



## TIBBİ CİHAZ SEKTÖRÜNDE KULLANILAN DERİN ÖĞRENME YÖNTEMLERİNE GENEL BAKIŞ

Orhan GÜNDÜZ<sup>1\*</sup>, Cengiz TEPE<sup>2</sup>, Nurettin ŞENYER<sup>3</sup>, Mehmet Serhat ODABAŞ<sup>4</sup>

<sup>1</sup>AYGÜN Cerrahi Aletler, Ar-Ge Bölümü, 55330, Samsun, Türkiye

<sup>2</sup>Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 55139, Samsun, Türkiye

<sup>3</sup>Samsun Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 55080, Samsun, Türkiye

<sup>4</sup>Ondokuz Mayıs Üniversitesi, Lisansüstü Eğitim Enstitüsü, Akıllı Sistemler Mühendisliği Anabilim Dalı, 55139, Samsun, Türkiye

**Özet:** Hayatımızın hemen hemen her yerinde, dünya çapında ilgi odağı haline gelen derin öğrenme temelli bir yapay zeka ürününe veya uygulamasına sıkça rastlamaktayız. Bu durum derin öğrenme yöntemlerinde ve kullanıldığı alanlarda hızlı bir gelişme yaşandığının kanıtıdır. Bu alanlara yüz tanıma, ses tanıma, sürücüsüz araç kullanımı, savunma sanayi, güvenlik sanayi ve daha birçok alan örnek olarak gösterilebilir. Bu çalışmada, derin öğrenme yöntemlerinin tıbbi cihaz sektöründeki kullanıldığı alanlara göre sınıflara ayırdığımız ve ayrıca yapılan yayınların yıllara göre dağılımı incelediğimiz bir derleme çalışması yapılmıştır. Tıbbi cihaz sektöründe derin öğrenmenin kullanıldığı alanlar, sağlık hizmetleri, büyük veri ve giyilebilir teknolojiler, biyomedikal sinyal, görüntü işleme, teşhis ve medikal nesnelere interneti olmak üzere altı adet sınıfa ayrılmıştır. Sonuç olarak, derin öğrenme yöntemlerinin tıbbi cihaz sektöründe kullanımın hız kazanması son yıllarda olmuştur. En çok teşhis ve görüntü işleme alanlarında çalışmalar yapıldığı görülmüştür.

**Anahtar kelimeler:** Derin öğrenme, Tıbbi cihaz, Yapay zeka, Sinirsel ağlar, Medikal nesnelere interneti


### Overview of Deep Learning Methods Used in the Medical Device Industry


**Abstract:** Almost everywhere in our lives, we often come across a deep learning based artificial intelligence product or application that has become the center of attraction worldwide. This is evidence of a quick development in deep learning methods and the areas where they are used. Face detection, voice recognition, self-driving, defense industry, security industry and many other areas can be shown as samples. In this study, a literature review has been made that we divided into classes according to the fields in which deep learning methods are used in the medical device industry and also where we examine the distribution of the articles by years. It is divided into six classes such as healthcare, big data and wearable technologies, biomedical signal, image processing, diagnosis and internet of medical things. As a result, the use of deep learning methods in the medical device industry has gained speed in recent years and also most studies have been done on diagnosis and image processing.


**Keywords:** Deep learning, Medical device, Artificial intelligence, Neural networks, Internet of medical things


\*Sorumlu yazar (Corresponding author): AYGÜN Cerrahi Aletler, Ar-Ge Bölümü, 55330, Samsun, Türkiye

E mail: orhan55gunduz@gmail.com (O. GÜNDÜZ)

Orhan GÜNDÜZ  <https://orcid.org/0000-0002-8132-8301>

Cengiz TEPE  <https://orcid.org/0000-0003-4065-5207>

Nurettin ŞENYER  <https://orcid.org/0000-0001-8668-5263>

Mehmet Serhat ODABAŞ  <https://orcid.org/0000-0002-1863-7566>

**Gönderi:** 12 Ocak 2021

**Kabul:** 02 Mart 2021

**Yayınlanma:** 01 Nisan 2021

**Received:** January 12, 2021

**Accepted:** March 02, 2021

**Published:** April 01, 2021

**Cite as:** Gündüz O, Tepe C, Şenyener N, Odabaş MS. 2021. Overview of deep learning methods used in the medical device industry. BJS Eng Sci, 4(2): 68-74.

### 1. Giriş

Dünya genelinde sürekli artan nüfus miktarıyla birlikte, insanların sağlık sorunları da artmaktadır. Bu durum tıbbi cihaz kullanımının sürekli artan bir ihtiyaç olduğunu göstermektedir. Ayrıca insanlar Covid-19 pandemisi gibi daha önce insanlarda görülmeyen birçok virüs/mikroorganizmalar ile karşılaşmıştır ve karşılaşmaya devam edeceği öngörülmektedir. Covid-19 pandemi tedavisinde kullanılan solunum (ventilatör) cihazları da, tıbbi cihazların bu gibi salgınlarda insan sağlığı için ne kadar önemli bir rol oynadığını göstermektedir.

Tıbbi cihaz pazar büyüklüğü Türkiye için 2,6 milyar dolardır. Bu miktarın %85'lik kısmını ithal ürünler ve %15'lik kısmını yerli üretim tıbbi cihazları

oluşturmaktadır. Türkiye bu tıbbi cihaz pazarındaki %1'lik kısmına sahiptir (Özlü, 2020). Global tıbbi cihaz pazar büyüklüğü 2018'de 425,5 milyar dolar olarak hesaplanmış ve 2025'e kadar %5,4'lük büyüme ile 612,7 milyar dolara ulaşması beklenmektedir (Fortune Business Insights, 2019).

Tıbbi cihazların yüksek teknolojik oranları sürekli yükselmektedir. Önceden tedavi edilmesi zor yada imkansız olarak görülen hastalıkların, bu gelişmeler ile birlikte tedavisi mümkün olmaktadır. Bu teknolojik gelişimin en önemli faktörlerinden biri de derin öğrenmenin tıbbi cihazlarda uygulanmasıdır. Derin öğrenme, genelde çok katmanlı sinir ağ yapısı ile uygulanan bir makine öğrenimi biçimidir ve veri sınıflandırılması veya yeni hastalık fenotiplemesi gibi uygulamalarda tıpta umut veren bir makine öğrenim




dalıdır (Krittanawong ve ark., 2019).

Bu çalışmamızda tıbbi cihazlara yönelik son yıllarda yapılan derin öğrenme çalışmaları incelenmiştir. Çalışmalar derin öğrenme yöntemlerini kullandığı alanlara göre sınıflara ayrılarak incelenmiştir ve ayrıca yapılan çalışmaların yıllara göre dağılımı gösterilmiştir.

## 2. Yöntem

Tıp ile ilgili en büyük veri tabanı olan PubMed üzerinden “(deep learning) and (medical device)” anahtar kelimeleri ile yapılan taramada toplam 620 adet yayın yapıldığı görülmüştür. En büyük sıçrama 2018 yılında 128 yayın ile yapılmıştır. Sonrasında 2019’da 200 ve 2020’de ise 155 yayın yapılmıştır. Şekil 1’de yayınların yıllara göre dağılımı gösterilmiştir.

### Yayın sayısı




Şekil 1. PubMed’de derin öğrenme ve tıbbi cihaz anahtar kelimeleriyle yapılan arama sonucu.

Aynı kaynakta “(deep learning) AND (device)” anahtar kelimesiyle arama yapıldığında 1,396 yayın çıkmaktadır. Aşağıdaki grafik incelendiğinde yine en büyük sıçramayı 2018 yılında, 258 yayın ile yapmıştır (Şekil 2).

Sonrasında 2019’da 417 ve 2020’de ise 529 yayın yapılmıştır. Her iki grafikten de anlaşıldığı gibi tıbbi cihaz sektöründe derin öğrenme uygulamaları hızla artmaktadır.

### Yayın sayısı



Şekil 2. PubMed’de derin öğrenme ve cihaz anahtar kelimeleriyle yapılan arama sonucu.


Özellikle Türkiye için popüler dergi yayın adresi olan dergipark üzerinden (“derin öğrenme” OR “deep learning”) (“medical device” OR “tıbbi cihaz”) anahtar

kelimeleriyle yapılmıştır. Burada Türkçe kaynaklar olduğu için kelimeler Türkçe anlamları ile birlikte tarama yapılmıştır ve 424 yayın bulunmuştur. 2017 ve 2018


yıllarında yayın sayısı ivmelenme kazanarak 2020 yılında 174 adet yayına ulaşmıştır (Şekil 3). Pubmed üzerinden yapılan derin öğrenme taramaları, kullanıldıkları yerlere göre 6 farklı sınıfa ayrılmıştır. Pubmed global bir veri tabanı olduğu için, her alana göre detaylı taramalar bu veri tabanı üzerinden gerçekleştirilmiştir. Sonuç olarak sağlık hizmetleri alanında 95, büyük veri ve giyilebilir teknolojiler alanında 190, biyomedikal sinyal alanında 8, görüntü

işleme alanında 282, teşhis alanında 714 ve son olarak medikal nesnelerin İnterneti alanında 6 adet yayın bulunmaktadır (Şekil 4). Bu alanlardaki yayınlar toplandığında 1,295 adet yayın elde edilmektedir. Şekil 2'deki tarama sayısı ile arasındaki 101 yayın bulunmaktadır. Aşağıdaki grafikte yayınların dağılımı gösterilmektedir ve görüldüğü gibi bu pastanın en büyük dilimine %55,1 oranla, derin öğrenme yöntemlerinin teşhis amaçlı kullanılması sahiptir.

### Yayın sayısı



Şekil 3. Dergipartk'ta derin öğrenme ve tıbbi cihaz anahtar kelimeleriyle yapılan arama sonucu.



Şekil 4. Sınıflara göre yayın dağılımı.

### 3. Sonuç ve Öneriler

Bulunan yayın sayısı içeriğine göre 29 adet yayına düşürülmüştür. Bu yayınlar ana teması üzerinde incelenerek kategorize edilmiştir. Tıbbi cihaz sektöründe derin öğrenmenin kullanıldığı alanlardan sağlık hizmetleriyle ilgili 7, büyük veri ve giyilebilir teknolojiler ile ilgili 2, biyomedikal sinyal ile ilgili 5, görüntü işleme ile ilgili 6, teşhis ile ilgili 5 ve medikal nesnelerin İnterneti ile ilgili 4 adet yayın incelenmiştir.

#### 3.1 Sağlık Hizmetleri

Sağlık hizmetleri "Healthcare" PubMed üzerinden yapılan taramalarda yayın sayısı olarak %7,3'lük paya sahiptir.

Sağlık hizmetleri kaynakları sınırlı olsa da, akıllı telefon cihazları dünya çapında giderek daha fazla kullanılabilir hale geliyor. Sağlık hizmetlerini iyileştirmek için derin öğrenme uygulamalarının refah ve ekonomi üzerinde potansiyel olarak derin bir etkisi vardır. Deng yaptığı çalışmada TensorFlow, MXNet, Mobile AI Compute Engine (MACE) ve Paddle-mobil derin öğrenme platformunun endüstriyel düzeyi irdelenmiştir (Deng, 2019). Bir başka çalışmada Amota ve arkadaşları yaptıkları çalışmada derin öğrenme ve büyük veri yapısının kullanıldığı çevrimiçi medikal sağlık öneri sistemini tanıtmışlardır (Amato ve ark., 2019). Ngiam ve

Khor yaptıkları derleme çalışmasında sağlık hizmetlerinde kullanılan makine öğrenimi yöntemlerine örnekler sunmuşlardır (Ngiam ve Khor, 2019). Estava ve arkadaşları yaptıkları çalışmada, sağlık hizmetleri için derin öğrenme, bilgisayarlı görü, doğal dil işleme, pekiştirmeli öğrenme ve genelleştirilmiş yöntemleri incelemişlerdir (Esteva ve ark., 2019).

Ali ve arkadaşları kolektif derin öğrenme yöntemi kullanarak ve öznelik füzyonun yaklaşımından yararlanarak kalp hastalığının tahmini için akıllı bir sağlık sistemi geliştirmişlerdir. Öznelik füzyon yöntemi, sensörlerden ve elektronik tıbbi kayıtlardan çıkarılan özellikleri birleştirilerek değerli sağlık verisi üretmiştir. Bu sistem diğer sistemlerden daha yüksek doğruluk oranı (%98,5) sağlamıştır (Ali ve ark., 2020). Yaptıkları diğer bir çalışmada sağlık hizmetlerinde insan vücudu için yaygın ve tehlikeli iki rahatsız olan diyabet ve anormal kan basıncı parametrelerini kullanmışlardır. Bu parametreler aynı zamanda kalp-damar hastalık riskini artırmaktadır. Ali ve arkadaşları, kronik hastalar için gelişmiş teknolojileri, veri madenciliğini, bulut sunucuları, büyük verileri, ontolojiler ve derin öğrenmeyi entegre eden yeni bir sağlık izleme sistemi geliştirmişlerdir (Ali ve ark., 2021).

Miotto ve arkadaşları, sağlık hizmetleri alanını geliştirmek için derin öğrenme teknolojilerinin uygulanmasına ilişkin son zamanlarda yayınlanan literatürü derlemişlerdir. Bu çalışma sonucunda, derin öğrenme yaklaşımlarının büyük biyomedikal verilerin gelişkin insan sağlık sistemine katkı sağlamada bir araç olabileceğini göstermiştir (Mitto ve ark., 2017).

### 3.2 Büyük Veri ve Giyilebilir Teknolojiler

Sensör teknolojisinin gelişimi, özellikle giyilebilir teknolojisini ve boyutlarını önemli ölçüde değiştirmiştir. Kwon ve arkadaşları yaptıkları çalışmada yüzük tipli bir giyilebilir cihaz ile PPG sinyallerini elektrokardiyografiye bağlı kalmadan, derin öğrenme analizi yardımıyla atriyal fibrilasyonu doğru teşhis etmiştir (Kwon ve ark., 2020). Başka bir çalışmada Haghi ve arkadaşları yaptıkları çalışmada, giyilebilir sağlık bakım cihazlarını hem bilimsel makalelerde hem de ticari çabalarda incelemiştir. Giyilebilir cihazlar, gelişmiş teknolojinin yardımıyla büyük ölçüde geliştirilmiştir ve uzun vadeli sağlık izleme sistemleri için güvenilir araçlar olarak kabul edilmektedir. Bunlar çevredeki çok çeşitli sağlık izleme göstergelerinin, yaşamsal belirtilerin ve form durumunun gözlemlenmesinde uygulanır. Giyilebilir cihazlar artık çok çeşitli sağlık hizmetleri gözlemleri için kullanılmaktadır. Veri toplamada gerekli olan en önemli unsurlardan biri sensördür. Son yıllarda, yarı iletken teknolojisindeki gelişmelerle birlikte, sensörler gerçeğe çok daha yakın bir şekilde bir dizi parametreyi araştırmamıza imkan sunmaktadır (Haghi ve ark., 2017).

### 3.3 Biyomedikal Sinyal

Tıbbi cihaz sektöründeki derin öğrenme uygulamalarında bu alanda yapılan çalışma sayısının oranı %0,6 dır. Bu durum bu alanın derin öğrenme uygulamalarının daha yeni yeni gelişmeye başlamış

olmasından kaynaklı olabilir. İnsan vücudundaki sinyaller analiz edilerek incelenmiştir. Yapılan bir uygulamada Craik ve arkadaşları yaptıkları derlemede, görev türü, EEG ön işleme yöntemleri, girdi türü, derin öğrenme mimarisi açısından irdelemişlerdir (Craik ve ark., 2019). Diğer bir yapılan çalışmada kalp atış hızı (HR) ve oksijen satürasyonu(SpO<sub>2</sub>) sinyalleri kullanılarak uykuda yada uyanıkken, uyku aşamalarını sınıflandırılmasında DNN/RNN'nin özel bir türü olan GRU kullanılmıştır (Casal ve ark., 2021).

Alhussein ve arkadaşları yaptıkları çalışmada, derin öğrenmeye dayalı otomatik bir elektroensefalogram (EEG) patoloji tespit sistemi önerilmiştir. Çeşitli patolojiler beyin sinyallerini etkileyebilir. Bu nedenle, EEG sinyalleri şeklinde yakalanan beyin sinyalleri, bir kişinin patolojiden muzdarip olup olmadığını gösterebilir. Evrişimli bir sinir ağı (CNN) kullanılmış ve çok katmanlı bir algılayıcıya dayalı bir füzyon stratejisi de araştırılmıştır. Derin CNN modeli ve füzyonu ile önerilen sistem % 87,96 doğruluk elde etmiştir (Alhussein ve ark., 2019). Yapılan başka bir çalışmada Dose ve arkadaşları yaptıkları çalışmada, inme rehabilitasyon stratejilerini iyileştirmek için kullanılacak bir elektroensefalogram (EEG) tabanlı Motor Görüntü (MI) Beyin-Bilgisayar Arayüzü (BCI) sistemi için Derin Öğrenme (DL) yaklaşımı uygulanmıştır (Dose ve ark., 2018). EEG sinyalleri üzerine yapılan başka bir çalışmada evrişimli sinir ağı (CNN) kullanılarak Parkinson hastalığı (PH) için otomatik bir tespit sistemi önerilmiştir. PH, beyindeki motor fonksiyonun kademeli olarak bozulması ile ilgilidir. PD hastalığı beyin anormallığı ile ilgili olduğundan, elektroensefalogram (EEG) sinyalleri genellikle erken teşhis için düşünülür. Yirmi PD ve yirmi normal deneğin EEG sinyallerini kullanılmıştır. On üç katmanlı bir CNN mimarisi uygulanmıştır. Geliştirilen model% 88,25 doğruluk,% 84,71 duyarlılık ve% 91,77 özgüllük performans değerleri elde edilmiştir. Geliştirilen sınıflandırma modeli, klinik kullanım kurulumundan önce geniş popülasyonda kullanılmaya hazır duruma getirilmiştir (Oh ve ark., 2018).

### 3.4 Görüntü İşleme

Derin öğrenme yöntemlerininin kullanıldığı %21,8 ile ikinci en büyük yayın oranına sahiptir. Tıbbi görüntüleme yapay zeka (AI), potansiyel olarak yıkıcı bir teknolojidir. Radyomik, yapay sinir ağları, makine öğrenimi ve derin öğrenmenin ilkeleri ve uygulamalarının anlaşılması, etik ve düzenleyici gereksinimleri barındıran tasarım çözümlerini, örnek ve sonuçları, kaliteyi ve verimliliği artıran yapay zeka tabanlı algoritmalar oluşturmak için temel sunar (Currie ve ark., 2019). Diğer bir uygulamada rotator manşet kas yırtılması ortopedik cerrahide en çok operasyon gerektiren sebeplerden biridir. Bu durumu Kim ve arkadaşları yaptıkları çalışmada evrişimsel sinir ağları algoritması kullanarak, fossa ve kas bölgesini kantitatif olarak tespit etmek için supraspinöz fossa daki supraspinatus kasının işgal oranının ölçmüşlerdir (Kim ve

ark., 2019). Yine bir diğer çalışmada Balu ve arkadaşları biyoprotez kalp kapakçık takılan hastaların, kalp kapakçıklarının deformasyonunun tahmini için sonlu elemanlar analizi tabanlı derin öğrenme yöntemini kullanmışlardır (Balu ve ark., 2019).

Yi ve arkadaşlarının yaptıkları çalışmanın amacı, total diz artroplastisinin varlığının veya yokluğunun belirlenmesi ve toplam diz artroplastisi ile tek kompartmanlı diz artroplastisinin sınıflandırılması için bir derin öğrenme sisteminin performansını geliştirmek ve test etmektir (Yi ve ark., 2020). Bir başka çalışmada, el ve bileği otomatik olarak algılamak ve bölümlere ayırmak, görüntüleri bir ön işleme motoru kullanarak standartlaştırmak, ince ayarlı bir CNN ile otomatik kemik yaş tahmini gerçekleştirmek için tam otomatik bir derin öğrenme sistemi oluşturmuşlardır (Lee ve ark., 2017). Ni ve arkadaşları yaptıkları çalışmada, radyografik görüntülerde 14 farklı IVC filtresinin otomatik olarak tanımlanması için derin öğrenme CNN sınıflandırma modeli geliştirmiş ve değerlendirmiştir. Sonuç olarak, radyografilerde farklı IVC filtre türlerinin otomatik olarak doğru şekilde tanımlanması için derin öğrenme CNN sınıflandırma modelinin kullanılmasının uygulanabilirliğini göstermiştir (Ni ve ark., 2020).

### 3.5 Teşhis

Yapılan makale incelemelerimizde derin öğrenme yöntemlerinin en çok hastalığın/rahatsızlığın teşhisi amacıyla kullanıldığı görülmektedir. Fauw ve arkadaşları yaptıkları çalışmada, 14,884 adet heterojen üç boyutlu optik koherens tomografi taramaları eğitildikten sonra, görmeyi tehdit eden bir dizi retina hastalığı konusunda uzmanların tavsiyesine ulaşan veya aşan bir performans elde etmişlerdir (De Fauw ve ark., 2018). Diğer bir çalışmada Ebigo ve arkadaşları, ResNet mimarisi ile derin evrişimli sinir ağı(CNN) temelinde bir bilgisayar destekli teşhis(CAD) sistemini eğitmek ve test etmek için iki adet veritabanı kullanılmıştır. Buradaki amaç Barrett özofagus (BÖ) hastalığı ve erken adenokarsinom değerlendirmektir. Sonuç olarak özellikle Barrett özofagus hastalığı teşhisinde yüksek doğruluk elde etmişlerdir ve tümör bölgesinin kaba bir segmentasyonunu otomatik olarak gösterimi yapmışlardır (Ebigo ve ark., 2018).

Fourcade ve Khonsari "Tıbbi görüntü analizinde derin öğrenme: Doktorlar için üçüncü bir göz" adlı yaptıkları derleme çalışmalarında, "Görüntü tanıma için derin öğrenme algoritmaları tıpta görsel teşhisi iyileştirebilir mi?" sorusunu güncel literatürde arayıp taramışlardır. Doktorlar için CNN'ler tam bir çözüm değildir, ancak doktorların rutin görevlerinin optimize edilmesine katkıda bulunacak ve pratiklerinde potansiyel olumlu bir etkiye sahip olacaktır sonucuna varmışlardır (Fourcade ve Khonsari, 2019). Krittanawong ve arkadaşları kardiyovasküler tıpta derin öğrenme uygulamaları ile ilgili yaptıkları derleme çalışmasında derin öğrenme yöntemlerinin iskemik ve yapısal kalp hastalıklarının görüntüleme, kalp yetmezliği tahmini ve kalp ritim bozukluğu(Aritmi) tespiti ve fenotiplemesinde

kullanıldığını göstermişlerdir (Krittanawong ve ark., 2019). Kim ve ark. (2021) "PAIP 2019: Karaciğer kanseri segmentasyonu zorluğu" adlı yaptıkları çalışmada, daha fazla erişebilirlik sağlayacak, yüksek kaliteli patoloji öğrenme veri seti oluşturmaktır.

### 3.6 Medikal Nesnelerin İnterneti

Yapılan incelemelerde bu alanı kapsayan yayın miktarı diğerlerine göre daha az olsada, sensör teknolojisinin gelişmesiyle birlikte nesnelerin interneti (IoT) trendi tıbbi cihazları da etkiliyor. IOT alanının gelişip daha yaygın hale gelmesiyle birlikte medikal cihazların interneti(IoMT) alanında yapılan derin öğrenme çalışmalarının hız kazanağı anlaşılmaktadır. Ushimaru ve arkadaşlarının çalışması, IoT'nin ameliyat için kullanılmasıyla, cerrahi prosedürü görselleştirilebilir. Bu görselleştirme ve devamı niteliğindeki analizler yoluyla, cerrahi cihazların optimum kullanımı, elektrokoterin uygun kullanımı ve cerrahi prosedürlerin standardizasyonu gibi cerrahi güvenliği artıracak çalışmalar sağlanabilir olduğunu göstermiştir (Ushimaru ve ark., 2019). Başka bir çalışmada, tıbbi görüntüleri şifrelemek ve görüntülerin şifrelerini çözmek için derin öğrenme tekniklerini kullanmışlardır (Ding ve ark., 2020).

Zeka ve Derin Öğrenmeyi Kullanan Tıbbi Nesnelerin İnternetinde ve Büyük Veri Hizmetlerinde Belirsizlik" konulu çalışmada Al Turjman ve arkadaşları ağ topolojisi, iletim / alım enerjisi, düğüm yükü ve gücü ve hesaplama kapasitesi gibi dinamik belirsizlik faktörlerini göz önünde bulundurarak bulut üzerinden veri sunmanın fiyatlandırma modelini ele almışlardır (Al-Turjman ve ark., 2019). Diğer bir çalışmada, küresel zorluğun üstesinden gelmek için kavramsal radyo (CR) tabanlı IoT'nin tıbbi alana özgü olan ve Bilişsel Tıbbi Şeylerin İnterneti (CIoMT) olarak adlandırılan yeni uygulaması incelenmiştir. Sonuç olarak CIoMT, virüsü başkalarına yaymadan hızlı teşhis, dinamik izleme ve izleme, daha iyi tedavi ve kontrol için umut verici bir teknoloji olduğu gösterilmiştir (Swayamsiddha ve Mohanty, 2020).

### 3.7 Tartışma

Bu çalışmada tıbbi cihaz sektöründeki derin öğrenme yöntemlerini kullanılan yayınlar incelenmiş ve kullanıldığı alanlara göre bölümlere ayrılmıştır. İlgili alanlarda çıkarılan yayın sayısına göre, derin öğrenme yöntemlerinin en çok ve en az kullanıldığı alanlar belirtilmiştir. Teşhis, derin öğrenme çalışmalarının en sık kullanıldığı ve en çok yayın çıkarılan alan olmuştur. İkinci sırada derin öğrenme yöntemlerinde görüntü işleme üzerine yapılan çalışmalar yer almaktadır. Bu çalışmalar en çok radyoloji alanında nesne tespiti, nesne segmentasyonu ve nesne sınıflandırması ile ilgilidir. En son sırada medikal nesnelerin interneti alanı yer almaktadır.

Yayınlar incelendiğinde derin öğrenme yöntemlerinin tıbbi cihaz sektöründe artan oranda bir ilgiyle karşılaştığı görülmektedir. Derin öğrenme birçok alanda olduğu gibi tıbbi cihaz sektöründe de yıkıcı/çığır açıcı etki bırakmaya devam edeceği görülmektedir. Cihazlar içerisinde



gömülecek derin öğrenme algoritmalar doktorların mesleğinin yerine geçmekten ziyade bir karar destek görevi üstlenecektir. Çıkarılan sonuca göre medikal cihazların interneti alanın en son sırada olması, bu alanda derin öğrenme yöntemlerinin daha yeni yaygınlaştığı sonucuna varılabilir.

## Katkı Oranı Beyanı

Bütün yazarlar makaleye aynı oranda katkı sağlamış olup tüm yazarlar makaleyi incelemiş ve onaylamıştır.

## Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

## Kaynaklar

- Alhoussein M, Muhammad G, Hossain MS. 2019. EEG Pathology detection based on deep learning. *IEEE Access*, 7, 27781–27788. <https://doi.org/10.1109/access.2019.2901672>.
- Ali F, El-Sappagh S, Islam SMR, Ali A, Attique M, Imran M, Kwak KS. 2021. An intelligent healthcare monitoring framework using wearable sensors and social networking data. *Future Generat Comput Systems*, 114, 23–43.
- Ali F, El-Sappagh S, Islam SMR, Kwak D, Ali A, Imran M, Kwak KS. 2020. A smart healthcare monitoring system for heart disease prediction based on ensemble deep learning and feature fusion. *Inform Fusion*, 63: 208–222. <https://doi.org/10.1016/j.inffus.2020.06.008>.
- Al-Turjman F, Zahmatkesh H, Mostarda L. 2019. Quantifying uncertainty in internet of medical things and big-data services using intelligence and deep learning. *IEEE Access*, 7: 115749–115759.
- Amato F, Marrone S, Moscato V, Piantadosi G, Picariello A, Sansone C. 2019. HOLMeS: eHealth in the big data and deep learning era. *Inform*, 10(2): 34. <https://doi.org/10.3390/info10020034>.
- Balu A, Nallagonda S, Xu F, Krishnamurthy A, Hsu M, Sarkar S. 2019. A deep learning framework for design and analysis of surgical bioprosthetic heart valves. *Sci Reports*, 9: 18560. <https://doi.org/10.1038/s41598-019-54707-9>.
- Casal R, Di Persia LE, Schlotthauer G. 2021. Classifying sleep-wake stages through recurrent neural networks using pulse oximetry signals. *Biomed Signal Proces Control*, 63, 102195. <https://doi.org/10.1016/j.bspc.2020.102195>.
- Craik A, He Y, Contreras-Vidal JL. 2019. Deep learning for electroencephalogram (EEG classification tasks: a review. *J Neural Engin*, 16(3): 031001. <https://doi.org/10.1088/1741-2552/ab0ab5>.
- Currie G, Hawk KE, Rohren E, Vial A, Klein R. 2019. Machine learning and deep learning in medical imaging: intelligent imaging. *J Med Imag Radiat Sci*, 50(4): 477–487. <https://doi.org/10.1016/j.jmir.2019.09.005>.
- De Fauw J, Ledsam JR, Romera-Paredes B, Nikolov S, Tomasev N, Blackwell S, Askham H, Glorot X, O'Donoghue B, Visentin D, van den Driessche G, Lakshminarayanan B, Meyer C, Mackinder F, Bouton S, Ayoub K, Chopra R, King D, Karthikesalingam A, Ronneberger O. 2018. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nature Med*, 24(9): 1342–1350. <https://doi.org/10.1038/s41591-018-0107-6>
- Deng Y. 2019. Deep learning on mobile devices: a review. *Mobile Multimedia/Image Proc, Sec, Applicat*, 52–66. <https://doi.org/10.1117/12.2518469>.
- Ding Y, Wu G, Chen D, Zhang N, Gong L, Cao M, Qin Z. 2020. DeepEDN: A Deep Learning-based Image Encryption and Decryption Network for Internet of Medical Things. *IEEE Internet Things J*, 8(3): 1504–1518.
- Dose H, Møller JS, Iversen HK, Puthusserypady S. 2018. An end-to-end deep learning approach to MI-EEG signal classification for BCIs. *Expert Systems with Applicat*, 114: 532–542. <https://doi.org/10.1016/j.eswa.2018.08.031>.
- Ebigbo A, Mendel R, Probst A, Manzeneder J, Souza Jr LA, Papa JP, Palm C, Messmann H. 2018. Computer-aided diagnosis using deep learning in the evaluation of early oesophageal adenocarcinoma. *Gut*, 68(7): 1143–1145. <https://doi.org/10.1136/gutjnl-2018-317573>
- Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, Cui, C, Corrado, G, Thrun, S, Dean, J. 2019. A guide to deep learning in healthcare. *Nature Med*, 25(1): 24–29. <https://doi.org/10.1038/s41591-018-0316-z>.
- Fortune Business Insights. 2019. Medical devices market size, share, trends analysis report 2018-2025. URL: <https://www.fortunebusinessinsights.com/industry-reports/medical-devices-market-100085> (erişim tarihi: 27 Kasım 2020).
- Fourcade A, Khonsari R H. 2019. Deep learning in medical image analysis: A third eye for doctors. *J Stomatol Oral Maxillofacial Surgery*, 120(4): 279–288. <https://doi.org/10.1016/j.jormas.2019.06.002>.
- Haghi M, Thurow K, Stoll R. 2017. Wearable Devices in Medical Internet of Things: Scientific Research and Commercially Available Devices. *Healthcare Inform Res*, 23(1): 4. <https://doi.org/10.4258/hir.2017.23.1.4>.
- Kim JY, Ro K, You S, Nam BR, Yook S, Park HS, Yoo JC, Park E, Cho K, Cho BH, Kim IY. 2019. Development of an automatic muscle atrophy measuring algorithm to calculate the ratio of supraspinatus in supraspinous fossa using deep learning. *Comput Methods Prog Biomed*, 182: 105063. <https://doi.org/10.1016/j.cmpb.2019.105063>.
- Kim YJ, Jang H, Lee K, Park S, Min SG, Hong C, Park JH, Lee K, Kim, J, Hong W, Jung H, Liu Y, Rajkumar H, Khened M, Krishnamurthi G, Yang S, Wang X, Han CH, Kwak JT, Choi J. 2021. PAIP 2019: Liver cancer segmentation challenge. *Med Image Analysis*, 67: 101854.
- Krittanawong C, Johnson KW, Rosenson RS, Wang Z, Aydar M, Baber U, Min JK, Tang W, Halperin JL, Narayan SM. 2019. Deep learning for cardiovascular medicine: a practical primer. *European Heart J*, 40(25): 2058–2073. <https://doi.org/10.1093/eurheartj/ehz056>.
- Kwon S, Hong J, Choi EK, Lee B, Baik C, Lee E, Jeong ER, Koo BK, Oh S, Yi Y. 2020. Detection of atrial fibrillation using a ring-type wearable device (cardiotracker and deep learning analysis of photoplethysmography signals: prospective observational proof-of-concept study. *J Med Internet Res*, 22(5): e16443. <https://doi.org/10.2196/16443>.
- Lee H, Tajmir S, Lee J, Zissen M, Yeshiwas BA, Alkasab TK, Choy G, Do S. 2017. Fully automated deep learning system for bone age assessment. *J Digit Imag*, 30(4): 427–441. <https://doi.org/10.1007/s10278-017-9955-8>
- Miotto R, Wang F, Wang S, Jiang X, Dudley JT. 2017. Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformat*, 19(6): 1236–1246. <https://doi.org/10.1093/bib/bbx044>.
- Ngiam KY, Khor IW. 2019. Big data and machine learning algorithms for health-care delivery. *The Lancet Oncol*, 20(5): e262–e273.
- Ni JC, Shpanskaya K, Han M, Lee EH, Do BH, Kuo WT, Yeom KW, Wang DS. 2020. Deep learning for automated classification of

- inferior vena cava filter types on radiographs. *J Vascul Intervent Radiol*, 31(1): 66-73.
- Oh SL, Hagiwara Y, Raghavendra U, Yuvaraj R, Arunkumar N, Murugappan M, Acharya UR. 2018. A deep learning approach for Parkinson's disease diagnosis from EEG signals. *Neural Comput Applicat*, 32(15): 10927-10933.
- Özlu CÇ. 2020. Ülkemizde tıbbi cihaz sektörü hangi yönde değişiyor? URL: <https://sesanltd.com.tr/ulkemizde-tibbi-cihaz-sektoru-hangi-yonde-degisiyor> (erişim tarihi: 27 Kasım 2020).
- Swayamsiddha S, Mohanty C. 2020. Application of cognitive Internet of Medical Things for COVID-19 pandemic. *Diabetes Metab Syndr*, 14(5): 911-915.
- Ushimaru Y, Takahashi T, Souma Y, Yanagimoto Y, Nagase H, Tanaka K, Miyazaki Y, Makino T, Kurokawa Y, Yamasaki M, Mori M, Doki Y, Nakajima K. 2019. Innovation in surgery/operating room driven by Internet of Things on medical devices. *Surgical Endoscopy*, 33(10): 3469-3477. <https://doi.org/10.1007/s00464-018-06651-4>
- Yi PH, Wei J, Kim TK, Sair HI, Hui FK, Hager GD, Fritz J, Oni JK. 2020. Automated detection classification of knee arthroplasty using deep learning. *The Knee*, 27(2): 535-542. <https://doi.org/10.1016/j.knee.2019.11.020>