



Bölüm 5

YAPAY ZEKÂNIN GÖRÜNTÜ İŞLEME ALANINDAKİ UYGULAMALARI

*Emre BENEŞ¹
Uğur SORGUCU²*

¹ Nevşehir Hacı Bektaş Veli Üniversitesi Mühendislik Mimarlık Fakültesi
Bilgisayar Mühendisliği Bölümü ORCID: 0000-0002-9432-3278

² Nevşehir Hacı Bektaş Veli Üniversitesi Mühendislik Mimarlık Fakültesi
Elektrik Elektronik Mühendisliği Bölümü ORCID: 0000-0002-2706-0906

1. Giriş

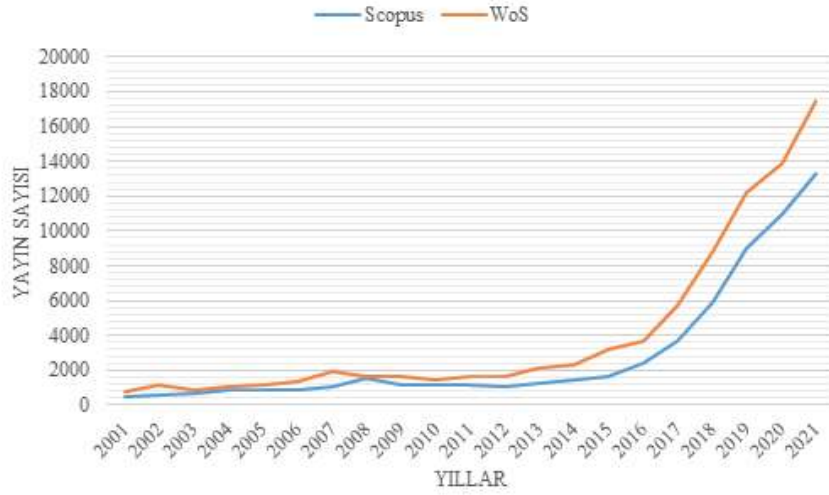
Dijitalleşme ve bilişim teknolojilerinin hayatımıza girmesiyle insan aklının çalışma hızı ile çok uzun sürecek, hatta tamamlanması imkânsız olan işlemler çok kısa sürede, bilgisayar gücü sayesinde, yapılabilir hale gelmiştir. Bu gücün bir sonucu olarak çok farklı alanlarda bilişim destekli yeni yöntemler geliştirilmiş ve insan hayatını kolaylaştıracak teknolojiler üremiştir.

Bilişim teknolojilerinin kendisine uygulama sahası bulduğu en önemli alanlardan birisi de görsel algılamadır. Görsel bilgiler çevre şartlarının tespiti, yorumlanması ve sonuca varmada insan algısı için büyük önem teşkil eder. Bu sebeple de bilgisayar ortamında görsel bilgiler sıklıkla kullanılmaktadır. Sağlık, sinema, savunma sanayii ve daha başka örnek verebileceğimiz birçok sektöre yönelik bilişim destekli görsel teknolojiler geliştirilmektedir. Bu teknolojilerin özelinde ise, görsel bilginin algılanması, hatalardan arındırılması, işlenmesi ve yorumlanması önem arz etmektedir. Bilgisayar ortamında insan görüşünü taklit eden ve bahsi geçen ihtiyaçlara cevap veren yöntemler görüntü işleme alanını teşkil etmektedir. Var olan ihtiyaç neticesinde de görüntü işleme alanında sürekli yeni yöntemler geliştirilmekte ve literatüre sunulmaktadır.

Bu yöntemlerin en temel sıkıntısı kendi başlarına karar verememeleri, sonuç üretmek için insan yönetimine ihtiyaç duymaları ve değişen şartlara uyum sağlayamayıp yeni şartlar için yeni tasarımlara ihtiyaç duymasındır. Dijital cihazların hızlı işlem yapabilme kapasitelerinin, geliştirilen algoritmalar ile desteklenmesi, insan gibi düşünebilen ve sonuç çıkartabilen yöntemler geliştirilmesi hususunda motivasyon sağlamıştır. Sonucunda ise yapay zekâ teknikleri geliştirilmiş ve birçok alanlarda uygulanması mümkün olmuştur. Günümüzde, gelişen yapay zekâ teknikleri ile akıllı davranışlar sergileyen bilgisayar sistemleri insan hayatının birçok noktasına etki etmektedir.

Yapay zekâ tekniklerinin gelişmesi kendisine hızlı bir şekilde görüntü işleme alanında da yer bulmuştur. Görüntü işlemede görüntülerdeki şartların kolaylıkla değişebiliyor olması genelleştirilebilir yöntemler geliştirmeyi zorlaştırmaktadır. Bu noktada yapay zekâ tekniklerinin görüntü işlemede kullanılması etkin sonuçlar vermiştir. Sonucunda bu uygulamalar, görsel verilerden anlamlı bilgiler çıkartan veri madenciliğinden sanal cisimlerin hatta ortamların oluşturulmasına kadar birçok uygulamada karşımıza çıkmaktadır. Bir diğer çarpıcı örnek olarak çevrenin dijital olarak algılanmasından bahsedilebilir. Otonom araçlarda farklı algılama teknolojileri ile görsel algılamada kullanılmakta ve sonucunda zeki davranış sergileyen bir araç ortaya çıkmaktadır. Bu örnekte yapay zekâ çevre algısına dayanarak karar verme süreçlerini yönetmektedir.

Yapılan çalışmalara verilecek örnekleri artırılabilir. Ancak literatür incelendiğinde çok fazla uygulama alanı olduğu ve hepsine değinmenin imkânsız olduğu açıktır. Bununla birlikte Şekil 1’de 2001-2021 yılları arasındaki yirmi yıllık sürede Scopus ve Web of Science (WoS) gibi alanda en önemli iki popüler indekste taranan dergilerde yayınlanmış Yapay zekâ ile görüntü işleme teknikleri yürütülmüş çalışmaları konu alan akademik makalelerin senelere göre dağılımı grafik olarak sunulmaktadır. Grafikler incelendiği zaman her iki indekste de sürekli bir artış olduğu ve artışın özellikle son senelerde ivme kazandığı görülmektedir. Gerek son yıllardaki yayın sayıları gerekse sayıdaki artış göz önüne alındığında, alana olan ilginin dikkate değer olduğu görülmektedir.



Şekil 1. Son 20 yılda Scopus ve Web of Science indekslerinde taranan dergilerde yayınlanmış görüntü işlemede yapay zekanın kullanıldığı yayın sayıları.

Bu bölümde görüntü işleme alanında yapay zekâ tekniklerinin kullanıldığı çalışmaları incelenmiş ve detaylı bir analizi verilmiştir. Özet olarak bölüm organizasyonu şu şekildedir; öncelikle görüntü işleme ve yapay zekanın ayrıntılı tanımı ve içeriği anlatılmış sonrasında ise bu uygulamalar hangi alanlarda hayat bulmuş bunlara değinilerek literatürden örneklerle uygulamalarından bahsedilmiş son olarak da değerlendirmeler paylaşılmıştır.

2. Görüntü İşleme

Görüntü işleme bilgisayar sistemleri ile elde edilen bir görsel verinin işlenerek anlamlı sonuçlar üretmesinin amaçlandığı yöntemlere verilen isimdir. Bu işlemler görüntünün algılama süreçleri, elde edilen verinin onarılması, özneliklerinin çıkartılması, yorumlanması ve sonuç üretme süreçlerinin tamamını kapsamaktadır.

Öncelikle çevreden gelen bilgilerin dijitalleştirilerek bilgisayar ortamına aktarılması gerekmektedir. Bu ilk aşamada çok farklı teknolojiler ile algılama yapabilmek mümkündür. Günümüze, elektromanyetik spektrumun insan gözünün algılaya bildiği görünür bölgesinden tutunda, mor ötesi ve kızıl ötesi alanlarda da görüntüleme yapan birçok görüntüleme sistemi geliştirilmiştir. Normal kameralarda olduğu gibi bazı sistemler kaynaktan yansıyan enerjiyi algılayarak pasif algılama yaparken, Röntgen cihazlarında olduğu gibi bazı sistemlerse ortama kendi enerjilerini yayıp geri yansıma miktarlarına bağlı olarak pasif algılama yapmaktadırlar. Bazı algılayıcılar ise ses dalgası gibi elektromanyetik enerji dışında başka kaynakları kullanarak algılama yapmaktadır. Ultrason bu tarz bir algılamaya güzel bir örnektir.

Görüntüleme işlemi bir anlığına için yapıлып resim niteliğinde tek görüntü elde edilebileceği gibi belirli bir zaman zarfında periyodik olarak yapılarak video niteliğinde zamana bağlı elde edilen verilerde üretilebilir. Bu sadeye görsel veri yanında zaman bilgisi de kaydedilmiş olur.

Algılama teknolojisi ne olursa olsun sonuçta ham dijital veri oluşmaktadır. Ham görüntüler çoğunlukla görüntüleme sisteminin yapısından, çevresel etmenlerden ya da kullanıcı hatası gibi etmenler sebebiyle bazı problemler içermektedir. Görüntünün geliştirilmesi aşamasında bu problemlerin ortadan kaldırılması amaçlanmaktadır. Görüntü bir takım ön işlemlere tabi tutulur. Kamera lens sisteminin yapısından dolayı üzerinde hiçbir işlem yapılmamış veride bazı geometrik şekilsel bozulmalar olabilir. Mesela resmin köşelerine denk gelen düz bir alan eğimli olarak algılanabilecektir. Ya da algılayıcı parametrelerinden kaynaklı elde edilen görüntüde kontrast düşük çıkabilir. Bu tip hatalar gerçek sahnede olmayıp görüntünün ham halinde olan hatalardır. Bu aşamada hataların ortadan kaldırılması ile artık ham görsel veriler farklı amaçlar için kullanılmaya hazırdırlar.



Şekil 2 Görüntü işleme genel aşamaları.

Görüntünün onarılması safhasında görüntü üzerinde algılayıcı sistemin dışında sebeplerden kaynaklanan olumsuzlukların giderilmesi amaçlanmaktadır. Örneğin sahne ışıklandırılması doğru yapılmadı ise görüntünün bazı bölgeleri olması gerektiğinin aksine karanlık çıkacaktır. Bu aşamada belirli matematiksel ve olasılık yöntemler kullanılarak görüntüde iyileştirme sağlanır.

Ön işlemler sonucunda sahnenin doğru bir gösterimi elde edilen görüntü üzerinde sağlanmış olur. Bu görüntü üzerinde işlem yapmak çok daha kesin sonuçlar üretecektir. Görüntü işleme yöntemleri dijital görüntüyü oluşturan en küçük eleman olan pikseller üzerinden yürütülebileceği gibi piksellerin belirli bir mantık içerisinde gruplandırılması ile oluşan görüntü bölgeleri üzerinden de yürütülebilir. İlaveten direkt resimdeki ya da bölgedeki piksel değerlerini kullanmaktansa Fourier ve dalgacık dönüşümleri gibi matematiksel işlemlerden yararlanılarak elde edilen farklı bilgiler üzerinden de görüntü işleme yöntemleri geliştirilmiştir. Sonuçta bütün yöntemler için en temel kaynak pikselleri ifade eden sayısal değerlerdir. Bu kaynaktan bölge tespit edilmesi ya da bir dönüşüm hesaplanması görüntü işleminin konusuna dahildir.

Görüntünün özniteliklerinin çıkartılması safhasında artık görüntü üzerindeki veriler anlamlandırılmaya çalışılmaktadır. Örneğin görüntü üzerinde köşe ve kenarların tespit edilmesi özniteliğe örnek olarak verilebilir. Verilerde piksel koordinatına göre hangi piksellerin kenar hangi piksellerin köşe olduğu bilgisi diğer birçok görüntü işleme yöntemi için kullanılan önemli verilerdir. Bir diğer örnek olarak derinlik hesaplanması verilebilir. Görsel veriler iki boyutlu (2D) olarak algılanmaktadır. Bir pikselin hangi mesafede bulunduğu bilgisi üçüncü boyut ile ilişkilidir. Üçüncü boyut için o noktanın derinliği yani mesafesi hesaplanması noktayı ifade eden pikseller için bir özniteliktir. Yine belirli bir amaç maksadıyla pikseller gruplanmak istenirse, ilgili pikselin hangi gruba teknik ifadesiyle hangi bölgeye ait olduğu bir özniteliktir. Öznitelik verileri her zaman tek başına anlamlı olmayabilirler ancak görüntüden anlam çıkartılmak istenildiğinde kritik öneme sahip olabilmektedirler.

Görüntü işlemede amaç insanın görsel algısı ile yürüttüğü işlemleri bilgisayar ortamında modellemektir ve algoritmalarda yapılan şey görüntüdeki sayısal değerler üzerinde yürütülen matematiksel, mantıksal ya da istatistiksel işlemler bütünüdür. Görsel bilgiden çıkartılan sonuçların bilgisayar ortamında modellenmesi, son görüntü işleme aşaması olarak karşımıza çıkmaktadır. Bu amaçla sadece piksel değerlerinden değil önceki aşamalarda belirlenmiş özniteliklerden de faydalanılır. Buna en güzel örneklerden birisi görüntüde yüz var mı sorusuna aranan cevaptır. Bu cevabı verebilmek için görüntü üzerinde birçok işlem yapılmaktadır. Bu amaç için geliştirilmiş yüz tanıma algoritmaları günümüzde sıklıkla kullanılır.

maktadır. Çok daha gelişmiş bir amaç görüntüdeki nesnelere tanımlamak olabilir. Bu örnekte öncelikle görüntü üzerinde nesnelere varlığı tespit edilmeli sonrasında tespit edilen nesnenin ne olduğuna karar verilmelidir.

Sonuç olarak görüntü işleme teknikleri görüntüyü oluşturan piksellerin oluşturulmasından görüntünün düzgün bir şekilde sunumunu sağlamak için doğru değerlerinin hesaplanmasına, ilgili piksele ait özelliklerin hesaplanmasından bu bilgilerle insan algısına yakın algılamalar yapmaya kadar çok geniş bir konu ağını bünyesinde barındıran geniş bir bilimsel alandır. Bilişim teknolojisindeki gelişmeler görüntü işleme tekniklerinin de her geçen gün gelişmesinin önünü açmakta ve bu alana olan ilgi her geçen gün artmaktadır.

3. Yapay Zekâ

Yapay Zekâ (YZ) terimi aslında genel bir terim olup altında birçok alt başlık barındırmaktadır. Bununla birlikte genel olarak insanın akıllı davranışlarının bilişim teknolojileri ile makinelere uyarlanmasıdır. Akıllı davranışlara öğrenme, değişen koşullarda karar verebilme, değişen şartlara kendini adapte edebilme gibi örnekler verilebilir. Dolayısıyla yapay zekanın amacı, akıllı makineler tasarlamaktır.

Örneğin bir satranç oyunu oynayabilen bir yazılım, oyunun herhangi bir anında rakibin hareketine göre oluşan yeni şartlar için en iyi hamleyi seçebilmeli ve akıllı bir tutum sergilemeli ve bu tutumu oyun bitene kadar değişen her şartta sürdürebilmelidir. Diğer bir örnekte bir emlak sitesi müşterisine değişen piyasa koşullarında aradığı özelliklerdeki bir konutun olması gereken fiyatını tahmin edip, müşterinin karar verme sürecine katkıda bulunabilmelidir. Yine diğer bir örnekte bir görüntüdeki nesnelere ayırt edilebilmesi, o nesneyi görüntüde niteleyecek sayısal desenin şartlara göre değişeceği gerçeğiyle basit programsal kıyaslarla mümkün olmayacaktır. Bunun için nesnelere sayısal görüntüde ayırt edebilecek yöntemlere ihtiyaç duyulacaktır. Bu örneklerdeki gereksinimler yazılımların standart programlama ile sağlanamayacak bir zekâ unsuru barındırmasını zorunlu kılmaktadır. Bu da YZ yöntemleri ile mümkündür. YZ, doğal dil işleme, veri madenciliği, siber güvenlik ve görüntü işleme gibi popüler birçok sahada otonom araçlar, spam tespiti, sesli komut alabilen cihazlar, diller arası çeviri, mimik analizi gibi uygulamalar kullanılmaktadır.

Bu bölümde en bilindik YZ yöntemleri için alt başlıklar açılmış ve yöntemler anlatılarak var oluş amaçları örneklendirilerek vurgulanmıştır.

3.1 Makine Öğrenmesi

Makine öğrenmesi YZ'nin bir alt dalı olarak tanımlanmaktadır. Burada amaç insanın öğrenme süreçlerinin makineler üzerinde modellenmesidir. İnsan daha önce karşılaşmadığı şeyleri gözlemleyerek, edindiği bilgi-

ler neticesinde sonuç çıkartabilme yeteneğine sahiptir. Bu özellik insanın öğrenme yeteneğinin basit bir tanımı olarak sunulabilir. YZ' nin insanın akıllı davranışlarından örnek aldığı yukarıda belirtilmiştir. Alt dalı olan makine öğrenmesinde, insanın öğrenebilme özelliğinin makineler üzerine uyarlanmasını sağlayacak yöntemler bulunmaktadır.

Öğrenme süreci gözlemler ve bu gözlemlerden sonuç çıkartarak matematiksel modeller ortaya koyma temeline dayanmaktadır. Böyle bir model geliştirebilmek için öncelikle deneysel ya da gözlemsel olarak elde edilebilecek verilere ihtiyaç vardır. Bu veriler, modele modeli eğitim aşamasında doğru yönlendirme yapabilecek, farklı şartları örnekleyen, doğruluğundan emin olunan verilerdir. Test verisi olarak adlandırılan bu veriler iki giriş ve çıkış verileri olmak üzere iki kısımdan oluşur. Giriş verileri şartları tanımlarlar. Çıkış verileri ise her giriş için ortaya çıkması arzu edilen sonuçları ifade eder.

Eğitilen model test verilerindeki yapıya uygun olarak girişlere karşılık arzu edilen çıkışları üretebilecek forma gelmelidir. Bunun tipik basit testi modelin test girişleri için ürettiği çıkışların arzu edilen çıkışlara ne kadar benzediğidir. Testi geçebilen model artık test verilerinde olmayan girişler için çıkışlar üreterek tahminlerde bulunabilir.

Makine öğrenmesine en basit örnek regresyon modelleridir. Test verilerinde girişler için çıkışları minimum hata ile üretebilecek bir doğru ya da eğriyi ifade edecek matematiksel eşitlik hesaplanmaya çalışılır. Bu eşitlik genelde istenilen derecede bir polinomdur. Polinomun katsayıları örnek veriler kullanılarak yaklaşık olarak hesaplandıktan sonra test verilerinde olmayan girişlerle model kullanılabilir ve çıkışlar üretilir. Bu çıkış hiçbir zaman kesin doğruluğundan emin olunamayacağı için tahmin olarak adlandırılır.

Makine öğrenmesi yöntemleri üç grupta incelenmektedir. Bunlar denetimli, denetimsiz ve takviyeli öğrenmedir. Denetimli öğrenmede eğitim verisinde arzu edilen değerler bulunmaktadır ve eğitim için hedef bu anlamda belirlidir. Modelin sonuçlarının kıyaslanabileceği veriler vardır çünkü. Yukarıda anlatılan regresyon buna bir örnek olarak verilebilir. Denetimsiz öğrenmede ise arzu edilen bir sonuç söz konusu değildir. Eldeki veri amaca göre etiketlenmesi söz konusudur. Denetimsiz öğrenmede amaç girişler ile çıkışlar arasında bir ilişki kurmaktır ama ver kümesini tanımlamaya yönelik işlemleri içermektedir. K-Means algoritması buna örnek olarak verilebilir. Bu algoritma verileri birbirine olan yakınlık ölçüsüne göre gruplar. Son grup olan takviyeli öğrenmede ise amaç değişen şartlara göre karar verebilme yeteneğinin geliştirilmesidir. Bu kararlar aksiyon olarak nitelendirilir ve geçmiş tecrübelerden yararlanarak yeni aksiyonların ne olacağı öğrenilir. Bunun için deneme yanılma metodu ile metot

eğitilir ve tecrübe edinmesi sağlanır. Bu şekilde eğitilen model bir süre sonra edindiği tecrübelerle doğru kararlar verebilmektedir. Özellikle oyun motorlar ya da kendi başına hareket edebilen robot sistemlerinde sık kullanılmaktadır.

3.1.1 Yapay Sinir Ağları ve Derin Öğrenme

Yapay sinir ağları (YSA) en bilindik makine öğrenme yöntemlerinden biridir. Önceden belirlenmiş girişler, çıkışlar ve ara katmandaki düğümlerle oluşturulan yapısı bir problem için tasarlanır ve test verileri için en uygun değerler verilene kadar parametrelerin değiştirilmesi yoluyla eğitilir. Elde edilen YSA modeli probleme özeldir. Ancak problemin test verilerinde örneklenmemiş farklı durumlarına da genelleştirilebilir.

YSA katmanlardan, katmanlar ise düğümlerden oluşur (bkz. Şekil 3). Her bir düğüme yapay nöron adı verilmektedir ve yapısı insan beyninin temel yapı taşı olan nöronlardan esinlenmiştir. Bir yapay nöron en az bir giriş almakta ve bu girişlere karşılık bir adet çıkış üretmektedir. Temel görevi girişlere göre tetiklenip çıkış üretecek mi yoksa tetiklenmeden herhangi bir çıkışa müsaade etmeyecek mi kararını vermektir.

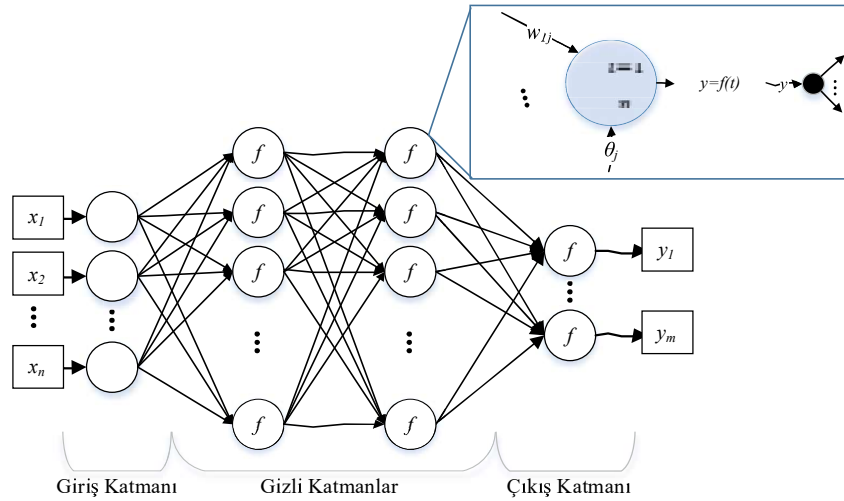
Bu karar için aktivasyon fonksiyonu denen matematiksel eşitlikler kullanılmaktadır. Bu fonksiyon nöron girişlerinin ile hesaplanan değeri kullanır. Bu hesapta öncelikle nörona giren bütün girişler farklı katsayılar ile çarpılarak ağırlıklandırılmaktadır. Son olarak bu toplam bias değeri ile ötelenerek aktivasyon fonksiyonuna gönderilmektedir. Aktivasyon fonksiyonu, aldığı değer bir eşik değeri üzerinde ise tetiklenerek sonuç üretir. Aksi takdirde sıfır değeri üretecektir.

YSA için katman sayısı minimum 3 olabilir. Bunlar giriş katmanı, çıkış katmanı ve gizli katman olarak isimlendirilmektedir. Giriş katmanında modele ait girişler alınmakta ve ilk gizli katmana ait bütün düğümlere giriş olarak dağıtılmaktadır. Giriş katmanı düğümlerinde genelde matematiksel bir işlem yürütülmez. Çıkış katmanına bir önceki gizli katmandaki tüm düğümlerden giriş gelmektedir. Bazı YSA tasımlarında bu katmanda aktivasyon fonksiyonu kullanılmaz sadece ağırlıklarla çarpılmış girişler toplanır. Bu katmanın çıkışı tüm YSA modelinin bir çıkışına denk gelecektir. Her YSA en az bir tane gizli katman bulundurur. YSA modelinin ayrıntısını büyük bir kısmı bu katmanlar yapıları ile belirlenmektedir. Bu katmanlardaki düğümler kendisinden önceki katmana ait bütün düğümlerin çıkışını giriş olarak almaktadır. Her düğüm arasındaki bağlantı için farklı bir ağırlık bulunmaktadır.

Bir YSA modelinin bir probleme uygulanabilmesi için sahip olması gereken giriş ve çıkış sayıları, kaç adet gizli katman bulunacağı ve her gizli katmanın kaç düğüm barındıracağı, her bir düğüm için hangi akti-

vasyon fonksiyonunun kullanılacağı belirlenmelidir. Bu aşama YSA'nın tasarlanma aşamasıdır. Bu model genelde katman sayıları verilecek ifade edilir. Örneğin Şekil 3'deki model n girişli m çıkışlı ve 2 gizli katmana sahip $n-2-m$ yapısında ileri beslemeli bir YSA modelini resmetmektedir. Burada ileri besleme terimi veri akışının her zaman girişlerden çıkışa doğru olduğunu ifade etmektedir. Bazı YSA modellerinde düğüm çıkışları kendilerine ya da bir önceki katman düğümlerine geri besleme yapabilmektedir. Bu tip modellere geribeslemeli YSA modelleri denilmektedir.

Sıradaki aşama tasarlanan YSA modelinin eğitilmesidir. Bunun için öncelikle problemin farklı durumlarını temsil edecek özellikte test verisi toplanmalıdır. Bu veriler YSA giriş ve bu girişler için arzu edilen çıkış değerlerini içerir. Test verileri kullanılarak geri yansımaya (backpropagation) yöntemi ya da sezgisel optimizasyon algoritmaları kullanılarak model eğitilir. Eğitim işlemi amaç modelin uygun çıkışlar üretebilmesini sağlayacak her bir bağlantıya ait katsayı ve bias değerlerini tespit etmektir.



Şekil 3 Örnek n girişli m çıkışlı 2 gizli katmanlı ileri beslemeli yapay sinir ağı modeli ve yapay nöronun iç yapısı.

Derin öğrenme YSA'daki gizli katmanın adeti ile ilişkili bir terim olarak karşımıza çıkmakta. Bir YSA'nın gizli katman sayısı onun model karmaşıklığını artırmakta ve daha derinlemesine modelleme yapabilmenin önünü açmaktadır. Derin öğrenme ismi de buradan gelmektedir. Günümüz karmaşık problemleri için çok daha fazla gizli katman içeren ve düğüm sayıları daha fazla olan büyük YSA lar kullanılmaktadır. Bu durum eğitimde belirlenecek parametre sayısını artırmakta ve hesaplamaları zorlaştırmakla birlikte gelişen işlemci güçleri paralel hesaplama teknikleri gibi işlem kapasitesini artırıcı yöntemlerle bu zorluğun üstesin-

den gelinebilmektedir. Bu durum ise günümüzde derin YSA modellerinin yaygınlaşmasına sebep olmaktadır.

Ayrıca görüntü işleme uygulamalarında geliştirilerek daha sofistike hale getirilmiş YSA modelleri kullanılmaktadır. Bunlara en temel örnek olarak Evrişimli sinir ağları (ESA) verilebilir. Bu modelde YSA görüntüye ait piksel değerlerini giriş olarak almaktansa öncelikle belirli seviyelerde görüntüye ait öznitelikleri çıkartmakta ve bu değerler ile bir ağ oluşturmaktadır.

3.2 Optimizasyon Algoritmaları

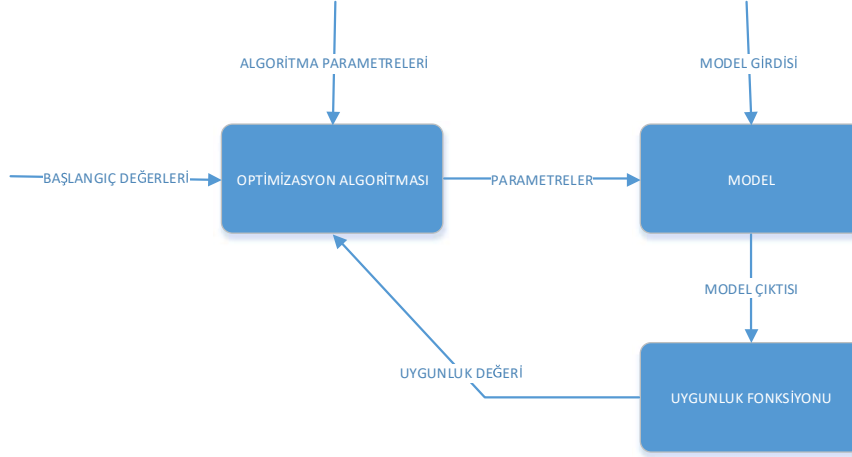
Optimizasyon herhangi bir YZ süreci için tasarlanmış matematiksel modelin en iyi çalışabileceği şartları bulmak için kullanılan süreçler ve geliştirilmiş algoritmaları ifade etmektedir. İyi optimize edilmiş bir model uygun sonuçlar verecektir. Aksi takdirce uyumsuz sonuçlar kaçınılmazdır.

Bilişim sistemlerinde çoğu zaman bir problem için, tanımlanmış veri girişlerine karşılık uygun sonuçları üretecek kompleks matematiksel modeller kurgulanır. Bu modeller farklı bilimsel çalışmalar ve formülasyonlardan faydalanmaktadır. Bununla birlikte, böyle kompleks sistemler bazı parametrelere bağlı çalışırlar. Gerekli olan parametrenin sayısı, ne işe yaradığı, ifade edildiği veri türü her problemin kendi doğasına özel olarak mühendislik çalışmaları ile belirlenebilirler. Bu işlemler başlı başına bir mühendislik becerisi ve probleme özel tecrübe gerektirecektir. Bununla birlikte, sistemler parametre değerlerinin ayarlanmasına muhtaçtırlar.

Basit modeller için parametre değerlerini deneme yanılma yoluyla tespit etmek mümkündür. Ancak kompleks sistemler için parametrelerin alabileceği değer aralıkları, parametre sayıları ve bunların kombinasyonu için tespit edilmesi gereken değerler göz önüne alındığında deneme yanılma ile uygun sonuçlar bulmak samanlıkta iğne aramaya benzetilebilir.

Parametreleri doğru bir şekilde tespit edilmiş bir matematiksel modelin ise ihtiyaca en uygun şekilde ayarlanması optimizasyon işlemleri ile mümkün olacaktır. Bir optimizasyon algoritması en uygun parametre değerlerini bulmak için iterasyonlar gerçekleştirir. Her iterasyonda daha iyi bir çözüm bulmaya çalışır ve sürekli çözümlerini iyileştirir. Türeve dayalı en dik iniş algoritması ya da sezgisel genetik algoritma tipik en bilindik optimizasyon algoritması örneklerindedir. Optimizasyon algoritmalarının kendine özel parametreleri vardır. Bu parametre değerleri tecrübe ya da deneysel yollarla belirlenerek algoritmanın performansının artırılması mümkün olmaktadır. Ayrıca optimizasyon algoritmaları bir uygunluk fonksiyonuna ihtiyaç duymaktadır. Bu fonksiyon algoritmanın ürettiği sonuçların amaca ne kadar hizmet ettiğini sayısal olarak değerlendirecek

fonksiyonlardır ve optimizasyon algoritması ile eğitilecek modelin amacına uygun olarak tasarlanmalıdır.



Şekil 4 Optimizasyon algoritmaları ile eğitim sürecinin genel şeması.

Bir optimizasyon sürecine YSA'nın parametrelerinin tespiti örnek olarak verilebilir. Bu örnekte optimizasyon algoritması en uygun katsayı setini üretmeye çalışır. Uygunluk fonksiyonu ise bu parametrelerle YSA modeli çalıştırıldığında test verileri için ürettiği sonuçların gerçek sonuçlarla olan farkı olarak tasarlanabilir.

3.3 Bulanık Mantık

Bulanık mantık insanoğlunun karar verme şeklinin bilgisayar ortamına uyarlanmış halidir. Bilgisayar programlamada her şey bir ve sıfır olarak ele alınır. Dolayısıyla da mantıksal bir önerme doğru ya da yanlış olarak kodlanabilmektedir. Bulanık mantıkta ise sonuç bir ve sıfır yerine ara değerler olarak değerlendirilebilmektedir. Bu durum bilgisayarla karar verme süreçlerinin insan gibi yapılabilmesine olanak sağlamaktadır.

4 Yapay Zekâ Teknikleri Kullanıldığı Görüntü İşleme Çalışmaları

İlk sayısal görüntü fikri 19. yüzyıl sonlarında Shelford Bidwell tarafından ortaya atılmıştır. Bu fikir resmin elektronik bir sinyal olarak iletilmesine dayanmaktaydı. Sayısal görüntünün ilk uygulamalarından biri, basılı bir resme ait bilgilerin okyanus altından kablolar vasıtasıyla gönderilmesi ve tekrar basılabilmesi ile 1920'lerde gerçekleşmiştir (Mcfafuane, 1972). Geliştirilen sistem baskı çoğaltma ve iletimi için kullanılmıştır (Gonzalez & Woods, 2008).

Sayısal veriyi alıp işleyebilen ve kaydedebilen bilgisayar sistemlerinin ilk geliştiği yıllarda bellek kapasitesi bir görüntüyü saklayabilmek

için çok yetersiz seviyedeydi. Bununla birlikte, donanımsal gelişmeler görüntülerin sayısal olarak saklanabilmesinin önünü açmıştır. Günümüz bilgisayarlarında kullanıldığı anlamda ilk sayısal görüntü 1957 yılında Russell Kirsch tarafından geliştirilmiş sayısal görüntü tarayıcı tarafından elde edilmiştir. Analog bir resmin bu tarayıcı ile taranarak sayısal hale dönüştürülmüştür. Elde edilen görüntü 176x176 pikselden oluşan siyah beyaz bir görüntüydü (Russell Kirsch/NIST, 2022). 1968 yılında ışığı sayısal sinyale dönüştüren ilk algılayıcı Peter Noble tarafından geliştirilmiştir (Noble, 1968). Bu algılayıcı analog bir resme ihtiyaç olmaksızın çalışan ilk algılayıcıdır. İlk yarı iletken görüntü algılayıcısı olan CCD (Charge Coupled Device) 1969 yılında geliştirilmiştir (Boyle & Smith, 1970). Bu gelişmeler sayısal görüntülerin oluşmasını sağlayan donanımların başlangıcı niteliği taşımaktadır.

Görüntüleme teknolojilerindeki gelişmelerle birlikte bilgisayar sistemleri de gelişmeye devam etmiş görüntüyü sayısal olarak saklayıp işleyebilecek özelliklerde bilgisayarlar 1960'lı yıllarda geliştirilmiştir (Gonzalez & Woods, 2008). Bununla birlikte 50'li ve 60'lı yıllarda üst düzey programlama dillerinin gelişmesi sayısal görüntü verileri üzerinde işlemler yapabilmeyi kolaylaştırmış, sonuç olarak da bu alanda algoritmalar geliştirilmesinin önü açılmıştır.

İlk görüntü işleme uygulamaları benzer dönemde yürütülen ay görevleri sırasında ay yüzeyinin gönderilen görüntülerinin düzeltilmesi işlemleri ile kendini göstermiştir. Uzay çalışmalarına ilaveten 70'li yılların başlarında ilk kez bilgisayarlı tomografi (CT) olarak bilinen cihazların geliştirilip bir insan beyninin filmi alınması ile tıp alanında da görüntü işleme uygulamaları görülmeye başlamıştır. Bilgisayar sistemlerinin bu gücü keşfedilmesi ile uzay çalışmaları, tıp, astronomi, haritacılık gibi birçok alanda görüntülemeye olan ihtiyaç zaman içerisinde görüntü işleme tekniklerinin geliştirilmesi için motivasyon kaynağı olmuştur.

Görüntüleme sistemleri ve görüntü işlemenin ortaya çıkmasına paralel olarak insan gibi düşünen makineler üretme fikri temelinde yükselen YZ teknikleri de diğer taraftan gelişmekteydi. İkinci dünya savaşında Alman iletişim cihazı Enigma makinesinin şifresini çözmek maksadı ile yürütülen çalışmalarda, Alan Turing tarafından ortaya atılan “makinelere düşünebilir mi” sorusu ile günümüzdeki yapay zekanın temelleri atılmıştır (Russell & Norvig, 2020). Ortaya çıkan insan gibi davranan makine fikri, oluşan yeni şartlara adaptasyon gibi insan zekâsı özelliğine ihtiyaç duymuş ve makine öğrenmesi yöntemleri geliştirmek için güçlü bir motivasyon kaynağı olmuştur. Warren S. McCulloch ve Walter Pitts tarafından yürütülen çalışma ilk YZ örneklerindedir. Bu çalışmada insan beyninin yapıtaşları olan nöronlar modellenmiştir. McCulloch-Pitts sinir modeli olarak bilinen bu yapay nöron modeli ile belirli koşulları karşılayan herhan-

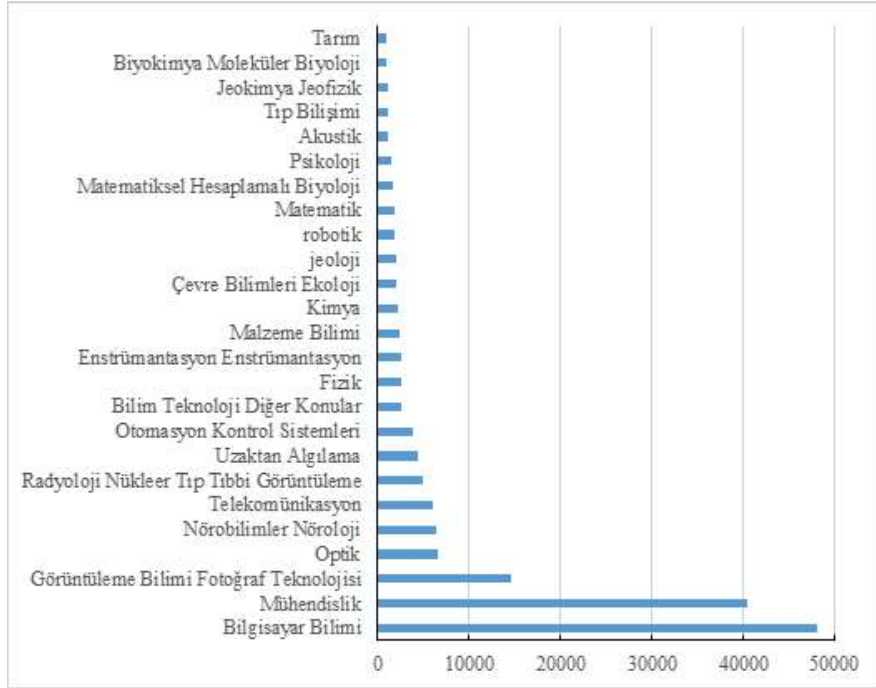
gi bir mantıksal ifade için onun tanımladığı şekilde hareket eden bir net bulunabileceği gösterilmiştir (McCulloch & Pitts, 1943). Bu çalışma ile yapay sinir ağlarının temeli atılmıştır. İlk YZ terimi resmi olarak 1956 da John McCarthy tarafından bir yaz çalıştayında kullanılmıştır (McCarthy, Minsky, Rochester, & Shannon, 2006). Bu dönemde deneme yanılmalarla tüm kombinasyonların denenmesi yöntemi ile sistemler çözülmeye çalışılıyor bu da donanımsal kaynakların etkin kullanılamaması problemi yaratıyordu. 50 lerin sonlarında şimdiki genetik algoritmanın ilkel versiyonu olan yöntem Friedberg tarafından önerilmiştir (Friedberg, 1958; Friedberg, Dunham, & North, 1959). Bu çalışma evrimsel hesaplamanın tanımlandığı ilk çalışmalardandır. Bu sistem makine kodunda bazı mutasyon olarak adlandırılan küçük değişiklikler yapılarak daha iyi çalışan programlar oluşturulması mantığıyla çalışmaktaydı. Böylece deneme yanılma yönteminde hızlanma amaçlanmıştır. Modern genetik algoritma 1975 tarihinde John H. Holland tarafında geliştirilmiştir (Holland, 1975). Bu algoritma belirli bir amaca yönelik sistemin uygun girişlere karşı arzu edilen sonuçları üretebilmesi için gereken sistem parametrelerini sayısal olarak bir dizi seleksiyon çaprazlama ve mutasyon gibi evrimsel işlemlerin gerçekleştirilmesiyle elde edilmektedir. Genetik algoritmanın görüntü işleme alanında sıklıkla kullanılmıştır.

Görüntü işlemenin geliştiği ilk yıllarda görüntünün daha doğru sayısal temsili elde etmek amacıyla Şekil 2’de belirtilen ilk üç aşama olan görüntünün elde edilmesi, geliştirilmesi ve onarılmasına yönelik yöntemlere ihtiyaç duyulmuştur. Bu yöntemler insan algısını iyileştirmeye yöneliktir. Bununla birlikte makine algısına yönelik görüntü işleme yöntemleri de geliştirilmeye başlanmıştır (Gonzalez & Woods, 2008). Bu bir görüntü içeriğini tanımlayabilecek işlemleri ifade etmekteydi. Görüntüdeki örüntünün tespiti, kenar ya da köşe tespiti bu işlemlerin belirgin örnekleridir. En iyi dönüşüm belirlenmesiyle çalışan örüntü tespiti yöntemi ilk zeki görüntü işleme çalışmalarına örnek olarak verilebilir (Preston & Carvako, 1972). 70 lerin sonlarında popüler bir denetimsiz öğrenme yöntemi olan K-Means algoritması görüntülerin bölütlenmesi amacıyla kullanılmaya başlanmıştır (Coleman & Andrews, 1979). Bununla birlikte görüntü işlemede sıklıkla kullanılan Canny kenar tespit algoritması 80 yılların ikici yarısında önerilmiştir (Canny, 1986). Bu algoritmada en iyi kenar belirleyicinin tespiti için sayısal optimizasyon kullanılmıştır. 90’larda ise yüz tespiti problemlerinin bir ihtiyacı olarak YZ nin görüntü işlemede uygulandığı örneklerle karşılaşmaktayız (Bouattour, Soulié, & Viennet, 1992; Turk & Pentland, n.d.).

En bilindik YZ modellerinden olan YSA görsel bilgiler için piksel değerlerini almakta ve sonuç üretmekteydi. Görüntünün ön adım olarak birtakım işlemlerden geçmesiyle elde edilen anlamlı bilgileri (çizgiler,

eğriler gibi ya da daha derin olarak yüz, nesne gibi) sinir ağına giriş olarak alan evrişimli sinir ağları (Convolutional Neural Network-CNN) 1980 yılında ortaya çıkmakla birlikte 2000 li yıllarda görüntü işleme uygulamalarında yaygınlaşmıştır. Şekil 1’deki son yirmi yılda görüntü işleme sahasında YZ kullanımına dair verilen grafik incelenecek olursa 2015-2017 yıllarından sonra bu sahada yapılan araştırmaların ivmelendiği görülebilir. Bu durumun, CNN gibi görüntüyü daha iyi analiz edebilen YSA modellerinin yaygınlaşmasının ve gelişen donanımlarla YSA modellerinde daha fazla ara katman kullanarak giriş ve arzu edilen sonuçlar arasında daha doğru ilişkiler kurabilen derin ağların gelişmesinin bir sonucu olduğu gözlemlenmektedir.

Günümüzde YZ uygulamalarını hayatın birçok alanında görmekteyiz. Şekil 5’ de YZ kullanılarak geliştirilmiş görüntü birleştirme tekniklerinin kullanıldığı akademik yayınların sayılarının araştırma alanlarına göre dağılımı gösterilmektedir. Veriler Web of Science indeksinden alınmıştır. Verilerden görülebileceği gibi tarımdan bilgisayar bilimlerine çok farklı alanlarda YZ ile görüntü işleme tekniklerine başvurulduğu görülmektedir.



Şekil 5 Yapay zekâ kullanılmış görüntü işleme yöntemlerine ait yayın sayılarının Web of Science indeksi araştırma alanlarına göre dağılımı.

4.1 Bilgisayar Bilimi Alnındaki Çalışmalar

Bilgisayar bilimi YZ ve görüntü işleme yöntemlerinin geliştirilmesini amaç edinen temel bilim dallarından biridir. Bu yanı ile bu alanda görüntü işleme ve YZ tekniklerinin kullanıldığı birçok çalışma bulunmaktadır.

Literatürde görüntü işleme için özelleşmiş ya da görüntü verilerini de işlemede başarılı olan YZ tekniklerinin geliştirildiğine sıklıkla tanık oluyoruz. Ian Goodfellow ve arkadaşları tarafından 2014 de önerilen çekişmeli üretici ağlar (generative adversarial networks-GAN), yazdıkları makalede zıt şekilde çalışan iki sinir ağı olarak tanımlanmıştır (Goodfellow et al., 2020). GAN görüntü işleme alanında da oldukça ilgi görmeye başlamış bir derin öğrenmeli sinir ağı modelidir ve temelde iki ağ içermektedir. Ağlardan biri bir görüntü oluştururken diğeri bu görüntüyü değerlendirerek gerçekliğine karar vermektedir. Böylece sanal görüntüler üretilmektedir. EfficientNet ismi verilen diğeri bir model türünce CNN yapısı geliştirilmiş ve literatüre sunulmuştur (Tan & Le, n.d.). Yürütülen çalışmada EfficientNet yapısının ImageNet veri setinde 84,3% lük doğruluk ile CNN yapısına göre 6,1 kat daha hızlı sonuç ürettiği gösterilmiştir. Grad-CAM ismi verilen teknik görüntü sınıflandırma, görüntü tasviri ve görsel soru cevaplama amacıyla CNN tipi ağlar üzerine geliştirilmiş bir diğeri örnektir (Selvaraju et al., 2020). Yapılan çalışmada bu teknik CNN ağı sonuçları için görsel açıklama tekniği olarak tanımlanmıştır. ShuffleNet isimli teknikle CNN yapısı limitli donanım kaynağı olan mobil cihazlarda kullanılacak şekilde organize edilerek yani bir tasarım ortaya konulmuştur. (X. Zhang, Zhou, Lin, & Sun, 2018). Res2Net isimli sistem de CNN yapısının çok ölçekli temsil özelliğinin geliştirildiği bir başka çalışma olarak karşımıza çıkmaktadır (Gao et al., 2021).

Genel bir model geliştirmenin yanı sıra özel bir amaca özel yapılmış çalışmalarda bulunmaktadır. Örneğin bir çalışmada yazarlar semantik görüntü bölütleme yöntemi geliştirmişlerdir (L.-C. Chen, Papandreou, Kokinos, Murphy, & Yuille, 2018). Bu çalışmada derin öğrenme ile CNN ağları temelli DeepLab ismini verdikleri bir model önerilmiş ve etkinliği PASCAL VOC 2010 veri seti üzerinden gösterilmiştir. Diğeri bir çalışmada, evrişimli blok dikkat modülü (Convolutional Block Attention Module) ismini verdikleri bir eklenti ileri beslemeli CNN ağları için geliştirilmiş ve nesne tanıma amaçlı test edilmiştir (Woo, Park, Lee, & Kweon, 2018). Deneysel çalışmalarda ImageNet-1K, MS COCO ve VOC 2007 veri setleri kullanılmıştır. Yine semantik bölütleme için önerilen bir diğeri yöntemde yazarlar var olan sistemlerin performansının artırıldığını yayınlarında göstermişlerdir (L. C. Chen, Zhu, Papandreou, Schroff, & Adam, 2018).

Bilgisayar bilimleri görüntü işlemede YZ tekniklerinin en çok kullanıldığı alanlardan biri olarak karşımıza çıkmaktadır (Bkz. Şekil 5). Bu

alanda yürütülen çok fazla çalışma bulunmakta ve genel olarak görüntü işlemede kullanılabilecek yeni modeller tasarlamak ya da modelleri özel bir uygulamada daha iyi sonuçlar verebilecek iyileştirmelerde bulunmak temelli çalışmalar yürütüldüğü gözlemlenmiştir.

4.2 Mühendislik Alanındaki Çalışmalar

Mühendislik alanındaki çalışmalarda uygulamalı yöntemlerin var olduğu görülmektedir. Örneğin görüntü erişimi (image retrieval) uygulamasının gerçekleştirildiği bir çalışmada sorgu olarak kullanılan görüntünün özellikleri kullanılarak en uygun görüntülere erişebilmek hususunda verimli bir yöntem geliştirilmeye çalışılmıştır (Khaleel, 2022). Bu maksatla çalışmada görüntü özellikleri çıkartmak için lineer diskriminant analizi yöntemi, benzerlik analizi için cuckoo arama algoritması, karınca koloni optimizasyon algoritması ve tek katmanlı YSA yapısı kullanılmıştır. Ayrıca cuckoo arama algoritması ile bulanık mantığın hibrit olarak kullanıldığı yeni bir görüntü özellik kıyaslama yöntemi de çalışmada önerilmiştir. Bir başka çalışmada farklı modlardaki hedef ve nesnelere tanımlamak için görüntülerin işlendiği analiz edildiği ve anlaşılmaya çalışıldığı görüntü özelliği tanıma uygulaması yapılmıştır (Zou, Fu, & Li, 2019). Çalışmada kamyon numaralarının tespiti için derin öğrenmeli CNN yapısı kullanılmıştır. Diğer bir ilginç çalışmada çiftçiler tarafından bireysel olarak verimsiz ve yüksek maliyetli bir şekilde yürütülen mango meyvesinin sınıflandırılması işleminin görüntü işleme kullanarak YZ teknikleri ile daha verimli hızlı ve doğru bir şekilde yapabilecek mango sınıflandırma sistemi geliştirilmiştir (Thong, Thinh, & Cong, 2019). Bu maksatla YSA yapısıyla sınıflandırma yapılırken öncelikle görüntü işleme ile meyvenin şekil özellikleri görüntü üzerinden tespit edilmiştir.

Özellikle mühendislik sınıfında yürütülen çalışmaların birçoğu aynı zamanda bilgisayar bilimleri alanına da girdiği not edilmekle birlikte çok çeşitli uygulamalarda görüntü işleme ve YZ tekniklerinin kullanıldığı bu saha için tespit edilmiştir.

4.3 Görüntüleme Bilimi ve Fotoğraf Teknolojisi Alanındaki Çalışmalar

Görüntü elde etme ve görüntüden dijital bilgi çıkartma konularını kapsayan bu alanda da YZ ile yürütülmüş birçok çalışma olduğunu görmekteyiz.

Bu alanda popüler olan başlıklardan biri, düşük çözünürlükteki görüntüden yüksek çözünürlüklü görüntü elde etme yöntemi olan süper çözünürlüktür (SÇ). Zhang ve arkadaşları tarafından yürütülmüş çalışma SÇ için güzel bir örnektir (Y. Zhang et al., 2018). Bu çalışmada RSAN ismi verilen bir model önerilmiş ve başarımı yürütülen çalışmalarla gösteril-

miştir. Görüntü rekonstrüksiyon işlemleri bu sahada yürütülen bir diğer işlemdir. Elde edilen bilgilerden iki ya da üç boyutlu görüntüler oluşturması ya da kayıp bilgilerin elde edilmesi ile görüntü kalitesinin artırılması şeklinde kullanılan yöntemlere örnek olarak verilebilecek literatürde yayınlanmış bir çalışmada görüntülerin çözünürlük kalitelerinin artırılmasına için testler yürütülmüş ve EPGN ismini verdikleri derin ağ önerilmiştir (Q. ; Zhang et al., 2022).

Optik karakter tanıma, görsel üzerindeki karakterleri tanıyıp metin haline dönüştürme yöntemleri olarak tanımlanmakta, önceleri tarayıcıdan görüntüsü alınmış belgelerin metin belgesini oluşturmakta kullanılırken günümüzde mobil cihazların kamerası ile alınan görüntülerdeki metinlerin tespit edilerek doğal dil işleme uygulamalarından, metinden konuşma uygulamalarına kadar çok farklı teknikler için girdi sağlayabilmekte böylece kendisine birçok uygulama sahası bulmaktadır. Bu alanda yürütülmüş bir çalışmada İngilizce dışında farklı dillerde el yazması ya da bilgisayar baskısı görüntülerden karakter tanıma yapan bir YSA temelli bir sistem geliştirilerek 800 görüntü üzerinden %85 doğrulukta çalıştığı gösterilmiştir (Waruna, Premachandra, Jayakody, & Kawanaka, 2022).

Bu alanda bir görüntüden amaca özel bilgi çıkartan çalışmalarla da literatürde karşılaşılabilir. Görüntüden UML (Unified Modelling Language) sınıf diyagramı üretme bu konuda yapılmış enteresan çalışmalardan bir tanesidir (Nedelcu, Ionita, Mocanu, & Saru, 2022). Çalışmada modele verilen gemi modellerinin özellikleri sınıf diyagramı olarak üretilmekte ve sınıfta geminin türü, yolcu kapasitesi, katsayısı rengi hızı gibi bilgiler tutulmaktadır.

Bir başka çalışmada tehlikeli anlarda önlem amaçlı silah tespiti uygulaması geliştirmek amacıyla CNN temelli modeller kullanılmıştır (Das & Tomar, 2022). Modeller öncelikle internet filmleri ateşli silahlar veri tabanı kullanarak silah görüntüleriyle ön eğitime tabi tutulmuş nihai modeller ise MS COCO veri seti kullanılarak birbiri ile kıyaslanmıştır sonuç olaraksa YOLOv3 modelinin en iyi sonuç verdiği not edilmiştir.

Yapılan literatür aramasında araştırma alanı olarak bu sahanın etiketlendiği son bir sene içerisinde beş bini aşkın çalışma olduğu not edilmiş olup YZ yöntemlerinin alanda sıklıkla kullanıldığı görülmüştür.

4.4 Tıbbi Görüntüleme Alanındaki Çalışmalar

Görüntü işleme teknikleri birçok alan gibi tıp ve sağlık alanlarında da sıklıkla kullanılmaktadır. Bilgisayarların yaygınlaşması ve sağlık alanında kullanılmasıyla, bu alandaki bilgi enformatiği de aynı şekilde artmıştır. Görüntü işlemenin tıbbi görüntüleme işlemlerinde kullanılmasıyla invazif olmayan muayene yöntemleri gelişmiştir. Bununla birlikte, tıbbi tanı iş-

lemleri de görüntü içeren enformatik bilgi ile daha anlaşılır ve daha doğru tanı konulabilir hale gelmiştir. Bilgisayarlı tomografi, röntgen ve ultrason gibi cihazlardan elde edilen görüntüler ile hem tanı hem de tedavi süreçleri gelişmiştir. Hekimler açısından birçok kolaylık sağlanmıştır. Tanı sürecindeki hız ve doğru karar vermenin sağlanması ile tedavi süreçleri hızlanmış ve düşük maliyetli bir hale gelmiştir. Hasta açısından da benzer faydalar sağlanmıştır. Nitekim tıbbi görüntülerin elde edilmesi ile doğru tanıya hızlı ulaşılmasının sağlanması ile tedavi süreçleri de aynı şekilde hızlı ilerlemekte ve hastanın hastalığa bağlı semptomları ile psikolojik süreçleri de çabuk iyileşmektedir.

Tıbbi görüntülemenin sağlık alanında kullanılması oldukça eski bir konudur. Nitekim 19. Yüzyılın sonlarında tesadüfen keşfedilen X ışınları sayesinde röntgen cihazı geliştirilmiş ve vücudun ilk görüntüleme işlemleri bu gelişme ile başlamıştır (Röntgen, 1898). Bu gelişme öylesine kıymetli bulunmuştur ki aynı dönemde fizik alanında Nobel ödülü de bu gelişmeyi duyuran W.C Röntgen' e verilmiştir. Ancak tıbbi görüntüleme sistemlerindeki gelişmeler röntgen ile sınırlı kalmamıştır. Sonrasında birçok teknolojik gelişmeyle birlikte tıbbi görüntüleme sistemlerinde gelişmeler kaydedilmiştir. Örneğin, görünür bölge ışınları kullanılarak endoskopi, gastroenteroloji işlemleri yapılmaktadır (Atlan & Pençe, 2021). X ışınlarının kullanılması ile bilgisayarlı tomografi ve manyetik rezonans görüntüleme işlemleri yapılmaktadır. Gama ışınları kullanılarak, nükleer tıp alanındaki görüntüleme işlemleri yapılmaktadır. Ultrason işlemlerinde ise yüksek frekanslı ses dalgaları kullanılmaktadır (Bushberg, Seibert, Leidholdt, & Boone, 2011).

Teknolojinin gelişmesiyle tıbbi görüntüleme sistemleri zaman içerisinde güçlenmiş ve çeşitlenmiştir. Nitekim zaman içerisinde çeşitlenen hastalıkların tespitinde, hekimler karar verme süreçlerinde de tıbbi görüntülemelerden fazlasını beklemeye başlamıştır. Bu ihtiyaç sonrasında, tıbbi görüntüleme sistemleri ile makine öğrenmesi ve veri madenciliği beraber kullanılmaya başlamıştır. Müjdat Tiryaki tarafından yapılan mamografi görüntüleri yapay sinir ağları kullanılarak sınıflandırılmış ve yüzde 85 gibi yüksek bir oranla doğru bulguların elde edildiği raporlanmıştır (Müjdat Tiryaki, 2020). Bir diğer çalışma da derin öğrenme yöntemleri kullanan dopler ultrason görüntülerinde tümörlerin iyi huyu – kötü huyulu olarak sınıflandırmasını sağlamıştır (Shia & Chen, 2020). Sarhan, MRI görüntülerinde tespit edilen beyin tümörlerini sınıflandırmak için Dalgacık Tabanlı Evrişimli Sinir Ağı (WCNN) kullanmıştır ve %99.3 doğruluk oranına sahip sonuçlar elde etmiştir (Sarhan, 2020).

Yapılan çalışmalar göstermiştir ki, farklı enerji türlerinin kullanılmasıyla farklı görüntüleme teknikleri tıp alanında sıklıkla kullanılmaktadır. Ancak yürütülen çalışmalar zaman içerisinde gelişen teknolojiyle baş-

kalaşmaya başlamıştır. Yürütülen çalışmaların da çağın gerekliliklerine uyum sağlaması adına diğer uygulamalarla birleşmesi kaçınılmaz bir sonuç olarak ortaya çıkmıştır. Bu bağlamda tıbbi görüntü işlemleri ile YZ teknikleri bir arada kullanılmaya başlamış ve bu entegrasyon giderek derinleşmektedir.

4.5 Diğer Alanlardaki Çalışmalar

Bilişim teknolojileri, endüstri 4.0 ile birçok alanda daha yoğun kullanılmaya başlamıştır ve elde edilen kazanımlar eksponansiyel olarak artmaktadır. Nitekim endüstri 4.0 birçok sektör açısından çok önemli gelişmeler getirmiştir. Hız, ekonomik, dayanıklılık gibi birçok avantaj uygulama alanındaki ihtiyaca göre entegre edilmiştir. Bu anlamda yürütülen çalışmaların bir kısmında YZ etkisi görmek mümkündür. Alan sınırlaması olmaksızın, hemen her sektör de yapay zekaya ilişkin bir örnek görmek mümkün olmaktadır.

Otomotiv sektöründe, son yıllarda kullanımı giderek artan YZ uygulamaları görmek mümkündür. Akıllık fren sistemleri, otomatik park asistanı, akıllı şerit takip sistemi gibi doğrudan güvenlik ve konfor uygulamalarının yanı sıra adaptif aydınlatma sistemleri ve motor gücünün elektriksel pillerde akıllı depolanmasını sağlayan teknolojilerde de YZ teknolojilerinden faydalanılmaktadır (Kulikov & Bickel, 2019; Pananurak, Thanok, & Parnichkun, 2009; Yüzgeç, Şahin, Bölüm, Şeyh, & Üniversitesi, 2017)

Bankacılık sektörü, YZ uygulamalarının sıklıkla görüldüğü bir diğer alan olmaktadır. Günümüz bankacılık sistemlerinde ileri seviyede YZ teknolojisi kullanılmaktadır. Sürekliliği esas alan e-dijital dönüşüm süreçleri ve dijital bankacılık uygulamalarında verilen hizmet üretimi sürecinde YZ tabanlı uygulamalar ve aplikasyonlar devamlı olarak kullanılmakta ve her geçen gün bir yaygınlaşmaktadır. Yürütülen bir çalışmada bankacılıktaki kara para aklamanın YZ ile tespitine yönelik bir çalışma yürütmüş ve yatırım bankacılığı açısından ne denli önemli olduğuna işaret etmiştir (Vedapradha & Ravi, 2018). Bankacılıkta dijitalleşme kapsamında, öğrenen yapay zekâ desteğiyle sorunlu kredilerin belirlenmesi isimli tez çalışmasında risk teşkil eden kredilerin belirlenmesinde YSA'nın kullanımının öneminden bahsetmiştir. Böylelikle banka karlılıklarına doğrudan etki edebileceğinin altı çizilmiştir (Ceran, n.d.)

YZ teknikleri birçok mühendislik dalında kullanılmaktadır. Yukarıda bu hususlarla ilgili birçok örnek de verildi. Ancak kullanımının giderek yoğunlaştığı bir diğer saha ise inşaat mühendisliği alanıdır. Bu hususta yürütülen onlarca çalışma bulunmaktadır. Örneğin bir çalışmada uçucu külün betonun basınç dayanımı üzerindeki etkisini YZ ile modellemişlerdir (Teknolojileri et al., 2016). Bunun sonucunda betondan istenen ba-

sınç değerini belirleyecek uçucu kül oranı YZ ile belirlenmiştir. Bir diğer çalışmada YSA kullanılarak kullanılması gereken yalıtım malzemesinin kalınlığı tespit edilmiştir (Keleşoğlu, Ekinci, & Fırat, 2005). YSA 'nın önerdiği kalınlık ile matematiksel olarak elde edilmesi gereken kalınlığın tatminkâr bir doğrulukta olduğu raporlanmıştır. İnşaat mühendisliğindeki uygulamalar sadece modellemek ya da tahmin etmek yönünde değildir, optimizasyon da inşaat mühendisliği branşında faydalanılan alanlardan birisi olmuştur. Örneğin bir diğer çalışmada en iyi inşaat maliyetini hesaplamak için genetik algoritmalarından faydalanmışlardır (Fairbairn, Silvos, Toledo Filho, Alves, & Ebecken, 2004).

5 Sonuç ve Değerlendirme

20.yüzyılın ortalarında ortaya çıkan YZ fikri hem ülkemizde hem de dünyada kabul görmüştür. YZ'nın insan düşünce yapısını taklit eden karakteristiğinden birçok alanda aktif olarak faydalanılmıştır. Uzman sistemler geliştirilmiş ve karar veren yapılar endüstriyel anlamda kullanılmaya başlanmıştır. Bu anlamda 1950 'lerde ortaya çıktığı noktadan çok daha gelişmiş durumdadır. Birçok programlama dili, YZ uygulamalarının kendi içerisinde hayat bulmasına olanak tanıyacak şekilde yenilenmiştir. Nitekim YZ 'nin uygulama alanları o kadar değişmiştir ki, buna uyumlu hale gelmekte önemli bir problem olmuştur. Çünkü YZ bir merak olmaktan çıkmış, çağın gerekliliği haline gelmiştir.

Günümüzde yapay zekâ uygulamaları gündelik yaşamımıza sirayet etmiş, ev eşyalarından araçlara cep telefonlarından kişisel bilgisayarlara birçok dijital cihazda kendisini göstermektedir. Bu çalışmada insanın en önemli algılarından biri olan görsel algılamının dijital uygulamalarında hayatımızı oldukça fazla etkileyen YZ etkisi irdelenmiş gelişim süreçleri anlatılmış ve son beş yıldaki bilimsel çalışmalar özetlenmiştir. Şekil 5'de de görülebileceği gibi alanda çok fazla çalışma var olup hepsinin bir çalışmada özetlenmesi mümkün olmamakla birlikte bu çalışmaların en çarpıcılar ve en çok atıf alanları incelenmiş ve en yaygın kullanım alanlarına değinilmiştir. Bununla birlikte yapılan literatür taraması her ne kadar farklı araştırma alanları için ayrılsa da alanlar arasında çok keskin sınırlar bulunmamakta. Bazı çalışmalar birden fazla alanla ilişkili olabilmektedir.

Yapılan araştırmalar göstermiştir ki derin öğrenme görüntü işleme üzerinde büyük bir etki bırakmaktadır. Donanımsal güç ile birleştiğinde eğitilmesi mümkün olmuş ve güçlü bir genelleştirmeye sahip modeller ortaya konulabilmektedir. Mobil cihazlarda dahi bu modellerin kullanılabilmesi geliştirilen yöntemlerin kullanım sahasını da genişlettiği görülmektedir.

Yapılan çalışmalarda son yıllarda uygulama aracı olarak YZ için Tesorflow ve Pytorch gibi Python dili kütüphanelerinin görüntü işleme içinse OpenCV yazılım kütüphanesinin öne çıktığı gözlemlenmiştir. Bu-

nun sebebinin Python dilinin sağladığı kütüphane zenginliği ve uygulama kolaylığı ile elde ettiği son yıllardaki popülaritesiyle birlikte adı geçen kütüphanelerin dünyaca ünlü yazılım devleri tarafından geliştirilip destek veriliyor olması, erişiminin kolay ve ücretsiz oluşu ve yardım videolarının ve belgelerinin bolluğu olduğu düşünülmektedir.

Kendi içerisinde birçok görüntü işleme yöntemi geliştirilmekle birlikte bu yöntemler değişen şartlara göre uyum sağlaması uygulanabilirliği açısından büyük önem arz etmektedir. YZ yöntemleri ise diğer taraftan akıllı karar verme süreçleri sağlaması görüntü işlemeye büyük katkıda bulunmaktadır. YZ yöntemlerinin görüntü birleştirmede kullanılması ile bu yöntemlerin uygulanabilirliği artmış ve cep telefonlarından tutunda oyunlara hatta araçlara kadar büyük bir uygulama sahası bulmuştur. Doğru ya da yanlış mantığı ile net sonuç üretmek çalışan yöntemler yerine yaklaşımlar sağlayabilen ve bu hali ile farklı şartlarda da kullanılabilen teknolojiler üretilebilmektedir.

Geleneksel yöntemlerin yetersiz kalması, sistem iyileştirmek veya optimize etmek, hız, güvenlik, şifreleme gibi birçok gereksinimin karşılanması olarak faydalanılan YZ teknikleri giderek yaygınlaşmaktadır. Bu anlamda, birçok ülkenin ulusal güvenlik ve gelişim stratejisinde YZ ön plana çıkan bir başlık olmaktadır. Siber güvenlik, kriptoloji, veri depolama gibi ulusal çıkarları ve ulusal güvenlik işlemlerini de kapsayan YZ uygulamaları hükümetler tarafından desteklenmektedir. Nitekim bu husus sadece güvenlik perspektifiyle değerlendirilmiyor, bunula birlikte çağın gerisinde kalmamak adına da önemseniyor. Dünyada bu yönde sarf edilen emek azımsanmayacak kadar büyüktür. Bu kitap bölümünde kısıtlı bir alan ile ifade edilmeye çalışılan bu literatür özeti ve gelecek projeksiyonunun bu alanda çalışma yapan ve yapmayı planlayan araştırmacılar için yol gösterici olacağı düşünülmektedir.

KAYNAKLAR

- Atlan, F., & Peñçe, İ. (2021). Yapay Zekâ ve Tıbbi Görüntüleme Teknolojilerine Genel Bakış. *Acta Infologica*. İstanbul Üni. Enformatik Böl. Kalenderhane Mah. 16 Mart Şehitleri Cad. No: 8 Vezneciler Fatih İstanbul: Istanbul University.
- Bouattour, H., Soulié, F. F., & Viennet, E. (1992). Neural Nets for Human Face Recognition. *Proceedings of the International Joint Conference on Neural Networks*, 3, 700–704. Retrieved 8 November 2022 from <https://doi.org/10.1109/IJCNN.1992.227070>
- Boyle, W. S., & Smith, G. E. (1970). Charge coupled semiconductor devices. *The Bell System Technical Journal*, 49(4), 587–593. Retrieved from <https://doi.org/10.1002/j.1538-7305.1970.tb01790.x>
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M. Jr., & Boone, J. M. (2011). *The Essentials Physics Of Medical Imaging*, 1048. Retrieved 19 November 2022 from https://books.google.com/books/about/The_Essential_Physics_of_Medical_Imaging.html?hl=pt-PT&id=tqM8IG3f8bsC
- Canny, J. (1986). A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6), 679–698. Retrieved from <https://doi.org/10.1109/TPAMI.1986.4767851>
- Ceran, M. (n.d.). BANKACILIKTA DİJİTALLEŞME KAPSAMINDA, ÖĞRENEN YAPAY ZEKÂ DESTEĞİYLE SORUNLU KREDİLERİN BELİRLENMESİ. Marmara Üniversitesi Bankacılık Ve Sigortacılık Enstitüsü , İstanbul. Retrieved 19 November 2022 from
- Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 833–851. Retrieved 10 November 2022 from https://doi.org/10.1007/978-3-030-01234-2_49/TABLES/7
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2018). DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834–848. Retrieved from <https://doi.org/10.1109/TPAMI.2017.2699184>
- Coleman, G. B., & Andrews, H. C. (1979). Image Segmentation by Clustering. *Proceedings of the IEEE*, 67(5), 773–785. Retrieved 8 November 2022 from <https://doi.org/10.1109/PROC.1979.11327>
- Das, P. A. K., & Tomar, D. S. (2022). Convolutional neural networks based weapon detection: a comparative study. <https://doi.org/10.1117/12.2622641>, 12084, 351–359. Retrieved 14 November 2022 from <https://doi.org/10.1117/12.2622641>

- Fairbairn, E. M. R., Silvano, M. M., Toledo Filho, R. D., Alves, J. L. D., & Ebecken, N. F. F. (2004). Optimization of mass concrete construction using genetic algorithms. *Computers & Structures*, 82(2–3), 281–299. Retrieved 19 November 2022 from <https://doi.org/10.1016/J.COMPST-RUC.2003.08.008>
- Friedberg, R. M. (1958). A Learning Machine: Part I. *IBM J. Res. Dev.*, 2(1), 2–13. Retrieved from <https://doi.org/10.1147/rd.21.0002>
- Friedberg, R. M., Dunham, B., & North, J. H. (1959). A Learning Machine: Part II. *IBM Journal of Research and Development*, 3(3), 282–287. Retrieved from <https://doi.org/10.1147/rd.33.0282>
- Gao, S. H., Cheng, M. M., Zhao, K., Zhang, X. Y., Yang, M. H., & Torr, P. (2021). Res2Net: A New Multi-Scale Backbone Architecture. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(2), 652–662. Retrieved 10 November 2022 from <https://doi.org/10.1109/TPAMI.2019.2938758>
- Gonzalez, R. C., & Woods, R. E. (2008). *Digital image processing*. Upper Saddle River, N.J.: Prentice Hall. Retrieved from <http://www.amazon.com/Digital-Image-Processing-3rd-Edition/dp/013168728X>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2020). Generative Adversarial Networks. *Commun. ACM*, 63(11), 139–144. Retrieved from <https://doi.org/10.1145/3422622>
- Holland, J. H. (1975). *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. Oxford, England: U Michigan Press.
- KELEŞOĞLU, Ö., EKİNCİ, C. E., & FIRAT, A. (2005). The using of artificial neural networks in insulation computations. *Sigma Journal of Engineering and Natural Sciences*, 23(3), 58-. Retrieved 19 November 2022 from <https://sigma.yildiz.edu.tr/article/1122>
- Khaleel, B. I. (2022). COLOR IMAGE RETRIEVAL BASED ON FUZZY NEURAL NETWORK AND SWARM INTELLIGENCE TECHNIQUES. *IJUM Engineering Journal*, 23(1), 116–128. Retrieved 16 November 2022 from <https://doi.org/10.31436/iiumej.v23i1.1802>
- Kulikov, I., & Bickel, J. (2019). Performance analysis of the vehicle electronic stability control in emergency maneuvers at low-adhesion surfaces. *IOP Conference Series: Materials Science and Engineering*, 534(1). Retrieved 19 November 2022 from <https://doi.org/10.1088/1757-899X/534/1/012009>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4), 12. Retrieved from <https://doi.org/10.1609/aimag.v27i4.1904>

- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. Retrieved from <https://doi.org/10.1007/BF02478259>
- Mcfafuane, M. D. (1972). Digital pictures fifty years ago; Digital pictures fifty years ago. *PROCEEDINGS OF THE IEEE*, 60(7). Retrieved 29 October 2022 from <https://doi.org/10.1109/PROC.1972.8775>
- MüjdatTiryaki, V. (2020). Mamografi görüntülerindeki anormalliklerin yerel ikili örüntü ve varyantları kullanılarak sınıflandırılması. *Journal*, 9(1), 297–305.
- Nedelcu, I. G., Ionita, A. D., Mocanu, S. A., & Saru, D. (2022). UML Class Model Generation of Images Using Neural Networks. *International Conference on Systems, Signals, and Image Processing, 2022-June*. Retrieved 14 November 2022 from <https://doi.org/10.1109/IWSSIP55020.2022.9854486>
- Noble, P. J. W. (1968). Self-scanned silicon image detector arrays. *IEEE Transactions on Electron Devices*, 15(4), 202–209. Retrieved from <https://doi.org/10.1109/T-ED.1968.16167>
- Pananurak, W., Thanok, S., & Parnichkun, M. (2009). Adaptive cruise control for an intelligent vehicle. *2008 IEEE International Conference on Robotics and Biomimetics, ROBIO 2008*, 1794–1799. Retrieved 19 November 2022 from <https://doi.org/10.1109/ROBIO.2009.4913274>
- Preston, K., & Carvalko, J. R. (1972). On Determining Optimum Simple Golay Marking Transformations for Binary Image Processing. *IEEE Transactions on Computers*, C–21(12), 1430–1433. Retrieved 8 November 2022 from <https://doi.org/10.1109/T-C.1972.223519>
- Röntgen, W. C. (1898). Ueber eine neue Art von Strahlen. *Annalen Der Physik*, 300(1), 12–17. Retrieved 19 November 2022 from <https://doi.org/10.1002/ANDP.18983000103>
- Russell Kirsch/NIST. (2022, April). First Digital Image. Retrieved from <https://www.nist.gov/mathematics-statistics/first-digital-image>
- Russell, S. J., & Norvig, P. (2020). *Artificial Intelligence: a modern approach* (4th ed.). Pearson.
- Sarhan, A. M. (2020). Brain Tumor Classification in Magnetic Resonance Images Using Deep Learning and Wavelet Transform. *Journal of Biomedical Science and Engineering*, 13(06), 102–112. Retrieved 19 November 2022 from <https://doi.org/10.4236/JBISE.2020.136010>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2020). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *International Journal of Computer Vision*, 128(2), 336–359. Retrieved from <https://doi.org/10.1007/s11263-019-01228-7>

- Shia, W., & Chen, D. (2020). Abstract P1-02-10: Using deep residual networks for malignant and benign classification of two-dimensional Doppler breast ultrasound imaging. *Cancer Research*, 80(4_Supplement), P1-02-10-P1-02-10. Retrieved from <https://doi.org/10.1158/1538-7445.SAB-CS19-P1-02-10>
- Tan, M., & Le, Q. v. (n.d.). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. Retrieved 9 November 2022 from
- Teknolojileri, Y., Dergisi, E., Seyitömer, M., Külünün, U., Basınç, B., Etkisi, D., ... Bölümü, Y. E. (2016). Seyitömer Uçucu Külünün Betonun Basınç Dayanımına Etkisi Üzerine Bulanık Mantık Yaklaşımı. *Yapı Teknolojileri Elektronik Dergisi*, 1(1), 13–20. Retrieved 19 November 2022 from <https://dergipark.org.tr/tr/pub/yted/issue/22222/238558>
- Thong, N. D., Thin, N. T., & Cong, H. T. (2019). Mango Classification System Uses Image Processing Technology and Artificial Intelligence. *Proceedings of 2019 International Conference on System Science and Engineering, ICSSE 2019*, 45–52. Retrieved 16 November 2022 from <https://doi.org/10.1109/ICSSE.2019.8823119>
- Turk, M. A., & Pentland, A. P. (n.d.). Face recognition using eigenfaces. *Proceedings. 1991 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 586–591. Retrieved 8 November 2022 from <https://doi.org/10.1109/CVPR.1991.139758>
- Vedapradha, R., & Ravi, H. (2018). Application of Artificial Intelligence in Investment Banks. *Review of Economic and Business Studies*, 11(2), 131–136. Retrieved 19 November 2022 from <https://doi.org/10.1515/REBS-2018-0078>
- Waruna, H., Premachandra, H., Jayakody, A., & Kawanaka, H. (2022). Converting high resolution multi-lingual printed document images in to editable text using image processing and artificial intelligence; Converting high resolution multi-lingual printed document images in to editable text using image processing and artificial intelligence. Retrieved 14 November 2022 from <https://doi.org/10.1109/ICIPRob54042.2022.9798739>
- Woo, S., Park, J., Lee, J.-Y., & Kweon, I. S. (2018). CBAM: Convolutional Block Attention Module. In V. Ferrari, M. Hebert, C. Sminchisescu, & Y. Weiss (Eds.), *Computer Vision – ECCV 2018* (pp. 3–19). Cham: Springer International Publishing.
- Yüzgeç, U., Şahin, S., Bölümü, B. M., Şeyh, B., & Üniversitesi, E. (2017). Mobil Otonom Park Etme (MOPA) Uygulaması Geliştirilmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 9(2), 27–34. Retrieved 19 November 2022 from <https://dergipark.org.tr/tr/pub/tbbmd/issue/30339/288029>
- Zhang, Q. ;, Ye, X. ;, Chen, Y., Zhang, Q., Ye, X., & Chen, Y. (2022). Extra Proximal-Gradient Network with Learned Regularization for Image Compressive Sensing Reconstruction. *Journal of Imaging 2022*, Vol. 8, Page 178,

8(7), 178. Retrieved 14 November 2022 from <https://doi.org/10.3390/JI-MAGING8070178>

- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 6848–6856. Retrieved 10 November 2022 from <https://doi.org/10.1109/CVPR.2018.00716>
- Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., & Fu, Y. (2018). Image Super-Resolution Using Very Deep Residual Channel Attention Networks. In V. Ferrari, M. Hebert, C. Sminchisescu, & Y. Weiss (Eds.), *Computer Vision – ECCV 2018* (pp. 294–310). Cham: Springer International Publishing.
- Zou, X., Fu, Y., & Li, X. (2019). Image Feature Recognition of Railway Truck Based on Machine Learning. In *2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)* (pp. 1549–1555). Retrieved from <https://doi.org/10.1109/ITNEC.2019.8729485>