım alanları her geçen gün artmakta ve çeşitlenmektedir. Günümüzde özellikle sağlık hizmetleri, iletişim sistemleri, siber güvenlik uygulamaları, savunma sanayi, sesli asistan teknolojileri ve e-ticaret platformlarında yaygın bir şekilde yer almaktadır. Bunun yanı sıra eğitim alanında da giderek artan bir öneme sahiptir. (Uzun, Tümtürk ve Öztürk, 2021).

2.1. Yapay Zekanın Tarihsel Gelişimi

Günümüzde yapay zekânın ilk çalışmaları, 1943'te Warren McCulloch ve Walter Pitts tarafından yapılmıştır. Çalışmalarında beynin nöron yapısını temel alarak her nöronun “açık” veya “kapalı” olabileceği bir model geliştirmiş ve böylece basit hesaplamalar ile mantıksal işlemlerin (AND, OR, NOT) yapılabileceğini göstermişlerdir. Ayrıca, uygun şekilde düzenlenen nöron ağlarının öğrenebileceğini öne sürmüşlerdir; Donald Hebb ise bunu, nöronlar arasındaki bağlantıların deneyimle değiştiği bir kural ile modellemiştir (Hebbian öğrenme) (Russel ve Norvig, 2020). Bu dönemde, yapay zekânın insan zekâsını taklit edebilme potansiyeli tartışılmaya başlanmıştır. 1950 yılında İngiliz matematikçi Alan Turing, “Makine düşünebilir mi?” sorusunu gündeme getirmiş ve insan gibi problem çözebilen makinelerin mümkün olup olmayacağını tartışmıştır. Turing'in önerdiği fikir, daha sonra “Turing Testi” olarak bilinecektir. “Yapay zekâ” terimi ise ilk kez 1956'da John McCarthy tarafından Dartmouth konferansında kullanılmış ve bu tarih alanın ilk resmi konferansı olarak kayda geçmiştir (Arslan, 2020).

Bu dönemin ardından yapay zekâ alanında önemli ilerlemeler kaydedilmiştir. Geliştirilen programlar arasında 1961'de Aziz, 1963'te Benzeşim, 1965'te Eliza, 1970'te Bilgin ve 1979'da Stajyer yer almaktadır (Can ve Sezgin, 2024). Ancak yapay zekâ sistemleri oluşturmak her zaman kolay olmamıştır. 1974-1980 yılları arasında, “AI winter” yani “yapay zekâ kışı” olarak bilinen dönemde, yapay zekâ projelerine yönelik eleştiriler ve olumsuz raporlar yayımlanmış, devletin desteği önemli ölçüde azalmıştır. 1980'lerde ise İngiliz hükümeti, Japonya ile rekabet edebilmek amacıyla

yapay zekâ projelerine yeniden yatırım yaparak bu alanı canlandırmıştır (Öztürk ve Şahin, 2018).

1997 yılında IBM tarafından geliştirilen Deep Blue adlı bilgisayar programı, dünya satranç şampiyonu Garry Kasparov'u yenerek uluslararası düzeyde büyük yankı uyandırmıştır. Söz konusu program, saniyede yaklaşık 200 milyon satranç hamlesini değerlendirebilme kapasitesine sahip olup, Kasparov ile yapılan karşılaşmada üstün performans sergilemiştir. Bu olay, bilgisayarların belirli bilişsel görevlerde insan zekâsını aşabileceğine dair önemli bir kanıt teşkil etmiştir (Coşkun ve Gülleroğlu, 2021).

2000 yılında, MIT Yapay Zekâ Laboratuvarı'nda Dr. Cynthia Breazeal liderliğinde geliştirilen Kismet, insan duygularını algılayabilen ve taklit edebilen öncü bir sosyal robottur. Sensörler, mikrofonlar ve gelişmiş programlama altyapısı ile donatılan Kismet, neşe, heyecan, üzüntü ve korku gibi çeşitli duygusal durumları tanıyabilmekte ve bunlara uygun tepkiler verebilmektedir (Coursera Staff, 2025). 2009 yılında Rajat Raina, Anand Madhavan ve Andrew Ng tarafından yayımlanan çalışma, GPU'ların kullanımını derin öğrenmede devrim yaratarak geniş ölçekli sinir ağlarının eğitilmesini mümkün kılmıştır (Alalaq, 2025). 2015'te yapay zekâ araştırmalarındaki etik ve güvenlik kaygıları öne çıkmış; bilim insanları özerk silahların geliştirilmesinin yasaklanmasını talep eden bir açık mektup imzalamış ve Stanford Üniversitesi araştırmacıları etiketlenmemiş verileri analiz edebilen yöntemler geliştirmiştir. 2018'de yapay zekâ, dil işleme alanında insan zekâsını aşan başarılar göstermiş, 2019'da 17 milyar parametrelili bir sistem geliştirilmiş, 2020'de Oxford Üniversitesi Curial testini sunmuş ve OpenAI, 175 milyar parametrelili GPT-3 modelini kullanıma açmıştır. 2021'de OpenAI, metin tabanlı komutlarla görsel üretebilen DALL-E'yi; Kaliforniya Üniversitesi, San Diego ise hava ile çalışan yumuşak bir dört ayaklı robotu tanıtmıştır. 2023'te ise OpenAI, hem metin hem görsel girdileri işleyebilen multimodal GPT-4 modelini geliştirmiş ve yapay zekânın yeteneklerini önemli ölçüde genişletmiştir (Biswas, 2025; Karjian, 2024). 2024 yılında Avrupa Birliği, yapay zekâ kullanımını düzenleyen ilk kapsamlı yasal çerçeve olan Yapay Zekâ Yasasını yürürlüğe koymuştur. Bu yasa, yapay zekâ sistemlerini risk düzeylerine göre sınıflandırarak, özellikle yüksek riskli uygulamalar için sıkı denetim ve yükümlülükler getirmiştir (European Parliament ve Council, 2024).

Yapay zekâ, sağlık, eğitim, mühendislik gibi birçok sektörde daha etkin kullanılmaya başlanmış, etik, güvenlik ve insan merkezli tasarım tartışmaları ise giderek önem kazanmıştır. Günümüzde yapay zekâ hem akademik araştırmalarda hem de günlük yaşamda karar destek sistemleri, otomasyon

ve etkileşimli teknolojiler aracılığıyla insan hayatına doğrudan katkı sağlayan kritik bir teknoloji olarak konumlanmıştır.

3. GÖRÜNTÜ İŞLEME KAVRAMI

Görüntü işleme, bir görüntüyü alıp üzerinde işlem yaparak ya geliştirilmiş bir görüntü elde etme ya da görüntüye ait çeşitli özellik ve verileri çıkarma sürecidir. Çoğunlukla sayısal yöntemler kullanılsa da optik ve analog teknikler de uygulanabilir. Sayısal görüntü işleme, bilgisayar tabanlı algoritmalar sayesinde daha esnek bir işlem imkânı sunar ve analog yöntemlerde görülebilecek gürültü veya sinyal bozulmalarını minimize eder. Görüntüler genellikle iki veya daha fazla boyutlu olduğundan, bu işlemler çok boyutlu sistemler şeklinde modellenebilir (Lu ve Guo, 2017). Bu teknikler, tıp, askeri, endüstri, coğrafi sistemler ve güvenlik gibi birçok alanda yaygın olarak kullanılmaktadır (Eldem, Eldem ve Palalı, 2017).

3.1. Görüntü İşlemenin Tarihsel Gelişimi

Dijital görüntü işlemenin kökenleri, 1920'lerde gazete endüstrisinde fotoğrafların Atlantik boyunca denizaltı kablolar aracılığıyla iletilmesiyle atılmıştır. Bartlane fotoğraf iletim sistemi sayesinde bir görüntünün Atlantik'i geçme süresi günler yerine birkaç saate indirgenmiş, ancak dijital bilgisayarlar kullanılmadığı için bu çalışmalar modern dijital görüntü işleme kapsamında değerlendirilmemektedir. Alanın sistematik gelişimi, 1940'larda John von Neumann'ın bilgisayar mimarisi ile başlamış ve transistör, entegre devreler, mikroişlemciler ile kişisel bilgisayarların ortaya çıkışıyla hız kazanmıştır. 1960'lı yıllarda Ranger 7 uzay aracından elde edilen Ay görüntüleri bilgisayar tabanlı yöntemlerle işlenmiş ve görüntü bozulmaları düzeltilmiştir. 1970'lerde ise tıpta bilgisayarlı aksiyal tomografi (CT) uygulamaları, medikal görüntülemeye önemli bir dönüm noktası oluşturmuştur (Gonzalez ve Woods, 2018).

1990'lardan itibaren multimedya teknolojileri ve İnternet'in hızlı ilerlemesi, sayısal görüntü işleme alanında köklü değişimlerin önünü açmıştır. Bu dönemde biriken büyük görüntü veri setleri, derin öğrenme ve yapay zekâ yöntemlerinin görüntü analizi uygulamalarında kullanılabilmesini sağlamıştır (Liu, 2024). Krizhevsky ve arkadaşları ILSVRC-2012 yarışmasında evrimsel sinir ağları (CNN) kullanarak görüntü sınıflandırmada çarpıcı bir başarı göstermiş ve bilgisayarla görmede derin öğrenme dönemini başlatmıştır (Brownlee, 2019). Daha sonra, VGGNet, GoogLeNet ve ResNet gibi daha derin ve karmaşık ağ mimarileri geliştirilmiş ve model doğrulukları sürekli artmıştır. Nesne tespiti alanında ise geleneksel HOG+SVM yöntemlerinden, iki aşamalı R-CNN serisi ve tek aşamalı


YOLO ile SSD gibi modern yaklaşımlara geçilmiş hem doğruluk hem de işlem hızında kayda değer iyileşmeler sağlanmıştır. Anlamsal segmentasyon çalışmalarında ise FCN, SegNet ve DeepLab serisi gibi modeller sayesinde hem doğruluk hem de işlem verimliliğinde önemli adımlar atılmıştır (Liu, 2024). Günümüzde dijital görüntü işleme, tıptan uzay araştırmalarına pek çok alanda kullanılmakta ve yapay zekâ ile derin öğrenmenin bu alandaki gücünü ortaya koymaktadır.

4. YAPAY ZEKÂ TABANLI GÖRÜNTÜ İŞLEME UYGULAMALARI

Günümüzde yapay zekâ ve gelişmiş algoritmalar sayesinde dijital görüntüleri analiz etme ve yorumlama kapasitesi önemli ölçüde artmıştır. YZ tabanlı görüntü işleme ve bilgisayarla görme alanındaki ilerlemeler, tıbbi görüntü analizinden endüstriyel kalite kontrol, otonom sürüş sistemleri, sağlık teknolojileri ve uzay uygulamaları gibi birçok sektörde verimliliği ve doğruluğu artıran yenilikçi uygulamaların ortaya çıkmasını sağlamıştır (Munir, 2025). Çalışmanın devamında, bu alanlardaki örnek uygulamalara yer verilerek YZ tabanlı görüntü işleme teknolojilerinin pratikteki yansımaları ele alınacaktır.

4.1. Google LYNA Algoritması: Kanserli Hücre Tespiti

Meme kanseri, kadınlarda en sık rastlanan kanser türlerinden biridir. Erken teşhis için kullanılan görüntü işleme yöntemleri, doktorların hastalığı çok daha erken fark etmesine yardımcı olmaktadır. Bu nedenle tıbbi görüntüleme, uzun süredir bilim dünyasında önemli bir araştırma alanı olarak öne çıkmaktadır (Zhang vd., 2021). Bu bağlamda, Google tarafından geliştirilen LYNA (LYmph Node Assistant) algoritması yüksek kaliteli mamogram ve MR görüntülerinden elde edilen verileri işleyip makine öğrenmesi teknikleriyle metastatik kanseri yüksek doğrulukla analiz eder ve bazen gözden kaçabilecek kanserli bölgeleri de tespit edebilir (Bhattacharya vd., 2024). LYNA, daha önce bildirilenlere kıyasla anlamlı derecede daha yüksek kanser tespit oranları elde etmiştir (Liu vd., 2017).




Resim 1.1. LYNA ile tümör tespiti ve artefakt ayırımı

Kaynak: <https://research.google/blog/applying-deep-learning-to-metastatic-breast-cancer-detection/>

Her iki veri setinde LYNA, metastatik kanser içeren slaytları (mikroskop altında incelenmek üzere hazırlanmış cam lamalar) kansersiz slaytlardan %99 doğruluk oranıyla ayırt edebilmiştir. Ayrıca algoritma, her slaytta hem kanser odaklarını hem de diğer şüpheli bölgeleri doğru şekilde tespit etmiştir; bazı odaklar, patologlar tarafından düzenli olarak fark edilemeyecek kadar küçüktür. LYNA'nın meme kanseri TNM evrelemesinin bazı bileşenlerini destekleyebileceği gösterilmiştir. Ancak bu çalışmalar, sınırlı boyuttaki veri setleri ve her hasta için yalnızca tek bir lenf nodu slaydının (cam lam üzerindeki doku örneği) incelenmesine dayanan simüle edilmiş tanı iş akışları ile sınırlıdır. Klinik süreçlerdeki uygulama ve hasta sonuçlarına etkisinin tam olarak değerlendirilmesi için ek araştırmalara ihtiyaç vardır (Stumpe ve Mermel, 2018).

4.2. SkinVision: Yapay Zeka Tabanlı Cilt Lezyonu Analiz Uygulaması

SkinVision, cilt kanserinin erken tespiti amacıyla geliştirilmiş bir mobil uygulamadır. Uygulama, klinik olarak test edilmiş bir yapay zeka algoritması ile dermatolog uzmanlığını birleştirerek, kullanıcıların cilt lekelerinin fotoğraflarını analiz eder ve potansiyel riskleri değerlendirmektedir.



Resim 1.2. SkinVision Uygulaması

Kaynak: <https://spectrum.ieee.org/skin-monitoring-apps-fail-detect-melanomas>

Uygulamanın algoritması, cilt lezyonlarının risk düzeyini değerlendirmekte ve yüksek riskli vakalarda tıbbi danışmanlık alınmasını önermektedir. SkinVision'ın performansı iki klinik çalışmada incelenmiştir. İlk çalışmada algoritma yalnızca malign melanomu (MM) tespit edebilmekte olup, %73 duyarlılık ve %83 özgüllük göstermiştir. Daha sonraki çalışmada algoritma hem pigmente hem de pigment içermeyen lezyonları analiz edecek şekilde yeniden kalibre edilmiş ve MM'nin yanı sıra bazal hücreli karsinom (BHK) ile bazı premalign lezyonları da tespit edebilir hale gelmiştir. Güncellenmiş algoritmanın duyarlılığı %80, özgüllüğü ise %78 olarak rapor edilmiştir (Udrea vd., 2020). Dr. Shari Marchbein (NYU Dermatoloji), SkinVision gibi uygulamaların farkındalık yaratma ve hastalara bilgi sağlama potansiyeline sahip olduğunu, ancak hiçbir uygulamanın dermatologların yıllara dayanan eğitim ve klinik deneyiminin yerini alamayacağını belirtmektedir (Donahue, 2017).

4.3. Tesla Otopilot: Yapay Zekâ Destekli Sürücüsüz Araç Sistemi

Trafik istatistikleri, kazaların yaklaşık %94'ünün sürücü hataları, uygunsuz manevralar ve dikkatsizlikten kaynaklandığını göstermektedir. Araçların otomatikleşmesi, dikkatsiz sürücülerden kaynaklanan hataların büyük ölçüde azaltılmasını mümkün kılmakta ve böylece kazaların önlenmesinde önemli bir potansiyel sunmaktadır (Bachute ve Subhedar, 2021).

Günümüzde otomotiv endüstrisi, sürücünün araç kullanımındaki rolünü giderek azaltan ve uzun vadede tamamen ortadan kaldırmayı hedefleyen

köklü bir dönüşüm sürecinden geçmektedir (Barabás vd., 2017). Otonom sürüş, bu dönüşümün merkezinde yer almakta ve bazı üst segment araçlarda kısmen kullanılabilmektedir. Bu noktada öne çıkan firmalardan biri de Tesla'dır. Şirket, sadece elektrikli motor teknolojisiyle değil, otonom sürüş alanında yürüttüğü yoğun Ar-Ge çalışmalarıyla da tanınmaktadır. Ayrıca Tesla, kullanıcılarını "beta test sürücüsü" olarak sisteme dâhil ederek, gerçek yol koşullarında veri toplayıp geliştirmelerini hızlandırmaktadır (Tatarek vd., 2017).

Tesla Otopilot sistemi, ön tampondaki radarlar ve araç üzerindeki geniş açılı kameralarla çevresel algılama yapar. Radarlar hareketli nesneleri tespit edebilir, ancak durağan nesneler ve şeritleri göremez. Kameralar ise araçlar, yayalar, bisikletçiler, yol çizgileri ve trafik işaretlerini tanır. Bu veriler, aracın işlemcisi tarafından DNN (Deep Neural Network / Derin Sinir Ağı) ile analiz edilir. DNN, nesneleri yüksek doğrulukla tespit edip 3D modellerini oluşturabilir ve yol yüzeyindeki enkaz veya çukurları algılayarak aracın güvenli şekilde yönlendirilmesini sağlar (Ingle ve Phute, 2016).



Resim 1.3. Tesla Otopilot

Kaynak: <https://tehad.org/2019/08/01/tesla-otopilot-teknolojisi-ile-yeni-bir-cag-baslatti/>

Son yıllarda bu alanda dikkate değer ilerlemeler kaydedilmiş olmasına rağmen, insan sürücülerin otonom sistemlere duyduğu güven tam olarak sağlanabilmiş değildir (Zhan vd., 2025).

4.4. Apple Face ID: Yapay Zekâ Tabanlı Yüz Tanıma Teknolojisi

Apple, tüketici cihazları alanında uzmanlaşmış öncü bir teknoloji şirketi olarak, parmak izi tarayıcılarını Face ID ile değiştirme yönünde önemli

adımlar atmıştır. Face ID, yüz tanıma teknolojisine dayanan bir biyometrik kimlik doğrulama sistemidir. Bu sistem, kullanıcıların cihazlarını güvenli bir şekilde açmalarına, ödemeleri doğrulamalarına ve uygulamalara hızlı bir şekilde erişmelerine olanak sağlamaktadır (Chan vd., 2022).

Yüz algılama algoritması, derin konvolüsyonel ağlar (DCN) kullanılarak iki temel amaç için optimize edilmiştir: birincisi, görüntüde yüz varlığını belirleyen ikili sınıflandırma; ikincisi, yüzün konumunu ve boyutunu tahmin eden regresyon. Karmaşık “teacher” ağlarının çıktılarıyla uyumlu olacak şekilde tasarlanan daha basit ve derin bir “student” ağı, modelin mobil cihazlarda verimli bir şekilde çalışmasını sağlamaktadır. Ağ tamamen konvolüsyonel olduğundan giriş görüntüsünün boyutuna göre dinamik olarak yeniden boyutlandırılabilir. İşlem yükleri GPU ve CPU arasında katman bazında dağıtılarak enerji tüketimi ve sistem performansı optimize edilir. Bu yaklaşımlar sayesinde, kullanıcılar cihazlarında düşük gecikmeli, gizlilik odaklı ve yüksek doğrulukta bir yüz tanıma deneyimi elde edebilir (Apple, 2017).



Resim 1.4. Apple Face ID


Kaynak: <https://support.apple.com/tr-tr/108411>

Apple Face ID, bu süreci TrueDepth kamera sistemi üzerinden gerçekleştirir. Kamera, kullanıcının yüzünü tarayarak derinlik haritası ve kızılötesi görüntü elde eder. Elde edilen veriler cihazın Secure Enclave’inde matematiksel bir temsile dönüştürülür ve bu temsil, önceden kaydedilmiş yüz verileri ile karşılaştırılarak doğrulama sağlanır (Apple, 2024). Böylece algoritmanın eğitim ve optimizasyon süreçleri ile gerçek zamanlı biyometrik doğrulama, kullanıcı gizliliğini koruyarak etkin bir şekilde bütünleşir.

4.5. Surya: Yapay Zekâ Destekli Güneş Aktivitesi Tahmini

Surya, NASA ve IBM iş birliğiyle geliştirilen, Güneş'in davranışlarını modelleyen temel bir heliofizik yapay zekâ modelidir. Heliofizik, Güneş'in ve güneş sisteminin etkilerini inceleyerek uzay havası olaylarını anlamayı sağlar. Bu bağlamda Surya, Solar Dynamics Observatory (SDO) verileri kullanılarak geliştirilmiş bir foundation model olarak büyük önem taşır (Koehl, 2025).

Sanskritçe'de "Güneş" anlamına gelen Surya, çok kanallı ve doğal çözünürlüklü SDO gözlemleriyle eğitilmiş, modern kendinden denetimli öğrenme paradigmasını kullanan bir modeldir. Model, güneş patlamaları ve uzay havasını tahmin etme, aktif bölge oluşumunu izleme, aktif bölge segmentasyonu ve güneş rüzgârı tahmini gibi uygulamalarda tutarlı ve aktarılabilir temsiller sunarak veri odaklı heliofizik çalışmalarına önemli katkılar sağlamaktadır (Roy vd., 2025)



Resim 1.5. Üst sırada gerçek (ground truth) güneş aktivitesi, alt sırada Surya modeli tarafından tahmin edilen aktivite gösterilmektedir.

Kaynak: <https://science.nasa.gov/science-research/artificial-intelligence-model-heliophysics/>

Ayrıca Surya, açık kaynak olarak erişilebilir ve SuryaBench veri setleri ile birlikte araştırmacıların Güneş hakkında daha fazla bilgi edinmesini ve yeni uygulamalar geliştirmesini kolaylaştırmaktadır (Martineau ve Murphy, 2025). Bu özellikleri sayesinde model, uzay hava durumu tahmininde ileri düzey otomasyon ve analiz imkânı sunmaktadır.


5. GÖRÜNTÜ İŞLEMEDE YAPAY ZEKÂ YAKLAŞIMLARI

5.1. Derin Öğrenme ve Görüntü İşleme İlişkisi

Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla verinin çok seviyeli soyutlamalarını ve yüksek seviyeli özelliklerini otomatik olarak

öğrenen bir makine öğrenimi alt alanıdır (LeCun, Bengio ve Hinton, 2015). Bu yöntem, karmaşık veri yapılarının keşfedilmesini sağlar ve her katmandaki temsiller, önceki katmandan öğrenilen bilgilerle oluşturulur. Özellikle görüntü işleme alanında, konvolüsyonel sinir ağları (CNN) yerel özellik çıkarımı ve hiyerarşik temsil yetenekleri sayesinde geleneksel yöntemlerin sınırlarını aşarak üstün performans göstermektedir (Krizhevsky, Sutskever ve Hinton, 2012). Veri miktarı ve karmaşıklığının artmasıyla geleneksel yöntemler yetersiz kalmaya başlamış, görüntü işleme alanında yüksek doğruluk ve güçlü öğrenme kabiliyeti sunan derin öğrenme yöntemleri öne çıkmıştır (Tan, Aydemir ve Ersoy, 2021).

Derin öğrenme, dünyayı kavramlar ve temsillerden oluşan katmanlı bir hiyerarşi olarak öğrenme yeteneği sayesinde diğer makine öğrenmesi yöntemlerinden ayrılır. Her bir kavram, daha basit kavramlarla bağlantılıdır ve daha soyut temsiller, daha temel temsillerin birleşimiyle hesaplanır. Bu yapı, derin öğrenmeye hem yüksek güç hem de esneklik kazandırır. (Bengio, Goodfellow ve Courville, 2017). Şekil 1, bu farklı yapay zekâ disiplinleri arasındaki ilişkiyi göstermektedir.



Şekil 1.1. Venn Diyagramı

Derin öğrenme, farklı veri türlerinde yüksek başarı göstererek doğal dil işleme, görüntü analizi, ses tanıma, otonom sistemler ve biyomedikal gibi birçok alanda yaygın şekilde kullanılmaktadır.

Wang, Wang ve Zhang (2019), konvolüsyonel sinir ağlarının (CNN) tıbbi görüntü analizinde kullanımını, özellikle tiroid kanseri teşhisi üzerinde uygulamalı bir örnekle incelemişlerdir. Çalışma, CNN tabanlı modellerin hastalık teşhisi ve tedavisinde etkinliğini artırmak için kullanılan stratejilere dair önemli bir bakış sunmaktadır (Wang, Wang ve Zhang, 2019).

Chu, ve arkadaşları (2024), ortaöğretimde dil analiz araçlarının geliştirilmesi için derin öğrenme ve görüntü tanıma teknolojilerini kullanmışlardır. Dil davranışını analiz etmek amacıyla kapsamlı bir çerçeve oluşturmuş, çevrimiçi ders videolarında görüntü işleme ve karakter tanıma teknikleri ile veri madenciliği gerçekleştirilmiştir. Deneysel bulgular, konuşma hızı, anlaşılabilirlik ve içerik benzerliği gibi göstergelerde anlamlı farklılıklar olduğunu ortaya koymuştur. Çalışma, etkili öğretim stratejilerinin belirlenmesine önemli katkılar sağlamaktadır (Chu vd., 2024).

Duja, Khan ve Alsuhaibani (2024), kamu ve özel sektörde kullanılan güvenlik kameralarından elde edilen büyük ve karmaşık görsel verilerde anomali tespiti için geliştirilen güncel derin öğrenme tabanlı yöntemleri incelemişlerdir. Çalışmada, konvolüsyonel sinir ağları (CNN), YOLO, transformer modelleri ve oto-enkoderler gibi yaklaşımların güçlü yönleri, veri kümelerinin sınırlamaları ve yöntemler arasındaki güçlü ve zayıf yönler arasındaki denge analiz edilmiştir. Bu sayede, gerçek zamanlı ve yüksek doğrulukta Video Gözetim Anomali Tespiti (VSAD) sistemlerinin geliştirilmesine katkı sağlanması hedeflenmiştir (Duja, Khan ve Alsuhaibani, 2024).

5.2. Derin Öğrenme Tabanlı Nesne Tespiti ve Sınıflandırma Algoritmaları

Görüntü işleme ve bilgisayarla görme alanlarında nesne tespiti, bir görüntü veya video karesindeki nesnelerin konumlarını ve sınıflarını otomatik olarak belirleyen kritik bir adımdır. Genellikle iki aşamada gerçekleşir: önce nesne belirginleştirilir, ardından arka plandan ayrılır. Nesnenin görünüm ve şekil özellikleri tespit için temel oluşturur. Nesne tespiti, uygun algoritmanın seçimini ve sonraki işlemlerin başarısını doğrudan etkiler (Tan, Aydemir ve Ersoy, 2021). Bu alanda geliştirilmiş başlıca yapay zekâ tabanlı algoritmalara aşağıda yer verilmiştir.


5.2.1 YOLO (You Only Look Once)

Derin öğrenme tabanlı nesne tespiti algoritmaları, gerçek zamanlı tespit ve konumlandırma alanında yüksek başarı sağlamaktadır. Doğru ve etkin nesne tespiti yöntemleri, sağlık alanında çeşitli hastalıkların tanı ve tedavisinde

uzmanlara önemli destek sunmaktadır. Bu yöntemlerden biri olan You Only Look Once (YOLO) algoritması bilgisayarla görme alanında büyük ilgi uyandırmıştır (Ragab vd., 2024). YOLO, bilgisayarla görme topluluğunda yaygın kabul gören, gerçek zamanlı ve uçtan uca çalışan bir nesne tespit algoritmasıdır. ((Diwan, Anirudh ve Tembhrne, 2022).

Nesne tespiti alanında yüksek hız ve etkinlik sağlayan YOLO algoritması, geleneksel yöntemlere kıyasla önemli avantajlar sunmaktadır. Geleneksel nesne tespit yaklaşımları, karmaşık mimarileri ve yüksek hesaplama maliyetleri nedeniyle sınırlı verimlilik ve düşük gerçek zamanlı performans sergilemektedir. Buna karşın, YOLO algoritması, nesne tespiti ve sınıflandırma süreçlerini tek bir ağ yapısı altında bütünleştirerek hem daha sade bir mimari hem de yüksek doğruluk ve hızlı işlem kabiliyeti sağlamaktadır. Bu özellikleriyle YOLO, gerçek zamanlı uygulamalar için etkili bir çözüm olarak öne çıkmaktadır (Kang vd., 2025).

YOLO mimarisi üç ana bileşenden oluşur: Backbone, Neck ve Head. Backbone, giriş görüntüsünden anlamlı özellikler çıkarır. Neck, farklı katmanlardan elde edilen özellik haritalarını birleştirerek Head'e aktarır. Head ise bu özellikler üzerinden nesnelerin konumlarını, varlık skorlarını ve sınıf tahminlerini yapar. Bu bileşenlerin tasarımı ve kullanımı, modelin hız ve doğruluk performansını doğrudan etkiler ve uygulamanın ihtiyaçlarına göre değişir (Ragab vd., 2024). Şekil 2.'de YOLOv5 versiyonu örnek olarak gösterilmiştir.



Şekil 1.2. YOLOv5 mimarisi

YOLO algoritmasının nesne tespitinde sağladığı hızlı ve etkili sonuçlar, günümüzde bu yöntemin birçok çalışmada yaygın olarak tercih edilmesini sağlamıştır (Karadağ ve Arı, 2023).

Aldughayfiq vd. çalışmalarında (2023), bası ülserlerinin erken tespiti ve sınıflandırılması için YOLOv5 modelini kullanmışlardır. Veri artırma ile desteklenen bu yöntem, önceki CNN tabanlı yaklaşımlara kıyasla daha

yüksek doğruluk ve etkinlik sağlamaktadır. Çalışma, erken tanıyla hasta bakımını iyileştirme ve sağlık maliyetlerini azaltma potansiyeli taşımaktadır (Aldughayfiq vd., 2023).

Torun, Tatlı ve Önalın çalışmalarında (2025), kamusal alanlarda sigara içme yasağının özellikle dumansız hava sahalarında daha etkin uygulanmasını sağlamak amacıyla YOLOv5 tabanlı gerçek zamanlı bir tespit modeli geliştirmişlerdir. Veri artırma teknikleriyle genişletilen eğitim setiyle yüksek performans gösteren model, tespit ettiği sigara içme davranışlarını sesli uyarı sistemiyle anında bildirerek yasağa uyumu artırmayı ve pasif içicilik riskini azaltmayı hedeflemiştir. Bu çalışma, halk sağlığını koruma ve dumansız hava sahası uygulamalarını güçlendirme konusunda yenilikçi ve etkili bir otomatik izleme çözümü sunmuştur (Torun, Tatlı ve Önalın, 2025).

5.2.2 R-CNN, Fast R-CNN, Faster R-CNN ve Mask R-CNN Modelleri

Son zamanlarda nesne tanıma ve tespiti alanında R-CNN ve onun geliştirilmiş versiyonları olan Fast R-CNN, Faster R-CNN ve Mask R-CNN yaygın şekilde kullanılmaktadır.

R-CNN (Region-based Convolutional Neural Network), nesneleri tespit ve konumlandırmak için geliştirilmiş derin öğrenme tabanlı bir nesne tespit modelidir. Model, bir görüntüdeki nesneleri kapsayan bounding box'lar (sınırlayıcı kutu) oluşturur ve her nesnenin kategorisini belirler. R-CNN ve varyantları, nesne tespiti alanında doğruluk ve verimliliği artırarak geleneksel yöntemlerin sınırlamalarını aşan önemli modellerdir (Jiang ve Learned-Miller 2017).

Fast R-CNN, R-CNN'in hesaplama yükünü azaltmak için tüm önerilen bölgelerde (region proposals) konvolüsyonel özellikleri paylaşır ve ROI (Region of Interest) pooling katmanı ile bölgeye özgü özellikleri çıkarır (Girshick, 2015; Sumit vd., 2024). Faster R-CNN, nesne tespitini iki aşamalı bir süreçle gerçekleştirir. İlk aşamada, Region Proposal Network (RPN) olası sınırlayıcı kutuları önerir (Ren vd., 2015). İkinci aşamada, Fast R-CNN'in CNN ve RoIPool bileşenleri kullanılarak her önerilen kutudan özellikler çıkarılır ve bu özellikler sınıflandırma ile bounding box regresyonu işlemleri için kullanılır (Huang vd., 2017).

Mask R-CNN, Faster R-CNN'in genişletilmiş bir sürümüdür ve iki aşamalı yapıyı sürdürür (Fang vd. 2023). İlk aşamada, RPN kullanılarak görüntü üzerinde olası nesne bölgeleri belirlenir. İkinci aşamada, her önerilen bölge sınıflandırılır ve hem sınırlayıcı kutular hem de piksel düzeyinde

maske tahminleri elde edilir (He, Gkioxari, Dollár, ve Girshick, 2017). Bu sayede, bir görüntüdeki her bir nesne detaylı bir şekilde tanımlanabilir ve segmentlenebilir. R-CNN ve türevlerinin sunduğu olanaklar sağlık, eğitim ve güvenlik gibi farklı alanlarda yapılan çalışmalarda da kendini göstermektedir.

Fernández-Carrobles ve arkadaşları (2019) çalışmalarında, halka açık alanlarda güvenliği artırmak amacıyla silah ve bıçak tespiti için Faster R-CNN tabanlı bir sistem geliştirmişlerdir. Farklı CNN mimarileri karşılaştırılmış ve sonuçlar önceki çalışmalara göre geliştirilmiştir (Fernández-Carrobles, Deniz ve Maroto, 2019).

Su ve diğerleri (2021) çalışmalarında, akıllı gözlükler üzerinden artırılmış gerçeklik destekli bir eğitim sistemi geliştirmişlerdir. Sistem, Mask R-CNN tabanlı nesne tespiti ve işaret parmağı analizleri ile etkin bir şekilde çalışmakta ve farklı ışık koşullarında da güvenilir sonuçlar vermektedir (Su vd., 2021).


Huang ve arkadaşları (2022) çalışmalarında, diyabetik ayak ülserlerinin (DFU) görüntü tanıma ile sınıflandırılması, konumlandırılması ve boyutunun belirlenmesi üzerine odaklanmışlardır. Hekimlerin etiketlediği veriler kullanılarak Fast R-CNN yöntemiyle makine öğrenimi modülleri eğitilmiş ve yara tespitinde %90 doğruluk elde edilmiştir (Huang vd., 2022).

5.2.3 SSD (Single Shot MultiBox Detector)

Bilgisayarlı görmede nesne tespiti, özellikle gerçek zamanlı uygulamalarda ve sınırlı hesaplama gücü bulunan ortamlarda önemli bir zorluktur (Juhartini, Arwidiyarti ve Desmiwa, 2025). Bu bağlamda, Liu ve arkadaşları (2016) tarafından geliştirilen Single Shot MultiBox Detector (SSD) modeli, sınıflandırma ve konumlandırma işlemlerini tek aşamada gerçekleştiren hızlı ve verimli bir nesne algılama yöntemi olarak öne çıkar. SSD, arka plan sınıfını da tahmin ederek yanlış pozitifleri azaltır. Ayrıca, farklı ölçek ve en-boy oranlarına sahip varsayılan kutular (default boxes; önceden tanımlanmış kutular) üzerinden çok ölçekli özellik haritaları kullanarak hem küçük hem de büyük nesneleri etkin şekilde algılar (Liu vd., 2016).

Model, bölge önerisi aşamasını ortadan kaldırdığı için iki aşamalı yöntemler olan Faster R-CNN'e göre daha hızlıdır. Tek karedeki tahminler, maksimum olmayan baskılama (Non-Maximum Suppression – NMS; aynı nesnenin birden fazla kez tespit edilmesini önlemek için en yüksek olasılığa sahip kutuyu seçip çakışan diğerlerini eler) yöntemi ile işlenir. SSD'nin erken katmanları, standart bir görüntü sınıflandırma mimarisine dayanır ve çok ölçekli özellik haritaları sayesinde farklı boyut ve şekillerde kutular modellenir. Modelin eğitimi sırasında, gerçek nesnelerin (ground truth) bilgileri bu sabit kutularla eşleştirilir (assignment); böylece hangi kutunun hangi nesneyi

temsil ettiği öğrenilir (López-Montiel vd., 2021). SSD mimarisinin genel yapısı Şekil 3.'te gösterilmektedir.



Şekil 1.3. SSD Mimarisi

Kaynak: Liu vd., (2016)

Bu özellikleri sayesinde SSD, hız ve doğruluk arasında dengeli bir performans sunar ve gerçek zamanlı nesne tespiti gerektiren uygulamalarda güçlü bir seçenek olarak değerlendirilir. Mevcut literatürde birçok çalışma bulunmakla birlikte, gerçek dünyadaki uygulamaları hâlâ sınırlıdır (Juhartini, Arwidiyarti ve Desmiwati, 2025).

Chen ve arkadaşları (2021) çalışmalarında, gastrointestinal endoskopi görüntülerinde mevcut polip ve lezyonların gözden kaçma olasılığını (yüksek kaçırma oranı) ve yanlış tanı oranlarını azaltmayı hedeflemişlerdir. Bu amaçla, VGG-16 tabanlı ve ek çok ölçekli katmanlar içeren SSD tabanlı bir otomatik polip tespit yöntemi geliştirmişlerdir. Manuel tespit ve Mask R-CNN ile karşılaştırıldığında, önerilen yöntem %95,74 mAP ile daha yüksek doğruluk sağlamış; manuel tespitten %12,4, Mask R-CNN'den ise %5,7 daha iyi sonuç vermiştir. Ayrıca, tek kare görüntüde manuel tespitten 8,41 kat daha hızlı çalışarak, derin öğrenmenin gastrointestinal görüntü tanımadaki etkinliğini göstermiştir (Chen vd., 2021).

Cao ve Liu, çalışmalarında (2024) sınıf ortamlarında öğrenci davranışlarını gerçek zamanlı olarak tespit etmek için MobilNet mimarisi ile optimize edilmiş SSD tabanlı bir model geliştirmişlerdir. Çeşitli öğrenci davranışlarını içeren 2.500 görüntü seti, ön işleme yöntemleriyle hazırlanarak modelin eğitiminde kullanılmış; modelin performansı precision, recall ve FPS metrikleri ile değerlendirilmiştir. Bu yaklaşım, eğitimde davranış izleme teknolojilerinde önemli bir gelişme sağlamıştır (Cao ve Liu, 2024).

6. SONUÇ

Yapay zekâ ve görüntü işleme alanındaki gelişmeler, günümüz teknolojisinin en önemli itici güçlerinden biri olarak öne çıkmaktadır. Bu teknolojiler, yalnızca veri analizi ve nesne tanıma gibi temel uygulamalarla sınırlı kalmayıp, sağlık, güvenlik, ulaşım, eğitim ve uzay araştırmaları gibi farklı disiplinlerde de somut çözümler sunmaktadır. Modern algoritmalar, özellikle derin öğrenme ve yapay sinir ağları, karmaşık verileri yüksek doğruluk ve hızla işleyebilme yetenekleri sayesinde bu uygulamaların etkinliğini artırmakta ve farklı sektörlerde uygulanabilirliğini mümkün kılmaktadır.

Sağlık alanında erken teşhis ve hastalık sınıflandırma sistemleri klinik süreçleri desteklerken insan hatasını azaltmakta; güvenlikte yüz tanıma ve anomali tespit uygulamaları izleme ve kontrol mekanizmalarını güçlendirmektedir. Endüstride ise üretim süreçlerinin optimizasyonu ve hata tespiti, kaynakların daha verimli kullanılmasına katkı sağlamaktadır. Uzay araştırmalarında yapay zekâ destekli görüntü işleme sistemleri, güneş aktiviteleri ve diğer kozmik olayların daha doğru öngörülmesini sağlayarak bilimsel bilginin artmasına imkân tanımaktadır.

Elde edilen bulgular, yapay zekâ ve görüntü işleme teknolojilerinin yalnızca teorik bir alan olmadığını, günlük yaşam ve endüstriyel uygulamalarda somut katkılar sağladığını göstermektedir. Bu teknolojiler, bilgiye dayalı karar alma süreçlerinde destekleyici bir rol üstlenerek, toplumsal ve endüstriyel alanlarda daha etkin ve verimli uygulamaların geliştirilmesine olanak tanımaktadır. Gelecekte, veri hacimlerinin artması ve algoritmaların daha da geliştirilmesiyle, yapay zekâ tabanlı görüntü işleme sistemlerinin farklı sektörlerdeki sorunları çözmede daha fazla fayda sağlaması ve süreçlerin iyileştirilmesine önemli katkılarda bulunması beklenmektedir. Bu bağlamda, yapay zekâ ve görüntü işlemenin, teknoloji ve toplum arasındaki etkileşimi güçlendiren, yenilikçi ve sürdürülebilir çözümlerin temel taşlarından biri haline gelmesi öngörülmektedir.

Kaynakça

- Alalaq, A. S. (2025). The history of the artificial intelligence revolution and the nature of generative AI work. *DS Journal of Artificial Intelligence and Robotics*, 2(4), 1–15.
- Aldughayfiq, B., Ashfaq, F., Jhanjhi, N. Z., ve Humayun, M. (2023). YO-LO-based deep learning model for pressure ulcer detection and classification. *Healthcare*, 11(9), 1222.
- Apple. (2017). An On-device Deep Neural Network for Face Detection. Erişim Tarihi: 25.08.2025 <https://machinelearning.apple.com/research/face-detection>
- Apple. (2024). About Face ID advanced technology. Erişim Tarihi: 25.08.2025 <https://support.apple.com/en-us/102381>
- Arslan, K. (2020). Eğitimde Yapay Zekâ ve Uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Bachute, M. R., ve Subhedar, J. M. (2021). Autonomous driving architectures: Insights of machine learning and deep learning algorithms. *Machine Learning with Applications*, 6, 100164.
- Barabás, I., Todoruț, A., Cordoș, N., ve Molea, A. (2017). Current challenges in autonomous driving. *IOP Conference Series: Materials Science and Engineering*, 252(1), 012096.
- Bhattacharya, S., Saleem, S. M., Singh, A., Singh, S., ve Tripathi, S. (2024). Empowering precision medicine: Regenerative AI in breast cancer. *Frontiers in Oncology*, 14, 1465720.
- Biswas, H. (2025, 22 January). History of AI: A Fascinating Journey Through Time. *Dorik Blog*. Erişim Tarihi:23.08.2025 <https://dorik.com/blog/history-of-ai>
- Brownlee, J. (2019, Temmuz 5). A Gentle Introduction to the ImageNet Challenge (ILSVRC). *Machine Learning Mastery*. Erişim Tarihi: 24.08.2025 <https://machinelearningmastery.com/introduction-to-the-imagenet-large-scale-visual-recognition-challenge-ilsvrc/>
- Can, Ö., ve Sezgin, M. (2024). Yapay zekâ teknolojilerinin kurumsal iletişimdeki rolünün değerlendirilmesi. *Uluslararası Sosyal Bilimler Akademik Araştırmalar Dergisi*, 8(1), 103-114. <https://doi.org/10.58201/utsobilder.1497333>
- Cao, Y., ve Liu, D. (2024). Optimization of student behavior detection algorithm based on improved SSD algorithm. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 15(5).
- Chan, J. (2022). Facial recognition technology and ethical issues. *Proceedings of the Wellington Faculty of Engineering Ethics and Sustainability Symposium*.

- Chen, X., Zhang, K., Lin, S., Dai, K. F., ve Yun, Y. (2021). Single shot multibox detector automatic polyp detection network based on gastrointestinal endoscopic images. *Computational and Mathematical Methods in Medicine*, 2021, 2144472.
- Chu, L., Liu, Y., Zhai, Y., ve Wang, D. (2024). The use of deep learning integrating image recognition in language analysis technology in secondary school education. *Scientific Reports*, 14, 2888.
- Coşkun, F., ve Gülleroğlu, H. D. (2021). Yapay zekânın tarih içindeki gelişimi ve eğitimde kullanılması. *Ankara University Journal of Faculty of Educational Sciences (JFES)*, 54(3), 947-966.
- Coursera Staff. (2025, May 23). The History of AI: A Timeline of Artificial Intelligence. Coursera. Erişim Tarihi:23.08.2025 <https://www.coursera.org/articles/history-of-ai>
- Diwan, T., Anirudh, G., ve Tembhurne, J. V. (2022). Object detection using YOLO: Challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6), 9243–9275.
- Donahue, R. (2017, Ekim 24). A woman discovered skin cancer with an app. Allure. Erişim Tarihi: 23.08.2025 <https://www.allure.com/story/woman-discovered-skin-cancer-with-app>
- Duja, K. U., Khan, I. A., ve Alsuhaibani, M. (2024). Video surveillance anomaly detection: A review on deep learning benchmarks. *IEEE Access*, 12, 164811–164842.
- Eldem, A., Eldem, H., ve Palalı, A. (2017). Görüntü işleme teknikleriyle yüz algılama sistemi geliştirme. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 6(2), 44–48.
- European Parliament ve Council. (2024). Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence. *Official Journal of the European Union*, L 1689. Erişim Tarihi:23.08.2025 <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>
- Fang, S., Zhang, B., ve Hu, J. (2023). Improved Mask R-CNN multi-target detection and segmentation for autonomous driving in complex scenes. *Sensors*, 23(8), 3853.
- Fernández-Carrobles, M. M., Deniz, O., ve Maroto, F. (2019). Gun and knife detection based on Faster R-CNN for video surveillance. In *Pattern Recognition and Image Analysis* (Vol. 11868, pp. 438–446).
- Girshick, R. (2015). Fast R-CNN. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 1440–1448.
- Gonzalez, R. C., ve Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson Education.
- Goodfellow, I., Bengio, Y., ve Courville, A. (2016). *Deep learning*. MIT Press.

- He, K., Gkioxari, G., Dollár, P., ve Girshick, R. (2017). Mask R-CNN. In Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2961–2969.
- Huang, H. N., Zhang, T., Yang, C. T., Sheen, Y. J., Chen, H. M., Chen, C. J., ve ark. (2022). Image segmentation using transfer learning and Fast R-CNN for diabetic foot wound treatments. *Frontiers in Public Health*, 10, 969846.
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., ... ve Murphy, K. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 7310–7311.
- Ingle, S., ve Phute, M. (2016). Tesla Autopilot: Semi Autonomous Driving, an Uptick for Future Autonomy. *International Research Journal of Engineering and Technology (IRJET)*, 3(9), 369–372.
- Jiang, H., ve Learned-Miller, E. (2017). Face detection with the Faster R-CNN. In Proceedings of the 12th IEEE International Conference on Automatic Face and Gesture Recognition (FG), 650–657.
- Juhartini, S., Arwidiyarti, D., ve Desmiwati. (2025). Single Shot Multibox Detector (SSD) in object detection: A review. *International Journal of Advanced Computing and Informatics*, 1(2), 118–127.
- Kang, J., Hu, X., Liu, Y., Zhang, L., ve Cao, J. (2025). Object detection YOLO algorithms and their industrial applications: Overview and comparative analysis. *Electronics*, 14(6), 1104.
- Karadağ, B., ve Arı, A. (2023). Akıllı mobil cihazlarda YOLOv7 modeli ile nesne tespiti. *Politeknik Dergisi*, 26(3), 1207–1214.
- Karjian, R. (2024, September 24). The history of artificial intelligence: Complete AI timeline. TechTarget. Erişim Tarihi:23.08.2025 <https://www.techtarget.com/searchenterpriseai/tip/The-history-of-artificial-intelligence-Complete-AI-timeline>
- Koehl, D. (2025, August 20). NASA and IBM's 'Hot' new AI model uncovers the Sun's secrets. NASA Science. Erişim Tarihi: 25.08.2028 <https://science.nasa.gov/science-research/artificial-intelligence-model-heliophysics/>
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25(2), 1097–1105.
- LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Liu, C. (2024). A review of digital image processing techniques and future prospects. *International Journal of Computer Science and Information Technology*, 4(3), Article 22.

- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., ve Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. *Lecture Notes in Computer Science*, 9905, 21–37.
- Liu, Y., Gadeipalli, K., Norouzi, M., Dahl, G. E., Kohlberger, T., Boyko, A., Venugopalan, S., Timofeev, A., Nelson, P. Q., Corrado, G. S., Hipp, J. D., Peng, L. H., ve Stumpe, M. C. (2017). Detecting cancer metastases on gigapixel pathology images. *arXiv preprint arXiv:1703.02442*.
- López-Montiel, J., Rodríguez, J., ve García, M. (2021). Evaluation of algorithms for traffic sign detection. *International Journal of Advanced Computer Science and Applications*, 12(5), 118–127.
- López-Montiel, M., Orozco-Rosas, U., Sánchez-Adame, M., Picos, K., ve Ross, O. H. M. (2021). Evaluation method of deep learning-based embedded systems for traffic sign detection. *IEEE Access*, 9, 101217–101238.
- Lu, Z.-M., ve Guo, S.-Z. (2017). *Lossless information hiding in images*. Syngress.
- Martineau, K., ve Murphy, M. (2025, August 20). Surya: A heliophysics AI model of the Sun. IBM Research. Erişim Tarihi: 25.08.2025 <https://research.ibm.com/blog/surya-heliophysics-ai-model-sun>
- M. C., Su, Zhang, T., Yang, C. T., Sheen, Y. J., Chen, H. M., ve Chen, C. J. (2021). Smart training: Mask R-CNN oriented approach. *Expert Systems with Applications*, 185, 115595.
- Munir, A. (Ed.). (2025). *Artificial Intelligence-Based Image Processing and Computer Vision*. AI, 6(2). MDPI.
- Öztürk, K., ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-I Vekayi*, 6(2), 25–36.
- Prins, C., Sheikh, H., ve Schrijvers, E. (2023). *Mission AI: The new system technology (Research for Policy)*. Springer.
- Ragab, M. G., et al. (2024). A comprehensive systematic review of YOLO for medical object detection (2018 to 2023). *IEEE Access*, 12, 57815–57836.
- Ren, S., He, K., Girshick, R., ve Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28, 91–99.
- Roy, S., vd., (2025). Surya: Foundation model for heliophysics. *arXiv*.
- Russell, S. J., ve Norvig, P. (2020). *Artificial intelligence: A modern approach (4th ed.)*. Pearson.
- Samtaş, G., ve Gülesin, M. (2012). Sayısal görüntü işleme ve farklı alanlardaki uygulamaları. *Ejovoc*, 2(1), 85–97.
- Stumpe, M., ve Mermel, C. (2018, Ekim 12). Applying deep learning to metastatic breast cancer detection. *Google Research Blog*. Erişim Tarihi:

- hi: 23.05.2025 <https://research.google/blog/applying-deep-learning-to-metastatic-breast-cancer-detection/>
- Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer, London, UK.
- Tan, F. G., Yüksel, A. S., Aydemir, E., ve Ersoy, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*, 25, 159–171.
- Tatarek, T., Kronenberger, J., ve Handmann, U. (2017). Functionality, advantages and limits of the Tesla Autopilot (Internal Report 17-04). Hochschule Ruhr West.
- Torun, N. K., Tatlı, O., ve Önalın, M. (2025). Kamu sağlığı ve çevresel sürdürülebilirlik için YOLOv5 tabanlı sigara tespiti ve sesli uyarı sistemi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 13(2), 746–762.
- Udrea, A., Mitra, G. D., Costea, D., Noels, E. C., Wakkee, M., Siegel, D. M., de Carvalho, T. M., ve Nijsten, T. E. C. (2020). Accuracy of a smartphone application for triage of skin lesions based on machine learning algorithms. *Journal of the European Academy of Dermatology and Venereology*, 34(3), 648–655.
- Uzun, Y., Tümtürk, A. Y., ve Öztürk, H. (2021). Günümüzde ve gelecekte eğitim alanında kullanılan yapay zekâ. In *1st International Conference on Applied Engineering and Natural Sciences (ICAENS 2021)*.
- Wang, J., Wang, S., ve Zhang, Y. (2019). Diagnosis of thyroid cancer using deep convolutional neural network models. *The Lancet Oncology*, 20(3), e129–e130.
- Yongqing, C., ve Dan, L. (2024). Optimization of student behavior detection algorithm based on improved SSD algorithm. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 15(5).
- Zhang, Y.-n., Xia, K.-r., Li, C.-y., Wei, B.-l., ve Zhang, B. (2021). Review of breast cancer pathological image processing. *BioMed Research International*, 2021, Article 1994764.
- Zhan, Y., Liu, X., Li, Z., ve Liang, J. (2025). Autonomous car-following via reinforcement learning with style-specific reward design. *Proceedings of the 37th Chinese Control and Decision Conference (CCDC)*, 297–304.