

## Yapay Zeka ve Diş Hekimliği

Büşra Yüçetürk<sup>1</sup>

### Özet

Zekâ, ilişki kurma, problem çözme ve çevreye uyum sağlama gibi bilişsel yetileri kapsamaktadır. Yapay zekâ (YZ) ise, bu yetileri makinelerde taklit etmeyi amaçlayan sistemler bütünüdür. YZ, makine öğrenmesi, yapay sinir ağları ve derin öğrenme gibi alt alanlarla gelişmiştir. Makine öğrenmesi, sistemlerin verilerden öğrenerek karar verebilmesini sağlarken; yapay sinir ağları, insan beynindeki nöronları taklit eden katmanlı yapılarla çalışır. Bu yapılarının derin ve çok katmanlı hâli olan derin öğrenme ise, özellikle görüntü, ses ve metin gibi karmaşık veriler üzerinde yüksek başarı gösteren bir modelleme yöntemidir.

Diş hekimliğinde yapay zekâ, hasta kayıt yönetimi, teşhis destek sistemleri ve görüntü analizleri gibi alanlarda önemli gelişmeler sağlamıştır. Panoramik, periapikal ve konik ışınli bilgisayarlı tomografi (CBCT) görüntülerinde dişlerin otomatik tespiti ve sınıflandırılması, tedavi planlamasında yüksek doğruluk sunmaktadır. Ayrıca diş yaşının belirlenmesi, çürük ve patoloji tespiti, sefalometrik analiz ve ağız hastalıklarının erken teşhisinde de yapay zekâ destekli sistemler başarıyla kullanılmaktadır. Bu gelişmeler, klinik verimliliği artırmakta ve hataları azaltarak hasta bakım kalitesini iyileştirmektedir.

### 1.Yapay Zeka Nedir?


Zekâ; nesneler ve kavramlar arasında ilişki kurabilme, karar verebilme, düşünerek çözüm geliştirme, yargıda bulunma ve sonuç çıkarabilme kabiliyeti olarak nitelendirilmektedir.. Aynı zamanda, öğrenme, anlama, çevreye uyum sağlama ve analiz yapabilme gibi becerileri de kapsamaktadır. Yapay zekâ ise, veri setleri aracılığıyla problemlere çözüm üretebilen, öğrenebilen makinelerden meydana gelen bir sistemler bütünüdür (1).

1 Uzman Diş Hekimi, Gaziantep Üniversitesi Diş Hekimliği Fakültesi, busrayctrk@outlook.com ORCID ID: 0000-0003-2686-1450

Yapay zekâ alanındaki araştırmalar, İkinci Dünya Savaşı döneminde önem kazanmaya başlamıştır. Yapay zekânın kurucularından kabul edilen Alan Turing, 1947’de verdiği konferansta bilgisayar programlarıyla akıllı makineler üretilebileceğini dile getirmiştir. 1950 yılında yayımladığı “Computing Machinery and Intelligence” adlı makalesinde “Makineler düşünebilir mi?” sorusunu ortaya atmış ve bu bağlamda günümüzde “Turing Testi” olarak bilinen “Taklit Oyunu”nu önermiştir. Turing adı verilen bu zeka testine göre, bilgisayarla insan arasındaki etkileşimde, insan ve bilgisayar farkı ayırt edilemiyorsa o bilgisayarın insan kadar akıllı sayılması gerektiğini kabul edilmektedir (2).

1950’lerde ilk kez ortaya atılan yapay zeka teriminin üzerine 1980’lerde makine öğrenimi terimi ve sonrasında derin öğrenme ve yapay sinir ağları (YSA) terimleri ortaya çıkmıştır (3).

Yapay karmaşık nöral bağlantı ağlarından oluşan sayısal metotlar bütününe yapay sinir ağları denilmektedir. Derin öğrenme ise karmaşık veri setlerini öğrenmek ve bu veri setlerinden çıkarım yapmak için çok daha fazla alt grupla beraber matematiksel işlemleri kullanan bir yapay zeka sinir ağıdır (4). Venn diyagramı yapay zeka ve alt gruplarının ilişkisini göstermektedir (5) (Şekil 1).



*Şekil 1. Yapay zeka alt gruplarının şematik görüntüsü(5)*

## 2. Makine Öğrenimi

Yapay zekâ teknolojisinin temel amacı, makinelerin yüklenen veriler aracılığıyla insanlar gibi problem çözme kabiliyeti kazanmasıdır. Bu teknolojiyi anlayabilmek için “Makine Öğrenmesi”, “Yapay Sinir Ağları”

ve “Derin Öğrenme” kavramlarının bilinmesi gerekmektedir. Makine öğrenmesi, yapay zekâ algoritmalarının en temel yapı taşlarından birini oluşturmaktadır (6).

Makine öğrenimi, yirmi birinci yüzyılı dönüştürme potansiyeline sahip bir yapay zekâ biçimidir. Bu terim, büyük veri kümelerine dayalı olarak akıllı tahminlerde bulunabilen geniş bir algoritma aralığını tanımlamaktadır. Söz konusu veri setleri çoğunlukla milyonlarca benzersiz veri noktasını dahil edecek ölçüde büyük görünmektedir (7).

Makine öğrenmesi modelleri, daha fazla veri ile beslendikçe gelişim göstermekte; böylece daha doğru değerlendirmeler yaparak daha özelleşmiş yanıtlar üretebilir hâle gelmektedir (8).

Son dönemdeki makine öğrenmesi alanında kaydedilen ilerlemeler, insan düzeyinde bilgi çıkarımı, semantik anlama ve hatta bazen soyut kalıpları insan uzmanlardan daha yüksek doğrulukla tanımlayabilme yetisine ulaşmıştır (9). Makine öğrenimi, makinenin aldığı öğrenme sinyali ya da geri bildirimle göre çeşitli sınıflara ayrılmaktadır.

## 2.1. Denetimli Öğrenme

Denetimli öğrenme, etiketlenmiş veri setleri kullanılarak modelin giriş ve çıkışlar arasındaki ilişkileri öğrendiği bir yapay zekâ yaklaşımı sunmaktadır. Rehberlik gerektiren bu süreç sonunda model, yeni verileri doğru şekilde etiketleyebilmektedir (10).

## 2.2. Denetimsiz Öğrenme

Denetimsiz öğrenmede sistem, dış bir rehber olmadan, etiketlenmemiş veriler arasındaki benzerlikleri analiz ederek analizleri keşfeder ve anlamlı bilgiler çıkarır (10).

## 3.Yapay Zeka Sinir Ağları


Yapay Sinir Ağları (YSA), insanın merkezi sinir sistemindeki karmaşık nöral bağlantı ağlarına benzer şekilde gelişim gösteren sayısal yöntemler bütünüdür. Bu sistemlerde, biyolojik sinir hücrelerinin (nöron) görevlerini üstlenen yapay sinir hücreleri, belirli görevleri yerine getirmek amacıyla bir araya gelerek katmanlı bir ağ yapısı oluşturmaktadırlar (11).

Warren McCulloch ve Walter Pitts’in 1943 yılında kaleme aldıkları “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” isimli araştırma, ilk yapay sinir ağı modelini sunan çalışmalardan biri olarak kabul edilmektedir (12).

Yapay sinir ağları, örnek verileri toplayarak bu örnekler arasındaki ilişkileri öğrenen ve edindiği bilgileri kullanarak karşılaştığı yeni örnekler hakkında karar verebilen yapılardır. Bu ağların, öğrenebilme ve genelleme yetenekleri sayesinde birçok bilim dalında uygulama alanı bulunmaktadır (13).

Biyolojik sinir hücrelerinde yer alan dendrit, hücre gövdesi ve akson gibi bileşenlerine karşılık olarak; yapay sinir ağlarında bu yapılar sırasıyla ağırlıklar, toplama fonksiyonu ve aktivasyon fonksiyonu olarak adlandırılmaktadır (5)

Yapay bir sinir hücresinde,  $X_1, X_2, \dots, X_n$  gibi girdiler, kendi ağırlıkları olan  $w_1, w_2, \dots, w_n$  ile çarpılır; ardından bu değerler toplanarak aktivasyon fonksiyonuna iletilmektedir. Aktivasyon fonksiyonu, bu toplamı işleyerek bir çıktı üretmektedir (14) (Şekil 2).



Şekil 2. Doğal sinir hücresi (a) ve Yapay sinir hücresi (b) (15,16)

Yapay sinir ağları genellikle üç katmandan oluşmaktadır: Girdi katmanı, çıktı katmanı ve gizli katmanı. Girdi ve çıktı katmanları çoğunlukla tek katmandan oluşurken, gizli katmanların sayısı ağına yapısına ve karmaşıklığına göre farklılık gösterebilmektedir. Girdi katmanı, verilerin ağına sunulduğu terminalleri içermektedir. Bu katmandaki veriler, bağlantıların ağırlıkları ile çarpılarak gizli katmana aktarılmaktadır. Gizli katman, ağına en önemli bölümünü oluşturur ve bazı yapay sinir ağı modellerinde birden fazla gizli katman bulunabilmektedir. Gizli katmanın yapısı ve nöron sayısı, ağına tasarımına ve kullanıcı deneyimine bağlı olarak belirlenmektedir. Gizli

katmandaki nöronlardan gelen çıkışlar, çıktı katmanına bağlantıların ağırlıkları ile çarpılarak aktarılmaktadır. Çıktı katmanı, ağı en son katmanıdır ve kendisine gelen girdileri işleyerek uygun bir çıktı oluşturmaktadır. Bağlantılar üzerindeki ağırlık değerleri, öğrenme süreci sırasında belirlenmektedir (17,18).

#### 4. Derin Öğrenme

21. yüzyılda insan beynindeki nöronal yapıyı taklit eden yapay sinir ağları, daha karmaşık problemleri çözebilmek amacıyla derin öğrenme kavramına evrilmiştir. 2006 yılında Hinton'un çok katmanlı yapay sinir ağlarının daha fonksiyonel eğitilebileceğini ortaya koymasıyla derin öğrenme kavramı literatürde yerini almıştır (19). Klasik yapay sinir ağlarıyla oluşturulamayan derin yapılar, modern hesaplama gücü sayesinde mümkün hâle gelmiş ve bu sayede doğrusal olmayan karmaşık ilişkiler modellenebilmiştir. Artan veri hacmi ve veri karmaşıklığı, derin öğrenme yöntemlerinin yaygınlaşmasına katkı sağlamıştır. Derin öğrenme; görüntü, ses ve doğal dil işleme gibi birçok alanda başarıyla kullanılmakta; plaka ve yüz tanıma, sürücüsüz araçlar, spam filtreleme ve tıbbi teşhis gibi uygulamalarda önemli rol oynamaktadır (20).

Derin öğrenme, geleneksel makine öğreniminde ihtiyaç duyulan elle özellik çıkarımı yerine, verilerin katmanlar boyunca otomatik şekilde işlenerek temsil edilmesini sağlar. Özellikle özellik çıkarımının otomatik olarak yapılması, derin öğrenmenin en önemli avantajlarından. Günümüzde bu alandaki araştırmalar hızla artmaktadır(21).

Derin öğrenme problemlerine göre farklı algoritmalar kullanılmaktadır. Bu algoritmalar arasında Evrişimli Sinir Ağları (ESA), Uzun Kısa Vadeli Hafıza (LSTM), Tekrarlayan Sinir Ağları (RNN), Sınırlı Boltzmann Makineleri (RBM), Derin İnanç Ağları (DBN) ve Derin Otokodlayıcılar yer almaktadır (22,23).

##### 4.1.Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN):

ESA'lar, özellikle görüntü işleme ve nesne tespitinde sıklıkla kullanılan ileri beslemeli ve çok katmanlı sinir ağı yapılarıdır (24). Sınıflandırma ve tespit görevlerinde sıkça tercih edilen ESA'larda evrişim, havuzlama, tam bağlı ve sınıflandırma gibi çeşitli katmanlar bulunur. Bu katmanlar sayesinde nesnelere ait ayırt edici özellikler belirlenerek sınıflandırma gerçekleştirilir (25).

ESA'ların eğitimi şu adımları içerir:


- Katman sayısı ve yapısı belirlenir, model oluşturulur.
- Başlangıç parametreleri tanımlanır.
- Girdi verisi modele aktarılır ve her katmanda işlenerek bir sonraki katmana iletilir (ileri besleme).

Bu süreçte ağırlıklar hesaplanır ve veri tüm katmanlar boyunca iletilir (26).

Modelin çıktısı hedef çıktıyla uyuşmadığında oluşan hata (kayıp), bağlantı noktalarına geri iletilerek sistemin kendini düzeltmesi sağlanmaktadır. Bu işleme geri besleme denir. Hata sinyali tüm nöronlara dağıtılır, toplam hata belirlenir ve ağ boyunca geri yayılım yoluyla modelin güncellenmesi gerçekleştirilmektedir (27).

#### 4.2. Tekrarlayan Sinir Ağı (RNN)


Tekrarlayan sinir ağları hafızaya sahip olmalarından dolayı zaman serileri ve ardışık verilerde başarılıdır. Her işlem adımı bir öncekinin çıktısına bağlıdır ve bu nitelik görüntü işleme gibi uygulamalarda yüksek doğruluk sağlamaktadır (28) (Şekil 3).



Şekil 3. Tekrarlayan sinir ağı modeli (25)

#### 4.3. Uzun Kısa Süreli Hafıza Ağları (LSTM)


Hochreiter ve Schmidhuber tarafından 1997'de geliştirilen LSTM, uzun vadeli bağımlılıkları yakalamak için tasarlanmıştır. Makine çevirisi, hisse senedi tahmini, konuşma ve el yazısı tanıma gibi alanlarda kullanılır ve diğer yöntemlere kıyasla kısa-uzun dönemli tahminlerde daha iyi başarı göstermektedir (29) (Şekil 4).



Şekil 4. Uzun kısa süreli hafıza ağı modeli (25)

#### 4.4. Sınırlı Boltzman Makineleri (RBM)

RBM, sınıflandırma, regresyon ve boyut indirgeme gibi alanlarda kullanılan derin öğrenme yöntemidir. İki katmandan oluşur: girişleri temsil eden görünür katman ve verilerin özelliklerini kodlayan gizli katman. Bu katmanlar arasındaki ağırlıklar öğrenilerek veri temsili sağlanır (30,31) (Şekil 5).




Şekil 5. Sınırlı boltzman makineleri modeli (25)

#### 4.5. Derin İnanç Ağları (DBN)

Geoffrey Hinton tarafından geliştirilen DBN, ardışık RBM katmanlarından oluşur. Katmanlar birbirleriyle bağlantılı çalışır ancak aynı katmandaki


düğümlemler yatay iletişim kurmaz. Son katmanda softmax işlevi bulunur ve denetimsiz öğrenme ile sınıflandırma yapılabilir. DBN'ler görüntü üretimi ve tanıma gibi alanlarda da kullanılır (31) (Şekil 6).



Şekil 6. Derin inanç ağı modeli (25)

#### 4.6. Derin Otokodlayıcılar

Derin otokodlayıcılar; kodlayıcı, kod çözücü ve kod bileşenlerinden oluşur. Girdileri daha düşük boyutlu kodlara dönüştürür ve aslına yakın bir çıktı üretir. Netleştirilen görüntüler, yorumlama amacıyla başka sinir ağılarına aktarılabilir (32) (Şekil 7).



Şekil 7. Derin Otokodlayıcı modeli (25)

## 5. Derin Öğrenme Kütüphaneleri

Derin öğrenme mimarilerini geliştirmek ve yapay sinir ağlarını eğitmek amacıyla kullanılan yazılım araçları derin öğrenme kütüphaneleri olarak tanımlanmaktadır. Bu derin öğrenme kütüphaneleri, büyük veri setlerinden anlamlı örüntüler çıkarabilmek ve derin öğrenme modellerinin görevlerini etkin şekilde yerine getirebilmek amacıyla geliştirilmiştir. Facebook tarafından geliştirilen PyTorch, dinamik ve esnek yapısı hesaplama grafikleri meydana getirme özelliği ile dikkat çeken açık kaynaklı bir derin öğrenme kütüphanesidir. UC Berkeley tarafından geliştirilen Keras, genellikle bilgisayar görüşü alanında öne çıkan hızlı bir derin öğrenme aracıdır. Google tarafından geliştirilen TensorFlow ise grafik tabanlı hesaplama modeliyle geniş bir topluluk tarafından desteklenen açık kaynaklı bir kütüphanedir (3). Apache MXNet ise, ölçeklenebilirliği, esnekliği ve çoklu dil desteğiyle öne çıkan, dağıtılmış eğitim olanağı sunan bir derin öğrenme platformudur. Bu kütüphaneler, geliştiricilerin farklı gereksinimlerine yönelik çeşitli avantajlar sunmakta olup, seçim süreci projenin ihtiyaçları, geliştirme tecrübesi ve topluluk desteği gibi unsurlara bağlıdır (33).

## 6. Derin Öğrenme ve Diş Hekimliği

Yapay zeka tabanlı algoritmalar, birçok alanda olduğu gibi diş hekimliği alanında da hızla gelişerek ilerlemektedir (34). Bilgisayar ve internet teknolojilerindeki ilerlemeler, diş hekimliği veri setlerinin kolay erişilebilirliği ve yapay zeka ile işlenebilmesi bu gelişmeyi desteklemektedir. Diş hekimliği pratiğinde hasta-klinisyen etkileşiminden klinik prosedürlere kadar teknolojik ilerlemeler büyük önem taşımaktadır (35).

Yapay zeka tabanlı modeller, dental asistanlarla bütünleşmiş biçimde hasta randevularını organize ederek hasta kayıtlarının yönetimini kolaylaştırmaktadır (36). Ayrıca hastaların tıbbi ve dental anamnezleri kaydedilmekte, sigara ve alkol kullanımı gibi olumsuz alışkanlıklar tespit edilerek hekimlere sunulmaktadır. Bu sayede, oluşan benzersiz veri tabanı ile hasta süreçleri hızlanmakta ve takibi kolaylaşmaktadır (35). Tüm bu ilerlemeler insan gücü ve zamandan tasarruf sağlarken, insan kaynaklı hataları azaltmakta ve maliyetleri azaltmaktadır (3).

Diş hekimliğinde yapay zeka, teşhis süreçlerini daha doğru ve etkin hale getirerek en doğru tedavi süreci planlarının oluşturulmasına katkı sağlamaktadır. Hekimlerin var olan tüm bilgilerini kullanarak doğru karar vermesi bazen zaman kısıtlamaları nedeniyle zor olabilmektedir. Bu durumda yapay zeka tabanlı modeller rehberlik edebilmektedir (3). Yapay zekâ algoritmaları, panoramik radyografilerde dişlerin otomatik olarak

algılanması ve doğrulanması için ayırt edici özelliklerden yararlanmaktadır. Ayrıca, periapikal radyografilerde dişlerin ve çevresindeki anatomik yapıların ayrıntılı görüntülenmesi, yapay zeka tabanlı diş numaralandırma sistemlerinin doğruluğunu ve hassasiyetini artırmaktadır. Periapikal görüntüler, diş morfolojisindeki küçük değişikliklerin tanımlanmasını ve doğru teşhisi kolaylaştırmaktadır. Doğru diş segmentasyonu ve tanımlanması, teşhisten tedavi planlamasına kadar klinik uygulamalarda önemli avantajlar sunmaktadır. Yapay zeka tabanlı üç boyutlu segmentasyon, diş hekimliği uygulamalarının etkinliğini artırarak karmaşık anatomik yapıların daha hassas tanımlanmasına olanak sağlamaktadır (37). Son zamanlarda konik ışınli bilgisayarlı tomografi (CBCT) görüntüleri kullanılarak dişlerin otomatik tespiti ve sınıflandırılması üzerine çalışmalar yapılmaktadır. (38).

Ağız, diş ve çene radyolojisi alanında yapay zeka, sefalometrik radyografilerde landmark tespiti, alveolar kemik kaybının değerlendirilmesi, kök morfolojisinin incelenmesi, üç ve iki boyutlu radyografilerde diş tespiti ve numaralandırılması, diş çürükleri ve periapikal patolojilerin saptanması gibi çeşitli araştırmalarda kullanılmaktadır (39,40). Ayrıca yapay zekâ modelleri, ağız hastalıklarının teşhisinde, ağız kanserlerinin ve yüksek riskli hastaların belirlenmesinde, ortodontide büyüme ve gelişimin izlenmesinde, el-bilek radyografileri kullanılarak kemik yaşının değerlendirilmesinde, diş hareketlerinin planlanmasında ve uygulanacak kuvvet miktarının ölçülmesinde etkin görev almaktadır (41). Evrişimli sinir ağı tabanlı algoritmalar, vertikal kök kırıkları, diş ve çene patolojileri, osteoporoz ve maksiller sinüzitin değerlendirilmesinde kullanılmaktadır (42).

Hangi dişlerin diş hastalıklarından etkilenip etkilenmediğini tespit eden otomatik, karmaşık tespit sistemleri diş tanımlama sürecinin temelini oluşturmaktadır. Araştırmacılar, dişleri sınıflandırmak ve numaralandırmak için çeşitli teknikler geliştirmiştir (43). Evrişimli sinir ağıları tabanlı modeller, otomatik diş segmentasyonu konusunda daha yüksek doğruluk değerleri sergilemektedir (44).

Diş yaşının belirlenmesinde klinik ve pantomografik yöntemler genellikle kullanılır. Klinik yöntem uygulanması kolay ve hızlı sonuçlar sağlayabilse da sıklıkla yanlış sonuçlar verebilmektedir. Pantomografik yöntem ise diş tomurcuklarının mineralizasyon aşamasını incelenmesini sağlayan daha hassas bir yaklaşımdır. Zaborowicz vd. (2021), dijital pantomografik görüntüler ve sinir modellemesi kullanarak kronolojik yaşını belirlemek için 4-15 yaş aralığındaki çocuklarda yeni bir yöntem geliştirmiştir. Bu yöntem, basit uygulanabilirliği, yüksek doğruluk sağlaması, pantomografik görüntülerde metrik yaş değerlendirmesi yapabilmesi nedeniyle kullanılan ilk

yöntemlerden biri olmaktadır (45). Benzer şekilde Zaborowicz vd. (2022), yaptığı diğer araştırmada üç derin sinir ağı modeli ile 4-15 yaş arası çocuk ve ergenlerin diş ve kemik göstergelerini kullanarak biyolojik yaşı doğru bir şekilde tanımlayabildiğini göstermiştir (46).

## Referanslar

1. Bellman R. Artificial intelligence : can computers think? (No Title) [Internet]. 1978; Available from: <https://cir.nii.ac.jp/crid/1130282270499133440>
2. Ramesh AN, Kambhampati C, Monson JR, Drew pJ. Artificial intelligence in medicine Ann R Coll Surg Engl. 2004;86(5):334–8.
3. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. J Dent Sci. 2021 Jan;16(1):508–22.
4. Schwendicke F, Elhennawy K, Paris S, Friebertshäuser P, Krois J. Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study. J Dent. 2020 Jan;92(103260):103260.
5. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional neural networks for radiologic images: A radiologist's guide. Radiology. 2019 Mar;290(3):590–606.
6. Nichols JA, Herbert Chan HW, Baker MAB. Machine learning: applications of artificial intelligence to imaging and diagnosis. Biophys Rev. 2019 Feb;11(1):111–8.
7. Samuel AL. Some studies in machine learning using the game of checkers. II—Recent progress. Annual Review of Automatic Programming. 1967 Nov 1;6:1–36.
8. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. Brief Bioinform. 2018 Nov 27;19(6):1236–46.
9. Calayır GN, Kabak M. Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama. Journal of Turkish Operations Management. 2021;5(1):662–75.
10. Silver D, Schrittwieser J, Simonyan K, Antonoglou I, Huang A, Guez A, et al. Mastering the game of Go without human knowledge. Nature. 2017 Oct 18;550(7676):354–9.
11. Jain AK, Mao J, Mohiuddin KM. Artificial neural networks: a tutorial. Computer (Long Beach Calif). 1996 Mar;29(3):31–44.
12. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. Takvim-i Vekayi. 2018;6(2):25–36.
13. Ergezer H, Dikmen M, Özdemir E. Yapay sinir ağları ve tanıma sistemleri. PiVOLKA. 2003;2(6):14–7.
14. Öztemel DE. YAPAY SİNİR AĞLARI [Internet]. Available from: [http://papatyabilim.com.tr/PDF/yapay\\_sinir\\_aglari.pdf](http://papatyabilim.com.tr/PDF/yapay_sinir_aglari.pdf)

15. Sinanoğlu C, Kurban AO, Yildirim Ş. Analysis of pressure variations on journal bearing system using artificial neural network. *Ind Lubr Tribol*. 2004 Apr 1;56(2):74–87.
16. Krogh A. What are artificial neural networks? *Nat Biotechnol*. 2008 Feb;26(2):195–7.
17. Efe MÖ, Kaynak O. Yapay sinir ağları ve uygulamaları. 2004; Available from: <https://scholar.google.gr/citations?user=OityWEAAAAAJ&hl=tr&oi=sra>
18. Firat M, Güngör M. Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi. *Teknik Dergi* [Internet]. 2004 Feb 1;15. Available from: <https://dergipark.org.tr/en/download/article-file/136710>
19. Kaya U, Yılmaz A, Dikmen Y. Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri. *Eur J Sci Technol*. 2019 Aug 31;(16):792–808.
20. Keleş A. DERİN ÖĞRENME VE SAĞLIK ALANINDAKİ UYGULAMALARI. *Electronic Turkish Studies* 2018 [Internet]. Available from: [https://www.researchgate.net/profile/Ali-Keles-5/publication/328347813\\_Derin\\_Ogrenme\\_ve\\_Saglik\\_Alanindaki\\_Uygulamalari/links/5f997a40a6fdccfd7b84c32a/Derin-Oegrenme-ve-Saglik-Alanindaki-Uygulamalari.pdf](https://www.researchgate.net/profile/Ali-Keles-5/publication/328347813_Derin_Ogrenme_ve_Saglik_Alanindaki_Uygulamalari/links/5f997a40a6fdccfd7b84c32a/Derin-Oegrenme-ve-Saglik-Alanindaki-Uygulamalari.pdf)
21. Elshaw R, Wahab A, Barnawi A, Sakr S. DLBench: a comprehensive experimental evaluation of deep learning frameworks. *Cluster Comput*. 2021 Sep;24(3):2017–38.
22. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436–44.
23. Collobert R, Weston J, Bottou L, Karlen M, Kavukcuoglu K, Kuksa P. Natural language processing (almost) from scratch. *Journal of machine learning research*. 2011;12:2493–537.
24. Söylemez ÖF, Ergen B. Farklı Evrimsel Sinir Ağı Mimarilerinin Yüz İfade Analizi Alanındaki Başarımlarının İncelenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2020;11(1):123–33.
25. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2019;10(2):409–45.
26. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to machine learning, neural networks, and deep learning. *Transl Vis Sci Technol*. 2020 Feb 27;9(2):14.
27. Kriegeskorte N, Golan T. Neural network models and deep learning. *Curr Biol*. 2019 Apr 1;29(7):R231–6.
28. Bae JH, Yeo D, Yim J, Kim NS, Pyo CS, Kim J. Densely distilled flow-based knowledge transfer in teacher-student framework for image classification. *IEEE Trans Image Process*. 2020 Apr 6;29:5698–710.

29. Somuncu E, Atasoy NA. Evrişimli tekrarlayan sinir ağı ile metin görüntüleri üzerinde karakter tanıma uygulaması gerçekleştirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. 2022;37(1):17–28.
30. HCA Deckshith Shetty, MJ Varma, S Navi, MR Ahmed. Diving Deep into Deep Learning: History, Evolution, Types and Applications. 2020;
31. Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science*. 2006 Jul 28;313(5786):504–7.
32. Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E. Deep learning for computer vision: A brief review. *Comput Intell Neurosci*. 2018 Feb 1;2018:7068349.
33. Gündüz G, Cedimoğlu İH. Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya University Journal of Computer and Information Sciences*. 2019;2(1):9–17.
34. Ghods K, Azizi A, Jafari A, Ghods K. Application of Artificial Intelligence in clinical dentistry, a comprehensive review of literature. *J Dent (Shiraz)*. 2023 Dec;24(4):356–71.
35. Mahdi SS, Battineni G, Khawaja M, Allana R, Siddiqui MK, Agha D. How does artificial intelligence impact digital healthcare initiatives? A review of AI applications in dental healthcare. *International Journal of Information Management Data Insights*. 2023 Apr;3(1):100144.
36. Khanna SS, Dhaimade PA. Artificial intelligence: transforming dentistry today. *Indian J Basic Appl Med Res*. 2017;6(3):161–7.
37. Hartoonian S, Hosseini M, Yousefi I, Mahdian M, Ghazizadeh Ahsaie M. Applications of artificial intelligence in dentomaxillofacial imaging: a systematic review. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2024 Nov;138(5):641–55.
38. Jang TJ, Kim KC, Cho HC, Seo JK. A fully automated method for 3D individual tooth identification and segmentation in dental CBCT. *IEEE Trans Pattern Anal Mach Intell*. 2022 Oct;44(10):6562–8.
39. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol*. 2021 Sep 1;50(6):20200172.
40. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone loss. *Sci Rep*. 2019 Jun 11;9(1):8495.
41. AGZ BİÇER, ÖGH TEPE, ÖGÖ ÇELİKSÖZ, BC YAMAN. Yapay Zeka Ve Restoratif Diş Hekimliği [Internet]. Available from: <https://iksadyayinevi.com/wp-content/uploads/2023/06/TIP-VE-SAGLIK-BILIMLERINDE-MULTIDISIPLINER-BAKIS-I.pdf#page=10>

42. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. *J Stomatol Oral Maxillofac Surg*. 2021 Sep;122(4):333–7.
43. Vishwanathaiah S, Fageeh HN, Khanagar S, Maganur P. Artificial intelligence its uses and application in pediatric dentistry: A review. *Biomedicines* [Internet]. 2023 Mar 1;11. Available from: <https://www.mdpi.com/2227-9059/11/3/788>
44. Lee JH, Han SS, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2020 Jun;129(6):635–42.
45. Zaborowicz K, Biedziak B, Olszewska A, Zaborowicz M. Tooth and bone parameters in the assessment of the chronological age of children and adolescents using neural modelling methods. *Sensors (Basel)*. 2021 Sep 8;21(18):6008.
46. Zaborowicz M, Zaborowicz K, Biedziak B, Garbowski T. Deep learning neural modelling as a precise method in the assessment of the chronological age of children and adolescents using tooth and bone parameters. *Sensors (Basel)*. 2022 Jan 14;22(2):637.

