

Sectoral Application Analysis of Studies Made with Deep Learning Models

Merve YILMAZ¹, Hasan ŞAHİN², Aytaç YILDIZ^{3*}

¹ Graduate Education Institute, Bursa Technical University, Bursa, Turkey
0000-0002-1236-355X, merveyyy016@gmail.com

² Department of Industrial Engineering, Bursa Technical University, Bursa, Turkey
0000-0002-0729-633X, aytac.yildiz@btu.edu.tr

³ Department of Industrial Engineering, Bursa Technical University, Bursa, Turkey
0000-0002-8915-000X, h.sahin@btu.edu.tr

Abstract: Deep learning is a sub-branch of machine learning that provides the opportunity to work with multidimensional data in multi-layered architectures using artificial neural network algorithms. Thanks to deep learning methods, natural language processing, image processing, visual object detection, drug discovery, etc. success rates have increased significantly. Deep learning provides convenience to researchers in subjects such as near-human-level image classification, human-level speech recognition, text reading and vocalization by exploring the complex structure of multidimensional data sets by using back propagation algorithm. Due to these features, deep learning and image processing methods have started to be used rapidly in the solution of many problems in many fields today. In the study, firstly, summary information about artificial intelligence and deep learning is given. Then, the studies using deep learning methods are examined and examples of how deep learning is applied to which area are given. At the end of the study, a summary table containing the aims of the examined articles, the methods they used, their contributions to the literature and the results they obtained was presented, allowing the researchers to obtain preliminary information about the methods they will use in their studies.

Keywords: Artificial intelligence, Deep learning, Image processing, Object detection

Derin Öğrenme Modelleriyle Yapılan Çalışmaların Sektörel Uygulama Analizi

Özet: Derin öğrenme, yapay sinir ağları algoritmalarını kullanarak çok katmanlı mimarilerde çok boyutlu veriler ile çalışma imkânı sağlayan, makine öğrenmesi alanının bir alt dalıdır. Derin öğrenme metotları sayesinde doğal dil işleme, görüntü işleme, görsel nesne tespiti, ilaç keşfi, vb. alanlarda ciddi bir şekilde başarı oranı artmıştır. Derin öğrenme, geri yayılım algoritmasını kullanıp çok boyutlu veri setlerinin karmaşık yapısını keşfederek insan düzeyine yakın görüntü sınıflandırması, insan düzeyinde konuşma tanıma, metin okuma ve seslendirme gibi konularda araştırmacılara kolaylıklar sağlamaktadır. Bu özelliklerinden dolayı derin öğrenme ve görüntü işleme yöntemleri günümüzde birçok alanda birçok problemin çözümünde hızlı bir şekilde kullanılmaya başlanmıştır. Bu çalışmada ilk olarak yapay zekâ ve derin öğrenmeye ait özet bilgiler verilmiştir. Daha sonra, derin öğrenme yöntemleri kullanılarak yapılan çalışmalar incelenerek derin öğrenmenin hangi alana nasıl uygulandığına dair somut örnekler verilmiştir. Çalışmanın son kısmında, incelenen makalelerin amaçları, kullandıkları yöntemler, literatüre olan katkıları ve elde ettikleri sonuçları içeren özet bir tablo sunularak araştırmacıların yapacakları çalışmalarda kullanacakları yöntemlere ilişkin ön bilgiler elde etmeleri sağlanmıştır.

Anahtar Kelimeler Yapay zeka, Derin öğrenme, Görüntü İşleme, Nesne tespiti

Reference to this paper should be made as follows (bu makaleye aşağıdaki şekilde atıfta bulunulmalı):

Merve YILMAZ, Hasan ŞAHİN, Aytaç YILDIZ, 'Derin Öğrenme Modelleriyle Yapılan Çalışmaların Sektörel Uygulama Analizi', *Elec Lett Sci Eng*, vol. 17(2), (2021), 126-140.

* Corresponding author; Tel.022430037, aytac.yildiz@btu.edu.tr

1. Giriş

Yapay zekâ (Artificial Intelligence-AI) görme, dinleme, hissetme gibi algılama; düşünme, anlama, öğrenme, planlama gibi akıl yürütme; konuşma ve yazma gibi iletişim yeteneklerine sahip insan zekasının davranışını sergileyen makineler veya yazılım uygulamaları olarak tanımlanmıştır (Humm, 2016). Yapay zekâ araştırmasının temel hedefleri arasında akıl yürütme, planlama, öğrenme, doğal dil işleme, algılama ve nesnelere hareketine karar verme yeteneği yer almaktadır. Yapay zekâ alanı; bilgisayar bilimi, matematik, psikoloji, dilbilim, felsefe, sinirbilim, yapay psikoloji ve diğer pek çok bilimden yararlanmaktadır.

Yapay zekâ, makineler tarafından sergilenen zekadır. Bilgisayar biliminde yapay zekâ araştırma alanı, kendisini, çevresini algılayan ve bir hedef doğrultusunda başarı şansını en üst düzeye çıkaran eylemlerde bulunan herhangi bir cihazı tanımlamaktadır. Günümüzde yapay zekâ olarak sınıflandırılan yetenekler arasında; insan konuşmasını başarılı bir şekilde anlama, stratejik oyun sistemlerinde kendi kendini süren arabalarda yüksek düzeyde rekabet etme, içerik dağıtım ağlarında akıllı yönlendirme, askeri simülasyonlar ve karmaşık verileri yorumlama yer almaktadır (Ongsulee, 2017). Yapay zekâ biliminin bir alt bilimsel çalışma dalı olan makine öğrenimi de tümevarım algoritmalarına ve diğer algoritmalara odaklanmaktadır. Ayrıca, verilerden öğrenebilen ve veriler üzerinde tahminlerde bulunabilen algoritmaların çalışmasını ve oluşturulmasını araştırır (Kohavi ve Provost, 1998). 1959'da Arthur Samuel, makine öğrenimini "bilgisayarlara açıkça programlanmadan öğrenme yeteneği veren çalışma alanı" olarak tanımlamıştır. Günümüzde makine öğrenimi, istatistik, bilgi teorisi, algoritma teorisi, olasılık ve fonksiyonel analiz gibi birçok disiplinin birleşiminden oluşmaktadır (Muñoz-Villamizar vd., 2020). Makine öğreniminin bir alt kümesi olan derin öğrenme, tahmin ve tespit görevi için birden çok düzeyde veri temsili analiz etme yeteneğine sahiptir (Wainberg vd., 2018). Şekil 1'de verilen görselde de yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki gösterilmektedir.



Şekil 1. Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki

2. Yapay Zekâ ve Derin Öğrenme

Derin öğrenmenin hızlı gelişimiyle, görüntü sınıflandırma ve nesne algılama doğruluğu büyük ölçüde gelişim göstermiştir. Böylelikle, büyük veri kümeleri birçok açıdan insanlardan bile daha iyi bir şekilde doğru bir şekilde sınıflandırılmıştır. Ayrıca, sınıflandırma özelliklerini doğrudan çıkarma avantajına ek olarak, güçlü bir genelleme yeteneğine de sahiptir (Zhao vd., 2019).

Derin öğrenme, birden çok işleme katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyiyle verilerin temsillerini öğrenmesine olanak tanımaktadır. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi diğer

birçok alanda en son teknolojiyi önemli ölçüde geliştirmiştir (Lecun vd., 2015). Derin öğrenme algoritması, verileri birkaç katmandan geçirir. Her katman, özellikleri aşamalı olarak çıkarma yeteneğine sahiptir ve onu bir sonraki katmana iletir. İlk katmanlar, düşük seviyeli özellikleri çıkarır ve sonraki katmanlar, eksiksiz bir temsil oluşturmak için özellikleri birleştirir (Mathew vd., 2020).

Derin öğrenme, bir makinenin her katmandaki temsili önceki katmandaki temsilden hesaplamak için kullanılan dahili parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerinde karmaşık yapıyı keşfeder. Derin öğrenmede kullanılan evrimsel ağlar görüntü, video, konuşma ve ses işlemede çığır açarken, tekrarlayan ağlar metin ve konuşma gibi sıralı verilere ışık tutmuştur (Lecun vd., 2015). Derin öğrenmede temel olan amaçlardan en önemlileri arasında görüntü işleme ve nesne tespiti yer almaktadır.

Görüntü işleme ya da diğer adıyla sayısal görüntü işleme, sayısal bir resmin girdi olarak alınıp amaca yönelik sinyal işleme algoritmaları kullanılarak, sonuçta istenilen görüntünün çıktısı olarak elde edilmesidir. Görüntü işleme teknikleri tıbbi, astronomi, bilgi arama gibi birçok alanda bilgiyi filtrelemek ve bilgiye daha hızlı ve hatasız ulaşmak için kullanılır. Sayısal görüntü işlemede renkli bir resim ile gri tonlardaki bir resim farklı ifade edilir. Renkli resimde her noktanın kırmızı, yeşil ve mavi (RGB) olmak üzere 3 değeri vardır. Bu değerlerin sayısal değişimlerinden renkler elde edilir. Gri tonlarda ise bu durum tek bir değer üzerinden gösterilir (Balbozan, 2011).

Video analizi ve görüntü algılama ile olan yakın ilişkisi nedeniyle nesne algılama son yıllarda çok fazla araştırmanın ilgisini çekmiştir. Genel nesne algılama, herhangi bir görüntüdeki mevcut nesnelere bulup sınıflandırmayı ve varlığın güvenini göstermek için bunları dikdörtgen sınırlayıcı kutularla etiketlemeyi amaçlar. Bu algılama yöntemlerinin çerçeveleri temel olarak iki türe ayrılabilir. Biri, geleneksel nesne algılama düzenini takip eder. Önce bölge önerileri oluşturur ve ardından her bir teklifi farklı nesne kategorilerine göre sınıflandırır. Diğeri, nihai sonuçlara doğrudan ulaşmak için birleşik bir çerçeve benimseyerek, nesne algılamayı bir regresyon veya sınıflandırma problemi olarak görür. Bölge önerisine dayalı yöntemler; R-CNN (Region Based Convolutional Neural Networks), SPP-net (Spatial Pyramid Pooling), Fast R-CNN, Faster R-CNN, R-FCN (Region-based Fully Convolutional Networks), FPN (Feature Pyramid Network) ve Mask olarak sıralanabilir. Regresyon/sınıflandırma tabanlı yöntemler de MultiBox, AttentionNet, G-CNN (Grid Convolutional Neural Network), YOLO (You Only Look Once) ve SSD (Single Shot Detector) olarak sıralanmaktadır (Zhao vd., 2019).

3. İlgili Çalışmalar

Uluslararası alandaki literatürde farklı alanlarda derin öğrenme yöntemleri kullanılarak yapılan pek çok çalışmanın olduğu tespit edilmiştir. Bu bölümde son 4 yılda öne çıkan çalışmalar sağlık, tarım ve mühendislik alanında yapılan çalışmalar olarak sınıflandırılmıştır.

3.1. Sağlık alanında yapılan çalışmalar

Kesav vd., (2021), R-CNN tekniğini kullanarak beyin tümörü sınıflandırması ve tümör tipi tespiti için yeni bir mimari önermişlerdir. Önerdikleri CNN mimari ile Glioma ve sağlıklı tümör görüntülerini %98,21 doğrulukla ve 64,5 saniyelik çok düşük yürütme süresi ile etkili bir şekilde sınıflandırmışlardır. Daha sonra aynı mimari yapıyı, önceki aşamada sınıflandırdıkları tümör bölgelerini tespit etmek için R-CNN'nin özellik çıkarıcısı olarak kullanmış ve tümör bölgesi, sınırlayıcı kutuları kullanarak sınırlandırmışlardır. Çalışmada kullandıkları metodoloji 277,174 saniye yürütme süresi ve %98,83 doğruluk ile diğer mevcut mimarilere kıyasla çok düşük yürütme süresine ulaşmayı başarmışlardır.

Kim vd., (2021), ResNet (Residual neural network) derin öğrenme modelini kullanarak hızlı tanı ve yoğun tedavi gerektiren beyin kanamalarını ve görüntülerdeki yerlerini tespit etmeyi amaçlamışlardır. Çalışmada, bilgisayarlı tomografiye (BT) göre kanamasız normal beyin görüntüleri ve subaraknoid, intraventriküler, subdural, epidural ve intraparaknoidal kanamalı görüntüleri analiz etmişlerdir. Normal beyin ve subaraknoid, intraventriküler, subdural, epidural ve intraparaknoidal kanamalı beyinlerin görüntüleri için bir kanama tahmin sistemi kurmuşlardır. Çalışma sonunda kanama bölgelerini doğru tahmin etmiş ve görüntülerde karşılık gelen yerlerin görselleştirmeleri piksel farkı dahilinde örtüşmüştür. Sistem performansının değerlendirilmesinde 0,67 hassasiyet ve 0,86 özgüllük ile 0,81 doğruluk elde etmişlerdir.

Gupta vd., (2021) akciğer kanserinin tespiti için CNN ve AlexNet CNN derin öğrenme modellerini kullanmışlardır. Yapılan çalışma sonunda CNN için, verilen akciğer kanseri görüntü veri setinde %90,47'lik bir eğitim doğruluğu ve AlexNet CNN mimarisini için yaklaşık %50,79'luk bir eğitim doğruluğunu kaydetmişlerdir.

Chen vd., (2021), en yaygın tip olan ventriküler septal kusurun (VSD) görüntü tespiti için derin öğrenme algoritmalarının kullanımını araştırmışlardır. Üç tip VSD içeren renkli Doppler ekokardiyografik görüntüler, renkli doppler ultrason tıbbi görüntüleri ile test etmişlerdir. Çalışmada, YOLOv4'ün mozaik veri büyütme, SPP ve kosinüs tavlama zamanlayıcı gibi bazı özelliklerinin ultrason tıbbi görüntüsü için uygun olmaması nedeniyle modifiye edilmiş YOLOv4-DenseNet algoritmasını önermişlerdir. Çalışmada, YOLOv4-DenseNet'in metrik mAP-50 açısından YOLOv4, YOLOv3, YOLOv3-SPP ve YOLOv3-DenseNet'ten daha iyi performans gösterdiğini tespit etmişlerdir.

Wang vd., (2020) açık kaynaklı ve genel halk tarafından erişilebilen göğüs röntgeni (CXR) görüntülerinden COVID-19 vakalarını tespit etmek için uyarlanmış derin bir konvolüsyonel sinir ağı tasarımı olan COVID-Net'i ve 13.870 hasta vakasında 13.975 CXR görüntüsünden oluşan ve kamuya açık veri seti olan Covidx'i de tanıtmışlardır. Bu veri kümelerinin inşa edilmesiyle COVID-19 vaka tespit için son derece doğru ve hızlı derin öğrenme çözümleri gelişimini hızlandırmayı ve en çok ihtiyacı olanların tedavisini hızlandırmayı vaat etmişlerdir.

Murali vd., (2020), ambliyopi risk faktörleri (ARF) açısından çocukları taramak için derin öğrenme ve görüntü işleme analizi tabanlı bir sistem kullanmışlardır. ARF'nin varlığını tahmin etmek için farklı ışık koşullarında çekilen görüntüleri otomatik olarak işlemek için bir algoritma geliştirmişlerdir. Yüzün görüntülerini bölümlere ayırmak için derin öğrenme ve görüntü işleme modellerini kullanmışlardır. Derin öğrenme, her ARF için bir risk panosu oluşturan sigmoidal modeller kullanarak normalleştirilmiş riskleri formüle etmek için kullanmışlardır. Model 54 genç yetişkin üzerinde test etmiş ve algoritmanın ARF'yi saptamada %79,6 doğruluk, %88,2 duyarlılık, %75,6 özgüllük ve %73,2 F-skoru değerlerini elde ettiğini tespit etmişlerdir.

Serte ve Demirel (2019), yaygın cilt lezyonu tiplerinden melanom ve seboreik keratoz için Gabor dalgacık tabanlı yeni bir derin CNN modelini önermişlerdir. Önerilen model, girdi görüntülerinin yedi yönlü alt bantlara ayrıştırılmasına dayanmaktadır. Yedi alt-bant görüntüsü ve giriş görüntüsü, sekiz olasılıklı tahmin üretmek için sekiz paralel CNN'e girdi olarak kullanmışlardır. Performans değerlendirme sonuçları, görüntü ve Gabor dalgacık tabanlı modelin bir bütününün, tek bir görüntü ve Gabor dalgacık tabanlı modellerden daha iyi performans elde ettiğini göstermektedir.

Hu vd., (2019), genişletilmiş tam evrişimli ağ (Dilated Fully Convolutional Network- DFCN) ve faz bazlı aktif kontur (Phase-Based Active Contour- PBAC) modelinin birleştirilmesiyle yeni bir otomatik tümör bölütleme yöntemini önermişlerdir. DFCN modeli, 89 hastadan 570 meme ultrasonu (BUS) görüntüsünü içeren veri kümesi ile eğitmiş ve test etmişlerdir. Sonra, önerilen yöntemin segmentasyon sonuçlarından çıkarılan 460 öznelik kullanılarak tanılama yeteneğini doğrulamak için 10 katlı bir SVM sınıflandırıcı kullanmışlardır. 170 BUS

görüntüsünden elde edilen deneysel sonuçlar, önerilen yöntemin %88,97 benzerlik katsayısına, 35,54 piksel Hausdorff mesafesine (HD) ve 7,67 piksel ortalama mutlak sapmaya (MAD) sahip olduğunu göstermiştir. Yazarlar bu değerlere göre önerilen yöntemin tıbbi ultrason uygulamaları için yeterince doğru, sağlam ve verimli olduğunu öne sürmüşlerdir.

Saii ve Kraitem (2017), 40 adet beyin MR (Manyetik Rezonans) görüntülerinden tümör tespiti için SVM (Support Vector Machine) kullanmışlardır. Çalışmada, beyin MR görüntülerinin simetrik özelliğine bağlı olarak uygun maske görüntüsünü oluşturmuş ve tümörü %95,5'lik doğruluk oranı ile birkaç saniye içinde tespit etmişlerdir.

3.2. Tarım alanında yapılan çalışmalar

Jin vd., (2021) derin öğrenme ve görüntü işleme teknolojisi kombinasyonunu kullanarak sebze plantasyonundaki yabancı otları belirlemek için iki adımdan oluşan bir yaklaşım önermişlerdir. İlk olarak, sebzeleri tespit eden ve etraflarına sınırlayıcı kutular çizen bir CenterNet modeli eğitmişlerdir. Eğitimli CenterNet %95,6 hassasiyet ve 0,953 F1 skorunu elde etmiştir. Daha sonra renkli görüntüde kalan yeşil nesnelere yabancı ot olarak kabul etmişlerdir. Yabancı otları arka plandan çıkarmak için bir renk indeksi belirlenmiş ve Bayesian sınıflandırma hatasına göre genetik algoritma aracılığıyla değerlendirmişlerdir. Bu şekilde, model yalnızca sebzeleri tanımlamaya odaklanmış ve yabancı ot türlerini işlemekten kaçınmıştır.

Zhang vd., (2020) hem domates hastalıklarını tanıyabilen hem de sağlıklı domates yaprak konumlarını tespit edebilen hastalıklı domates yapraklarını tespit etmek için faster R-CNN algoritmasını geliştirmişlerdir. Domates hastalığının derin özelliklerini çıkarabilen özellik çıkarımı için VGG16'nın yerine ResNet101'i seçmişlerdir. Deneysel sonuçlar, önerilen algoritmanın domates hastalıklarını etkili bir şekilde tespit edip tanıyabildiğini ve orijinal faster R-CNN'den daha yüksek tespit doğruluğuna sahip olduğunu göstermiştir.

Sa vd., (2016) derin evrişimli sinir ağlarını kullanarak meyve tespitine yeni bir yaklaşım sunmuşlardır. Çalışmadaki amaç, otonom bir tarımsal robotik platformun hayati bir unsuru olan doğru, hızlı ve güvenilir bir meyve algılama sistemini oluşturmaktır. Bunun için renkli (RGB) ve yakın kızılötesi (NIR) olmak üzere iki yöntemden elde edilen görüntüleri faster CNN modelini kullanarak meyve tespiti yapmışlardır.

3.3. Mühendislik alanında yapılan çalışmalar

Lee vd., (2021) nesne tespiti için gerekli olan büyük bir görüntü veri setini hızlı bir şekilde oluşturmak için bir yöntem önermişlerdir. Önerdikleri çalışmada nesne görüntülerini yakalamak için arka plan rengini değiştirebilen bir LCD monitör kullanmışlardır. Ayrıca, örnek görüntülerin çeşitliliğini artırmak için çeşitli açılardan görüntüleri yakalamak için kamerayı farklı konumlara taşımak için robotik bir kol kullanmışlardır. Derin öğrenme modelleri olarak faster R-CNN modeli ve YOLOv4 modelini seçmişlerdir. Önerilen yöntemi kullanarak oluşturulan 10.000 sentetik görüntüyü eğittikten sonra, faster R-CNN modeli için 0,76 ve YOLOv4 modeli için 0,97 ortalama mAP elde etmişlerdir. Daha iyi doğruluk elde etmek için daha fazla görüntü gerekmesine rağmen, 10.000 sentetik görüntüyü hazırlamak için yalnızca yaklaşık 2 saat harcanmış ve 800 gerçek görüntüyü yakalamak ve etiketlemek için gereken zamandan yaklaşık %69 tasarruf sağlamışlardır. Böylelikle, LCD monitör ve robot kolun birleştirilmesiyle, bir nesnenin görüntüsünün yakalanması ve etiketlenmesi için harcanan zaman ve işçilik önemli ölçüde azaltılmıştır.

Carell ve Atapour-Abarghouei (2021), insan müdahalesine ihtiyaç duymadan sürücünün telefon kullanma ihlalini yakalamak için yol kenarı kameralarıyla çalışmak üzere özel olarak eğitilmiş son teknoloji bir nesne dedektörünü önermişlerdir. Önerilen yaklaşım aynı zamanda ön cam kaynaklı sorunları da ele almakta ve bunu düzeltmek için gereken adımları ortaya koymaktadır. Önceden eğitilmiş on iki model, YOLO, SSD, faster R-CNN ve CenterNet'ten

oluşan dört popüler nesne algılama yöntemini kullanarak özel veri kümesiyle ayarlanmıştır. Test edilen tüm nesne dedektörleri arasında YOLO, %96'ya kadar en yüksek doğruluk seviyesini ve saniyede 30 kare hızını vermiştir.

Hacıfendioğlu vd., (2021) deprem sonrası oluşan zemin göçme alanlarının ve kısmen yıkılan (hasar gören) bina veya yapıların, deprem sonrası Google Earth uydu görüntüleri kullanılarak derin öğrenme tabanlı nesne algılama yöntemini kullanarak belirlenmeyi amaçlamışlardır. Endonezya'nın 2018 Palu bölgesinde meydana gelen deprem sonrasında elde edilen veri seti ve faster R-CNN yöntemini kullanmışlardır. Önerilen yöntemin etkinliğini göstermek için, veri setini ilk olarak Google Earth Pro yazılımı ile oluşturmuş ve deprem kaynaklı zemin kırılma alanı için 392 görüntü ve hasarlı alan için 223 görüntü ile 1024×600 piksel çözünürlükte oluşturulmuştur. Analizleri farklı görüntü ölçeklerini dikkate alarak gerçekleştirmişlerdir. Analizler sonucunda, nesne tespiti tabanlı derin öğrenme yöntemlerini kullanarak deprem kaynaklı zemin göçme etkilerinin (sıvılaşmış zemin) ve hasarlı yapıların büyük ölçüde tespit edilebileceği sonucuna varmışlardır.

Kıyak ve Unal (2021), otonom uçaklarda çarpışmayı önlemek ve hedef takibi elde etmek için derin öğrenmeye dayalı dört adet izleme modeli (DCNN-deep convolutional neural networks, DCNNFN- deep convolutional neural networks with fine-tuning, TLDCNN- transfer learning with deep convolutional neural network ve FNDCNNTL- fine-tuning deep convolutional neural network with transfer learning) geliştirmiş ve birbirleriyle karşılaştırmışlardır. Çalışma sonunda; DCNN'nin eğitim süresi 9 dakika 33 saniye, doğruluk yüzdesi ise %84 olarak hesaplamışlardır. DCNNFN'de ağın eğitim süresini 4 dakika 26 saniye olarak hesaplamış ve doğruluk yüzdesini %91 olarak bulmuşlardır. TLDCNN'nin eğitimi 34 dakika 49 saniye sürmüştü ve doğruluk yüzdesini %95 olarak hesaplamışlardır. FNDCNNTL ile ağın eğitim süresini 34 dakika 33 saniye olarak hesaplamış ve doğruluk yüzdesini %100'e yakın bulmuşlardır. Yazarlar, FNDCNNTL ve TLDCNN'nin diğer iki modele göre daha iyi sonuçlar elde etmesini kullanılan görüntü sayısının azalması ve ağ eğitim süresinin artması olarak öne sürmüşlerdir.

Wei vd., (2020) pantograf (elektrikli demiryolu araçlarındaki en önemli bileşenlerden biri) slayt plakasının çevrimiçi durum izlemesi için derin öğrenme ve görüntü işleme teknolojilerine dayalı yenilikçi ve akıllı bir yöntem önermişlerdir. Tasarlanan pantograf hata algılama sinir ağını (Pantograph Defect Detection Neural Network-PDDNet), CAFFE (Convolutional Architecture for Fast Feature Embedding)'de uygulamışlardır. LeNet, AlexNet ve AlexNet ile parametre optimizasyonu yapmışlardır. Çalışma sonunda PDDNet, yaklaşık %90,63 doğruluk sağlamışlardır.

Kako vd., (2020) küresel endişe kaynağı olan plastik deniz kalıntıları (Plastic marine debris-PMD) sorununu çözmek için insansız hava aracı (İHA) ve derin öğrenmeye dayalı görüntü işlemenin bir kombinasyonunu kullanarak PMD hacimlerini tahmin etmek için yeni bir yaklaşım önermişlerdir. İHA'dan elde edilen veriler kullanılarak oluşturulan bir kumsalın üç boyutlu modeli ve ortoskopik görüntüsü, PMD hacimlerinin görüntü işleme yoluyla kenar algılama ile hesaplanmasını sağlamıştır. Yöntemin doğruluğu, bilinen boyut ve şekillerde bir sahile yerleştirilen test kalıntılarının hacimlerini tahmin ederek doğrulamışlardır. Önerilen yaklaşım, <%5'lik bir hata ile PMD hacimlerini tahmin etmiştir. Böylelikle yapılan çalışmanın bir sahildeki PMD hacmini doğru, hızlı ve objektif bir şekilde hesaplayabilmek, sahil araştırmalarının verimliliğini artırmak ve tercihli temizlik gerektiren plajları belirlemek için uygulanabileceğini öne sürmüşlerdir.

Han vd., (2020) tarafından sualtı görüşünün iyileştirilmesini sağlamak için max-RGB yöntemi ve gri tonları yönteminin bir kombinasyonu uygulanmış ve daha sonra su altı algılama ve sınıflandırmasını gerçekleştirmek için derin bir CNN yöntemini önermişlerdir. Su altı görüşünün özelliklerine göre derin CNN yapısını değiştirmek için iki geliştirilmiş şema uygulanmıştır. İlk şemada, 26×26 özellik haritasında 1×1 evrişim çekirdeğini kullanmış ve

ardından çıktığı 13*1'e eşit olacak şekilde yeniden boyutlandırmak için bir alt örnekleme katmanı eklemiştir. İkinci şemada, ilk olarak bir alt örnekleme katmanını eklemiş ve ardından evrişim katmanı ağı eklemiş ve algılamayı sağlamak için son çıktı ile birleştirmiştir. Fast R-CNN, faster R-CNN ve orijinal YOLOv3 ile yapılan deneysel çalışmalardan elde edilen sonuçları karşılaştırdıklarında, ikinci şemanın su altı nesnelere tespit etmede daha iyi olduğunu doğrulamışlardır. Algılama hızını yaklaşık 50 fps ve mAP yaklaşık %90 olarak elde etmişlerdir.

Tümen ve Ergen (2020) trafik kazalarını önlemek veya en aza indirmek için sürücülere ve otonom araçlara anlık bilgi sağlamak veya gelişmiş sürücü yardım sistemleri kapsamında uyarı sistemleri geliştirmek için görüntü işleme yöntemini ve derin öğrenme tabanlı bir yaklaşımı önermişlerdir. Bilgileri, yol üzerindeki ayrımlara, kavşaklara ve yaya geçitlerine ait görüntülerin yeni bir model kullanılarak sınıflandırılması ve VggNet, AlexNet, LeNet'in CNN tabanlı olarak elde edilmesinden elde etmişlerdir. Yüksek düzeydeki başarı oranları ile önerilen yöntemin otonom araçlar veya gelişmiş sürücü yardım sistemleri için kullanılabilirliğini göstermişlerdir. Farklı veri setleri üzerinde gerçekleştirilen çalışmada önerilen yöntemin sürücü destek sistemleri için kullanılabilir olduğunu ve hem araçları hem de sürücülere uyarı gibi birçok alanda kullanılacak etkin bir yapı olduğunu vurgulamışlardır.

Hoang (2020), yerleştirilmiş parçalanma tanıma görevini otomatikleştirmek için bilgisayarla görü tabanlı bir yaklaşım geliştirmiş ve doğrulamıştır. Yeni geliştirilen model, görüntü işleme ve makine öğrenimi yaklaşımlarının entegrasyonudur. Temel bileşen analizi ve k-ortalama kümelemesi tarafından desteklenen Gabor filtresi, bir görüntü örneğindeki ilgili bölgeyi belirlemek için kullanmıştır. Deneysel sonuçlar, yeni geliştirilen modelin %85,32 sınıflandırma doğruluk oranı ve 0,82 F1 skoru ile iyi tespit doğruluğu elde edebildiğini göstermektedir. Çalışma sonunda yazar entegre modelin, yapı sağlık durumunu değerlendirme görevinde bina bakım kurumlarına yardımcı olacak yararlı bir araç niteliği taşıdığını öne sürmüştür.

Sipetas vd., (2020) metro platformlarında geride kalan yolcu sayısını tahmin etmek için mevcut veri kaynaklarını nesne algılama için gelişen bir teknolojiyle birleştirmişlerdir. Önerilen metodoloji de yoğun talep dönemlerinde geride kalan yolcuların toplam sayısını tahmin etmek için girdi olarak otomatik video sayımları ile arşivlenmiş verileri kullanmışlardır. Yoğun saatlerde yolcuların geride kalma olasılığının yüksek olduğu istasyonları belirlemek için başlangıç-varış verilerinden bir kalabalık analizi kullanmışlardır. Otomatik olarak sayılan yolcular ve metro operasyon verileri, normal çalışma koşullarında tipik bir hafta içi geride kalan yolcuların manuel sayımlarına göre kalibre edilen lojistik regresyon modellerini geliştirmek için kullanmışlardır. Modeller, normal operasyonlarda ayrı bir günde manuel olarak geride kalan yolcu sayımlarına karşı doğrulamışlardır. Sonuçlar, videodan alınan yolcu sayılarını metro operasyon verileriyle birleştirerek, bir günlük yoğun dönemde geride kalan yolcu sayısının gerçek sayılarının %10'u içinde tahmin edilebileceğini göstermiştir.

Liu vd., (2020) kereste çatlak hasarlarını tespit etmek DarkNet-53 ile YOLOv3 algoritmasını kullanmışlardır. Deneysel sonuçlar, YOLOv3 algoritmasına dayalı ahşap çatlak tespit modelinin, ahşap çatlak tespiti için iyi bir şekilde uyarlanabilen yüksek hassasiyet ve hıza sahip olduğunu göstermiştir. Önerilen yöntem, her bir görüntüyü 0,1 saniyeden daha kısa bir süre boyunca işleyerek %90'ın üzerinde bir doğruluğa ulaşmıştır. Araştırma, eski ahşap binaların çatlak tespiti için yeni bir referans şeması sağlayarak, mimarı mirasın korunması alanında derin öğrenme teknolojisini uygulamanın büyük potansiyelini göstermektedir.

Jiang vd., (2020) metal şaft yüzey kusurlarının tespiti ve sınıflandırmasını gerçekleştirmek için fast R-CNN derin öğrenme yöntemini kullanmışlardır. Yapılan deneyler, yöntemin pratik

üretimde uygulanabileceğini ve ayrıca yüksek ışık yüzeyine sahip büyük görüntülü mikro-ince kusurların diğer alanlarına da genişletilebileceğini kanıtlamaktadır.

Tao vd., (2020) mevcut boşluk algılama yöntemlerinin eksikliklerini, anahtar makinelerinin boşluk boyutlarını tespit etmek için YOLO tabanlı nesne algılama mimarisi ve görüntü işleme algoritmalarını birleştiren bir yaklaşım önermişlerdir. Çalışmada, YOLO boşluk görüntülerindeki hedef alanları algılamak için, görüntü işleme algoritmaları ise boşlukları tanımlayarak boşluk boyutlarını hesaplamak için kullanmışlardır. Çalışma sonunda, YOLO'nun boşlukları algılama doğruluğunun %100 olduğu ve boşluk boyutlarını hesaplama doğruluğunun ise %99'dan yüksek olduğunu görmüşlerdir.

Khowaja ve Nadir (2019), kumaşlardaki farklı kusurları tespit etmek için görüntü işleme yöntemini kullanmışlardır. Bu görüntü işleme yöntemi "MATLAB 7.10" kullanarak gerçekleştirmiş ve görüntü işleme için sistematik bir görme yaklaşımına sahip bir tekstil arıza dedektörünü kullanmışlardır. Çalışma sonunda kullanılan yaklaşımın kumaştaki hataların %90'ını kategorize ettiğini tespit etmişlerdir.

Sekrecka vd., (2019) nesne algılama için keskinleştirilmiş görüntülerin kullanılabilirliğini incelemeye ve geliştirmeye odaklanarak farklı çözünürlüklü görüntülerin kaynaşmasına yönelik yeni bir yaklaşım önermişlerdir. Yalnızca piksellerin parlaklığını değil, aynı zamanda görüntüdeki geometri ve topolojiyi de inceleyen SURF öznitelik dedektörüne dayalı yeni bir gösterge önermişlerdir. Önerilen yaklaşım, farklı uzamsal çözünürlük oranlarına sahip, yani 1:4'ten 1:60'a kadar olan birkaç farklı keskinleştirme yöntemini ve veri setlerini incelemek için kullanmışlardır. Sonuçlar, önerilen yaklaşımın, özellikle yüksek çözünürlük oranına sahip görüntü verileri için birleştirilmiş görüntülerin nesne tespitini önemli ölçüde geliştirdiğini göstermiştir.

Brunetti vd., (2018) evrimsel sinir ağları kullanılarak yaya tespiti ve takibi için yapılan çalışmaların analizini yapmışlardır. Analiz edilen çalışmalar, yaya algılamaya yönelik modern yaklaşımların nasıl çalıştığını araştırma ihtiyacını ve kıyaslama veri setlerinde özellik tabanlı yaklaşımlarla bir karşılaştırma yapılması gerektiğini vurgulamışlardır.

Zhang vd., (2018), üç yeni termal görüntü işleme entegrasyon yöntemi kullanılarak üç farklı hafif kompozit yapıdaki dahili yerleştirilmiş nesnelerin bilinmeyen konumlarını tespit etmek için kızılötesi termografi (IRT- infrared thermography) kullanmışlardır. Sonuçları geleneksel ana bileşen termografisi ve darbeli fazlı termografi görüntü işleme teknikleri ile karşılaştırmışlardır. Karşılaştırma, entegre sinyal yumuşatma işleminin, yerleşik tekniklere kıyasla görüntü kalitesini geliştirdiğini göstermiştir.

Borse vd., (2012), sensörler ve görüntü işleme ile bir mobil robot kullanarak hareketli bir nesneyi izleyen bir robotik uygulama gerçekleştirmiştir. Robotik platform, istenen nesnenin hareketini algılamak için bir görsel kameradan ve robotun istenen nesneyi algılamaya ve takip etmeye devam ederken gerçek zamanlı olarak engelleri algılamasına ve ardından engellerden kaçınmasına yardımcı olmak için bir aralık sensörü oluşturmuşlardır. Çalışmadan elde edilen deneysel sonuçlar, robotik ve akıllı sistemin bir nesneyi algılama ve engellerden aynı anda kaçınma gereksinimlerini karşılayabildiğini göstermiştir.

Yukarıdaki çalışmaların yapılma amacı, kullandıkları yöntem, literatüre olan katkıları ve elde ettikleri sonuçlara ilişkin özet bilgi aşağıdaki tabloda verilmiştir.

Tablo 1. İncelenen çalışmalara ilişkin özet bilgiler

Yazar(lar), Yılı	Makale Adı	Çalışma Amacı	Yöntem	Literatüre Katkısı	Elde Edilen Sonuç
Kesav vd., (2021)	Efficient and low complex architecture for detection and classification of brain tumor using R-CNN with two channel CNN	MR dilimlerini sınıflandırmak	İki Kanallı R-CNN	Tümör tiplerini sınıflandırmak ve saptamak	R-CNN kullanarak tümör tiplerini algılamak için 277.174 yürütme süresi ve %98,83 doğruluk elde edilmiştir.
Kim vd., (2021)	Cerebral hemorrhage detection and localization with medical imaging for cerebrovascular disease diagnosis and treatment using explainable deep learning	Beyin kanamalarını ve yerlerini tespit etmek	ResNet Grad-CAM	Hızlı tanı ve tedaviye olanak sağlayacak yöntem geliştirmek	Sistem performansının değerlendirilmesinde 0,67 hassasiyet ve 0,86 özgüllük ile 0,81 doğruluk elde edilmiştir.
Gupta vd., (2021)	Lung cancer detection using image processing and convolutional neural network	Akciğer kanserinin tespiti için en iyi modeli seçmek	CNN, AlexNet CNN	En yüksek doğruluk ve minimum kayıplı tahmin için en iyi modelin tespiti	CNN ile %90,47'lik bir eğitim doğruluğu ve AlexNet CNN ile yaklaşık %50,79'luk bir eğitim doğruluğu elde edilmiştir.
Chen vd., (2021)	Modified YOLOv4-DenseNet algorithm for detection of ventricular septal defects in ultrasound images	Ekokardiyografik görüntü tespiti için derin öğrenmeyi kullanmanın fizibilitesini ortaya koymak	YOLOv4-DenseNet	Ventriküler Septal Kusurun (VSD) görüntü tespiti için derin öğrenme algoritmalarını tanıtmak	Değiştirilmiş bir YOLOv4-DenseNet çerçevesi kullanarak nesne algılama problemini çözen ilk çalışma
Wang vd., (2020)	Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images	COVID-19 vaka tespit için doğru, pratik derin öğrenme çözümleri gelişimini hızlandırmak ve riskli olanların tedavisini hızlandırmak	COVID-Net	COVID-Net, CXR görüntülerinden COVID-19 tespiti için ilk açık kaynaklı ağ tasarımı sunmak, kamuya açık covid-19 pozitif vakadan oluşan bir açık erişim kriter veri seti olan Covidx'i tanıtmak	COVID-Net, COVID-19 tespiti için ilk açık kaynaklı ağ oluşturulmuştur.
Murali vd., (2020)	Application of deep learning and image processing analysis of photographs for amblyopia screening	Çocukları ambliyopi risk faktörleri (ARF) açısından taramak	DL-Kanna Algoritması	Çocuklarda ve genç yetişkinlerde daha ileri tanı ve tedavi için ambliyopi risk faktörleri (ARF) taraması yapmak	ARF'yi tespit etmede %79,6 doğruluk, %88,2 duyarlılık ve %75,6 özgüllük ile %73,2 F-skoru değerleri elde ettiği tespit edilmiştir.
Serte ve Demirel (2019)	Gabor wavelet-based deep learning for skin lesion classification	Cilt lezyonu sınıflandırmak	Gabor dalgacık tabanlı CNN	Cilt kanseri tespiti için geliştirilen alternatif yöntemlerden daha etkili cilt tipi sınıflandırması üretmek	Performans değerlendirme sonuçları, görüntü ve Gabor dalgacık tabanlı modelin bir bütününün, tek bir görüntü ve Gabor dalgacık tabanlı modellerden daha iyi performans elde ettiğini göstermektedir.
Hu vd., (2019)	Automatic tumor segmentation in breast ultrasound images using a dilated fully convolutional network combined with an active contour model	Otomatik tümör bölütleme yöntemi önermek	DFCN PBAC	Tıbbi ultrason uygulamaları için sağlam, doğru ve verimli sonuç elde edecek yöntem önermek	Önerilen yöntemin %88,97 ± %10,01 benzerlik katsayısına, 35,54 ± 29,70 piksel Hausdorff mesafesine (HD) ve 7,67 ± 6,67 piksel ortalama mutlak sapmaya (MAD) sahip olduğu belirlenmiştir.
Saai ve Kraitem (2017)	Automatic brain tumor detection in MRI using image processing techniques	Otomatik Beyin Tümörü Tespiti	Anizotropik Difüzyon Filtresi, SVM	Tümör segmentasyonunda büyük potansiyel ve yararlılık sağlamak	Tümör %95,5'lik doğruluk oranı ile birkaç saniye içinde tespit edilmiştir

Jin vd., (2021)	Weed identification using deep learning and image processing in vegetable plantation	Sebze plantasyonundaki yabancı otları belirlemek	CenterNet, GA	Sebze plantasyonundaki yabancı otları belirlemek, sebze ve yabancı ot arasından ayırım yapmanın görsel bir yöntemini göstermek, arka plandaki yabancı otları çıkarmak	Eğitilmiş CenterNet modeli %95,6 hassasiyet, %95,0 geri çağırma ve 0,953 F1 puanı elde etmiştir.
Zhang vd. (2020)	Deep learning-based object detection improvement for tomato disease	Hastalıklı domates yapraklarını tespit etmek	Faster RCNN	Domates hastalıklarını tanıyabilmek, sağlıklı domates yaprak konumlarını tespit edebilmek	Faster RCNN-resnet101'de %98,54 doğruluk elde edilmiştir.
Sa vd., (2016)	Deepfruits: A fruit detection system using deep neural networks	Meyve tespiti	Faster CNN	Doğru, hızlı ve güvenilir meyve algılama sistemi oluşturmak, meyve verimi tahmini ve otomatik hasat için ortam oluşturmak	Yöntemin yaklaşık %50 oranında küçültülmüş nesne algılamayı işleyebildiği görülmüştür.
Kıyak ve Unal (2021)	Small aircraft detection using deep learning	Derin öğrenme kullanarak küçük uçak algılama	DCNN, DCNNFN, TLDCNN ve FNDCNNNTL	Otonom uçaklarda çarpışmayı önlemek ve hedef takibi elde etmek	DCNN %84, DCNNFN %91, TLDCNN %95 ve FNDCNNNTL %100'e yakın doğruluk elde etmiştir.
Lee vd., (2021)	Using an LCD monitor and a robotic arm to quickly establish image datasets for object detection	LCD monitör ve robotik kol kullanarak nesne algılama için görüntü veri kümelerini hızla oluşturmak	Faster R-CNN modeli ve YOLOv4	Görüntü sentezi kullanılarak daha fazla zaman tasarrufu sağlayacak modeli tanıtmak	LCD monitör ve robot kolun birleştirilmesiyle, bir nesnenin görüntüsünün yakalanması ve etiketlenmesi için yaklaşık %69'luk zaman ve işçilik kazancı sağlanmıştır.
Carell ve Atapour-Abarghouei (2021)	Identification of driver phone usage violations via state-of-the-art object detection with tracking	Nesne tespiti ile sürücü telefonu kullanım ihlallerinin tespiti	YOLO, SSD, Faster RCNN ve CenterNet	İnsan müdahalesine ihtiyaç duymadan sürücü telefonu kullanımını yakalamak için yol kenarı kameralarıyla çalışmak üzere özel olarak eğitilmiş son teknoloji bir nesne dedektörü önermek	%96'ya kadar en yüksek doğruluk seviyesi ve saniyede 30 kare hızı elde edilmiştir.
Hacıfendioğlu vd., (2021)	Automatic detection of earthquake-induced ground failure effects through faster R-CNN deep learning-based object detection using satellite images	Uydu görüntüleri kullanarak daha hızlı R-CNN derin öğrenme tabanlı nesne tespiti ile deprem kaynaklı yer arıza etkilerinin otomatik tespiti	Faster R-CNN	Deprem sonrası oluşan zemin göçme alanlarının ve kısmen yıkılan bina veya yapıların, uydu görüntüleri kullanılarak derin öğrenme tabanlı nesne algılama yöntemi kullanılarak belirlenmesi amaçlanmıştır.	Nesne tespiti tabanlı derin öğrenme yöntemleri kullanılarak deprem kaynaklı zemin göçme etkilerinin ve hasarlı yapıların büyük ölçüde tespit edilebileceği sonucuna varılmıştır.
Wei vd., (2020)	Defect detection of pantograph slide based on deep learning and image processing technology	Derin öğrenme tabanlı pantograf slayt plakasının kusur tespiti	PDDNet, LeNet, AlexNet	Pantograf slayt plakasının çevrimiçi durum izlemesi için derin öğrenme ve görüntü işleme teknolojilerine dayalı yenilikçi ve akıllı bir yöntem önermek	PDDNet, yaklaşık %90,63 doğruluk elde etmiştir.
Kako vd., (2020)	Estimation of plastic marine debris volumes on beaches using unmanned aerial vehicles and image processing based on deep learning	PMD (plastik deniz kalıntıları) hacimlerini tahmin etmek için yeni bir yaklaşım önermek	Yapay sinir ağına dayalı görüntü işleme yöntemi	PMD hacmini doğru, hızlı ve objektif bir şekilde hesaplayabilmek	Önerilen yöntem, %5'lik bir hatayla PMD hacimlerini tahmin edebilmiştir.

Han vd., (2020)	Underwater image processing and object detection based on deep CNN method	Sualtı görüşünün iyileştirilmesini sağlamak	Fast R-CNN, Faster R-CNN ve orijinal YOLOv3	Yeterince doğru ve hızlı algılama ve sınıflandırma elde etmek	Algılama hızı yaklaşık 50 fps ve mAP yaklaşık %90 olarak elde edilmiştir.
Tümen ve Ergen (2020)	Intersections and crosswalk detection using deep learning and image processing techniques	Gelişmiş sürücü yardım sistemleri kapsamında uyarı sistemleri geliştirmek	CNN	Sürücü destek sistemleri için kullanılabilir ve hem araçları hem de sürücüleri uyarma gibi birçok alanda kullanılabilecek etkin bir yapı oluşturmak	Eğitilen modelin veri setinden rastgele ayrılmış verilerle test edildiği ve %93,10 doğruluk oranına sahip olduğu tespit edilmiştir.
Hoang (2020)	Image processing-based spall object detection using Gabor filter, texture analysis, and adaptive moment estimation (ADAM) optimized logistic regression models	Gabor filtresi, doku analizi ve uyarlanabilir moment tahmini (adam) optimize edilmiş lojistik regresyon modellerini kullanarak görüntü işleme tabanlı spall nesne algılama	ADAM	Yerleştirilmiş parçalanma tanıma görevini otomatikleştirmek için bilgisayarla görü tabanlı bir yaklaşım geliştirmek	Model, %85,32 sınıflandırma doğruluk oranı ve 0.82 F1 skoru ile iyi tespit doğruluğu elde edebildiğini göstermiştir.
Tao vd., (2020)	Gap detection of switch machines in complex environment based on object detection and image processing	Nesne algılama ve görüntü işleme dayalı karmaşık ortamlarda anahtar makinalarında boşluk algılama	YOLO	Mevcut boşluk algılama yöntemlerinin eksikliklerini, anahtar makinelerinin boşluk boyutlarını tespit etmek için YOLO tabanlı nesne algılama mimarisi ve görüntü işleme algoritmalarını birleştiren bir yaklaşım önermek	YOLO'nun boşlukları algılama doğruluğunun %100 olduğu ve boşluk boyutlarını hesaplama doğruluğunun %99'dan yüksek olduğu görülmüştür.
Vandaele vd., (2020)	Topological image modification for object detection and topological image processing of skin lesions	Deri lezyonlarının nesne tespiti ve topolojik görüntü işleme için topolojik görüntü modifikasyonu	TIM	Bir görüntüden hem ilgili hem de önemli topolojik bilgileri çıkarma yeteneğini geliştirmek için bir yöntem olarak topolojik görüntü modifikasyonunu (TIM) tanıtmak	ISIC 2018'den alınan çok çeşitli cilt lezyonu görüntüleri aracılığıyla bu yöntemin altı farklı jenerik ve denetimsiz model ve algoritmanın performansını önemli ölçüde artırdığını göstermiştir.
Sipetas vd., (2020)	Estimation of left behind subway passengers through archived data and video image processing	Metro istasyonlarının çok kalabalık olması durumunda istasyonda geride kalan yolcu sayısını tahmin etmek	YOLO	Arşivlenmiş veri ve video görüntü işleme yoluyla geride kalan metro yolcularının tahminini sağlamak	Videodan alınan yolcu sayılarının metro operasyon verileriyle birleştirilmesiyle, bir günlük yoğun dönemde geride kalan yolcu sayısının gerçek sayılarının %10'u içinde tahmin edilebileceğini göstermektedir.
Liu vd., (2020)	Automatic detection of timber-cracks in wooden architectural heritage using Yolov3 algorithm	YOLOv3 algoritması kullanılarak ahşap kereste-çatlakların otomatik tespiti	DarkNet-53 ile YOLOv3	Ahşap mimari mirasında (WAH) kereste çatlak hasarlarını tespit eden yöntemi önermek	Yöntem, her bir görüntüyü 0,1 saniyeden daha kısa bir süre boyunca işleyerek %90'ın üzerinde bir doğruluğa ulaşmıştır.
Jiang vd., (2020)	Object detection and classification of metal polishing shaft surface defects based on convolutional neural network deep learning	Metal parlatma shaftı yüzey hatalarının nesne tespiti ve sınıflandırılması	Fast-R-CNN	Metal shaft yüzey kusurlarının nesne tespiti ve sınıflandırmasını gerçekleştirmek için evrişimli sinir ağı öznitelik çıkarımına dayalı bir derin öğrenme yöntemi kullanmak	Yöntemin pratik üretimde ve yüksek ışık yüzeyine sahip büyük görüntülü mikro-ince kusurların diğer alanlarına da uygulanabileceği savunulmuştur.
Khowaja ve Nadir (2019)	Automatic fabric fault detection using image processing	Otomatik kumaş hatası algılama yaklaşımlarına	Matlab 7.10'da	Kumaştaki hataların kategorize edilmesini sağlamak	Kullanılan yöntem, kumaştaki hataların %90'ını kategorize etmektedir.

		genel bir bakış sağlamak	görüntü işleme		
Sekrecka vd., (2019)	Pre-processing of panchromatic images to improve object detection in pansharpened images	Pansharpen görüntülerde nesne algılamayı iyileştirmek için pankromatik görüntülerin ön işleme	SURF	Farklı çözünürlüklü görüntülerin kaynaşmasına yönelik yeni bir yaklaşım önermek	Önerilen yaklaşımın, özellikle yüksek GSD oranına sahip veriler için, birleştirme sonrası görüntülerin yorumlayıcı potansiyelini önemli ölçüde artırdığını göstermiştir.
Brunetti vd., (2018)	Computer vision and deep learning techniques for pedestrian detection and tracking: a survey	Yaya tespiti ve takibi için yapılan çalışmaları analiz etmek	DNN	Farklı veri kümelerinde yaya algılama sistemlerinin test edilmesinin önemini vurgulamak	Çalışma sonunda, kıyaslama veri setlerinde özellik tabanlı yaklaşımlarla bir karşılaştırma yapılması gerektiğini vurgulanmaktadır.
Zhang vd., (2018)	A comparative study of enhanced infrared image processing for foreign object detection in lightweight composite honeycomb structures	Hafif kompozit petek yapılarda yabancı cisim tespiti için gelişmiş kızılötesi görüntü işleme	IRT	Üç yeni termal görüntü işleme entegrasyon yöntemi kullanılarak üç farklı hafif kompozit yapıdaki dahili yerleştirilmiş nesnelerin bilinmeyen konumlarını almak için kızılötesi termografi (IRT) kullanmak	Entegre sinyal yumuşatma işleminin, yerleşik tekniklere kıyasla görüntü kalitesini geliştirdiğini göstermiştir

Sağlık Alanı

Tarım Alanı

Mühendislik Alanı

4. Sonuç ve Öneriler

Yapay zekâ, yaygın olarak akıllı davranış olarak adlandırılan şeylerin sayısal olarak anlaşılması ve bu tür davranışları sergileyen eserlerin oluşturulması ile ilgilenen bir bilim ve mühendislik alanı olarak tanımlanmaktadır. Yapay zekâyı geliştirmek için kullanılan en popüler yaklaşımlardan birisi olarak bilinen derin öğrenme de temelde üç veya daha fazla katmana sahip bir sinir ağı olan ve beynin yapısı ve işlevinden ilham alan makine öğreniminin bir alt kümesidir. Yapılan çalışmanın amacı, çeşitli zorlukları ele almak için umut verici ve yüksek potansiyelli bir yaklaşım olan derin öğrenme teknikleri kullanılarak gerçekleştirilen çalışmaları incelemektir. Böylelikle araştırmacılara nesne tanıma, sınıflandırma, bilgisayarla görme ve görüntü analizi veya daha genel olarak veri analizi ile ilgili çeşitli örnekler sunarak derin öğrenme modellerinin çözdüğü problemleri tanıtarak onlara yol göstermek hedeflenmiştir.

Bunun için ilk olarak yapay zekâ ve derin öğrenme ile ilgili kısa bilgiler verilmiştir. Sonrasında derin öğrenme ile ilgili son 4 yılda yapılan çalışmalar sağlık, tarım ve mühendislik alanları olarak kategorize edilmiştir. İncelenen çalışmalarda odaklandıkları alan, kullanılan modellerin teknik ayrıntıları, amaçları, literatüre katkıları, kullanılan veri kaynakları ve her birinin kullandığı performans ölçütleri incelenmiş ve bir tablo halinde de sunulmuştur. Yapılan incelemelere göre sağlık alanında genel olarak CNN, R-CNN, Resnet, YOLOv4 ve SVM yöntemlerin kanser ve tümör tespiti için daha fazla uygulandığı tespit edilmiştir. Tarım alanında ise faster R-CNN yönteminin sebze ve meyve tespitinde kullanıldığı görülmektedir. Derin öğrenme yöntemlerinin en fazla kullanıldığı mühendislik alanında yapılan çalışmaların sınıflandırma, görüntü ayırma ve tanımlama tabanlı olduğu görülmüştür. Bu alanda da en fazla CNN, faster R-CNN ve YOLO yöntemlerinin kullanıldığı tespit edilmiştir.

Gelecekte yapılacak çalışmalarda daha fazla çalışma incelenerek uygulama alanları artırılıp alanlara özgü daha fazla kategoriler elde edilebilir.

Kaynaklar

Balbozan, F.İ. (2011). *Kameralı lazer tarama sistemi ile nesne sınıflandırması ve uygulamaları* (Doctoral dissertation, DEÜ Fen Bilimleri Enstitüsü), DEÜ Fen Bilimleri Enstitüsü.

Brunetti, A., Buongiorno, D., Trotta, G. F., & Bevilacqua, V. (2018). Computer vision and deep learning techniques for pedestrian detection and tracking: A survey. *Neurocomputing*, 300, 17-33.

Carrell, S., & Atapour-Abarghouei, A. (2021). Identification of Driver Phone Usage Violations via State-of-the-Art Object Detection with Tracking. *arXiv preprint arXiv:2109.02119*.

Chen, S. H., Wang, C. W., Tai, I. H., Weng, K. P., Chen, Y. H., & Hsieh, K. S. (2021). Modified YOLOv4-DenseNet Algorithm for Detection of Ventricular Septal Defects in Ultrasound Images. *International Journal Of Interactive Multimedia And Artificial Intelligence*, 1-8.

Gupta, A., Manda, V. K., & Seraphim, B. I. (2021). Lung Cancer Detection Using Image Processing and Convolutional Neural Network. *Annals of the Romanian Society for Cell Biology*, 3044-3048.

Hacıefendioğlu, K., Başağa, H. B., & Demir, G. (2021). Automatic detection of earthquake-induced ground failure effects through Faster R-CNN deep learning-based object detection using satellite images. *Natural Hazards*, 105(1), 383-403.

- Han, F., Yao, J., Zhu, H., & Wang, C. (2020). Underwater image processing and object detection based on deep CNN method. *Journal of Sensors*, 2020.
- Hoang, N. D. (2020). Image Processing-Based Spall Object Detection Using Gabor Filter, Texture Analysis, and Adaptive Moment Estimation (Adam) Optimized Logistic Regression Models. *Advances in Civil Engineering*, 2020.
- Hu, Y., Guo, Y., Wang, Y., Yu, J., Li, J., Zhou, S., & Chang, C. (2019). Automatic tumor segmentation in breast ultrasound images using a dilated fully convolutional network combined with an active contour model. *Medical physics*, 46(1), 215-228.
- Humm, B. G. (2016). *Applied Artificial Intelligence An Engineering Approach*.
- Jiang, Q., Tan, D., Li, Y., Ji, S., Cai, C., & Zheng, Q. (2020). Object detection and classification of metal polishing shaft surface defects based on convolutional neural network deep learning. *Applied Sciences*, 10(1), 87.
- Jin, X., Che, J., & Chen, Y. (2021). Weed Identification Using Deep Learning and Image Processing in Vegetable Plantation. *IEEE Access*, 9, 10940-10950.
- Kako, S. I., Morita, S., & Taneda, T. (2020). Estimation of plastic marine debris volumes on beaches using unmanned aerial vehicles and image processing based on deep learning. *Marine Pollution Bulletin*, 155, 111127.
- Kesav, N., & Jibukumar, M. G. (2021). Efficient and low complex architecture for detection and classification of Brain Tumor using RCNN with Two Channel CNN. *Journal of King Saud University-Computer and Information Sciences*.
- Khowaja, A., & Nadir, D. (2019, December). Automatic fabric fault detection using image processing. In *2019 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS)* (pp. 1-5). IEEE.
- Kim, K. H., Koo, H. W., Lee, B. J., Yoon, S. W., & Sohn, M. J. (2021). Cerebral hemorrhage detection and localization with medical imaging for cerebrovascular disease diagnosis and treatment using explainable deep learning. *Journal of the Korean Physical Society*, 1-7.
- Kiyak, E., & Unal, G. (2021). Small aircraft detection using deep learning. *Aircraft Engineering and Aerospace Technology*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, W. C., Zhang, J. Y., & Wei, C. C. (2021). Using an LCD Monitor and a Robotic Arm to Quickly Establish Image Datasets for Object Detection. *IEEE Access*, 131006- 131019.
- Liu, Y., Hou, M., Li, A., Dong, Y., Xie, L., & Ji, Y. (2020). Automatic detection of timber-cracks in wooden architectural heritage using YOLOv3 algorithm. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 1471-1476.
- Muñoz-Villamizar, A., Rafavy, C. Y., & Casey, J. (2020). Machine learning and optimization-based modeling for asset management: a case study. *International Journal of Productivity and Performance Management*.
- Murali, K., Krishna, V., Krishna, V., & Kumari, B. (2020). Application of deep learning and image processing analysis of photographs for amblyopia screening. *Indian Journal of Ophthalmology*, 68(7), 1407.
- Ongsulee, P. (2017, November). Artificial intelligence, machine learning and deep learning. In *2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE)* (pp. 1-6). IEEE.

- Provost, F., & Kohavi, R. (1998). Guest editors' introduction: On applied research in machine learning. *Machine learning*, 30(2), 127-132.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). Deepfruits: A fruit detection system using deep neural networks. *sensors*, 16(8), 1222.
- Saii, M., & Kraitem, Z. (2017). Automatic brain tumor detection in MRI using image processing techniques. *Biomedical statistics and informatics*, 2(2), 73-76.
- Sekrecka, A., Kedzierski, M., & Wierzbicki, D. (2019). Pre-processing of panchromatic images to improve object detection in pansharpened images. *Sensors*, 19(23), 5146.
- Serte, S., & Demirel, H. (2019). Gabor wavelet-based deep learning for skin lesion classification. *Computers in biology and medicine*, 113, 103423.
- Sipetas, C., Keklikoglou, A., & Gonzales, E. J. (2020). Estimation of left behind subway passengers through archived data and video image processing. *Transportation Research Part C: Emerging Technologies*, 118, 102727.
- Tao, T., Dong, D., Huang, S., & Chen, W. (2020). Gap detection of switch machines in complex environment based on object detection and image processing. *Journal of Transportation Engineering, Part A: Systems*, 146(8), 04020083.
- Tümen, V., & Ergen, B. (2020). Intersections and crosswalk detection using deep learning and image processing techniques. *Physica A: Statistical Mechanics and its Applications*, 543, 123510.
- Vandaele, R., Nervo, G. A., & Gevaert, O. (2020). Topological image modification for object detection and topological image processing of skin lesions. *Scientific Reports*, 10(1), 1-15.
- Wainberg, M., Merico, D., DeLong, A., & Frey, B. J. (2018). Deep learning in biomedicine. *Nature biotechnology*, 36(9), 829-838.
- Wang, L., Lin, Z. Q., & Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific Reports*, 10(1), 1-12.
- Wei, X., Jiang, S., Li, Y., Li, C., Jia, L., & Li, Y. (2019). Defect detection of pantograph slide based on deep learning and image processing technology. *IEEE Transactions on Intelligent Transportation Systems*, 21(3), 947-958.
- Zhang, H., Sfarra, S., Genest, M., Ibarra-Castanedo, C., Duan, Y., Fernandes, H., ... & Maldague, X. P. (2018). A comparative study of enhanced infrared image processing for foreign object detection in lightweight composite honeycomb structures. *International Journal of Thermophysics*, 39(12), 1-10.
- Zhang, Y., Song, C., & Zhang, D. (2020). Deep learning-based object detection improvement for tomato disease. *IEEE Access*, 8, 56607-56614.
- Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. (2019). Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30(11), 3212-3232.