

YAPAY ZEKA İLE SAĞLIK ALANINDA DÖNÜŞÜM

Sueda Eren

Gazi Üniversitesi Yapay Zeka Uygulama ve Araştırma Merkezi

sueda.eren@gazi.edu.tr

DOI: 10.5281/zenodo.15361073

1. GİRİŞ

Sağlık sektörü hem bireylerin yaşam kalitesini doğrudan etkileyen hem de sürekli artan veri miktarı ve karmaşıklığı nedeniyle yeni çözümlere ihtiyaç duyan bir alandır. Bu noktada, yapay zekâ (YZ) teknolojileri yalnızca bir yenilik değil, aynı zamanda sağlık hizmetlerinin yeniden tanımlanmasında kilit bir rol üstlenmektedir. YZ, devasa sağlık verilerini işleyebilme, örüntü tanıma yetenekleri ve öğrenme kapasitesi sayesinde; hastalıkların erken teşhisi, tedavi planlarının kişiselleştirilmesi, klinik karar destek sistemlerinin güçlendirilmesi ve idari süreçlerin otomasyonu gibi birçok alanda çözüm sunmaktadır. YZ modelleri özellikle derin öğrenme mimarileri ile bu karmaşıklığı yöneterek yüksek doğrulukta öngörüler yapabilmektedir (Esteva et al., 2019).



YZ sistemleri, insan uzmanlara yardımcı olarak tanı doğruluğunu artırabilir, zamandan tasarruf sağlar ve tekrarlayan görevleri otomatikleştirerek sağlık çalışanlarının iş yükünü hafifletebilir. Bu nedenle klinik karar destek sistemlerinde özellikle radyoloji, dermatoloji, kardiyoloji ve nöroloji gibi karmaşık veriye dayalı alanlarda tercih edilmektedir (Topol, 2019).

YZ sistemlerinin en belirgin avantajlarından biri, doğruluk ve hız açısından insan performansına yaklaşabilmeleri, hatta bazı senaryolarda onu geçebilmeleridir. Özellikle görüntü işleme, doğal dil işleme, zaman serisi analizi ve tahmine dayalı modelleme gibi alanlarda bu algoritmalar hem niceliksel hem de niteliksel olarak önemli başarılar elde etmiştir. Örneğin, derin öğrenme modelleri kullanılarak geliştirilen sinir ağları, radyolojik görüntülerdeki anormallikleri %90'ın üzerinde doğrulukla tespit edebilmektedir (Estava et al., 2017). Bu tür teknolojiler, doktorlara sadece ikinci bir görüş sunmakla kalmaz, aynı zamanda klinik kararların tutarlılığını da artırır.

Yapay zekanın klinik uygulamalarda tercih edilmesinin bir diğer önemli nedeni, adaptif öğrenme yeteneğidir. Bir YZ modeli, gerçek hasta verileriyle beslendikçe kendini geliştirir, böylece zamanla daha iyi tahminlerde bulunabilir. Ayrıca, algoritmaların geri besleme mekanizmaları sayesinde sürekli olarak optimize edilmesi, tıpta "deneyimle uzmanlaşma" sürecini dijital ortamda yeniden üretebilmektedir. Bu, özellikle nadir hastalıkların tespiti gibi uzmanlık gerektiren alanlarda büyük önem taşımaktadır.

2. YAPAY ZEKANIN SAĞLIK SEKTÖRÜNDEKİ KULLANIM ALANLARI

2.1. Tıbbi Görüntüleme ve Tanı Sistemleri

YZ, özellikle manyetik rezonans görüntüleme (magnetic resonance imaging-MRI), bilgisayarlı tomografi (BT), röntgen ve ultrason gibi görüntüleme tekniklerinden elde edilen verilerin analizinde büyük bir rol oynamaktadır. Görüntülerdeki anormalliklerin, örneğin tümörler, kanamalar veya organ hasarları tespitinde YZ sistemleri, radyologlara destek olmakta veya bazı durumlarda onlardan daha yüksek doğrulukla sonuç verebilmektedir (Litjens vd., 2017).

Bu alanda yaygın olarak kullanılan konvolüsyonel sinir ağları (convolutional neural networks-CNN), görüntü işleme üzerine optimize edilmiş derin öğrenme mimarileridir. CNN'ler, katmanlar halinde yapılandırılmış filtreler aracılığıyla, bir görüntüdeki kenar, köşe ve daha karmaşık yapıları öğrenerek sınıflandırma yapar. Özellikle 'convolutional', 'pooling' ve 'fully connected' katmanları sayesinde görsel verilerdeki anlamlı desenleri tanıyabilirler (LeCun vd., 2015).

CNN'lerin ilk katmanı olan convolutional layer, görüntü üzerindeki yere bölgeleri işleyen filtreler ile çalışır. Bu filtreler, genellikle kenar, doku gibi düşük seviyeli özellikleri algılar. Her filtre, veri kümesi üzerinden öğrenilen ve modelin kendiliğinden optimize ettiği parametrelerden oluşur. Aktivasyon fonksiyonları karmaşık görüntüleri öğrenme yetisi sağlar.




Sueda Eren

Gazi Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü 4. sınıf öğrencisiyim. Gazi Üniversitesi Yapay Zeka Uygulama ve Araştırma Merkezi'nde kısmi zamanlı olarak çalışmaktayım. Makine öğrenmesi, derin öğrenme, büyük dil modelleri, bilgisayarlı görü ve medikal alanda yapay zeka uygulamaları ile ilgilenmekteyim.

Rectified Linear Unit (ReLU), her katmandan sonra uygulanarak modele doğrusal olmayanlık kazandırır. ReLU, negatif girdileri sıfıra çekerken pozitif girdileri olduğu gibi bırakır ve bu sayede gradyanların kaybolma sorununu azaltarak öğrenmeyi kolaylaştırır. Genel olarak yapay sinir ağı, yalnızca doğrusal dönüşümlerden oluşursa yeterince güçlü tahminler yapamaz, bu nedenle aktivasyon fonksiyonları büyük önem taşır. Aşağıdaki denklemde, x giriş değeridir ve ReLU fonksiyonu, x sıfırdan büyükse x 'i olduğu gibi geçirir, küçükse sıfıra eşitler. Yani negatif girdiler sıfırlanırken, pozitif girdiler değişmeden aktarılır.

$$f(x) = \max(0, x)$$

ReLU, diğer fonksiyonlara kıyasla daha sade bir yapıya sahiptir ve hesaplama açısından oldukça verimlidir. Bu özellikleri sayesinde derin ağlarda öğrenmeyi hızlandırır ve kaybolan gradyan (vanishing gradient) problemini azaltır. ReLU sayesinde model, verideki karmaşık desenleri daha etkili şekilde öğrenebilir.



Şekil 1. ReLU fonksiyonu

CNN'ler geri yayılım (backpropagation) algoritması ile eğitilir. Bu algoritma, çıktıda yapılan hata ile her bir ağırlığın bu hataya katkısını hesaplar ve zincir kuralını kullanarak ağırlıkları günceller. Böylece model zamanla daha doğru hale gelir. Ağ boyunca geriye doğru yayılmasıyla ağırlıkların güncellenmesini sağlayan backpropagation algoritması şu temel adımlara dayanır:

a. İleri yayılım:

Verilen her girdi x için, her katmandaki aktivasyon şu şekilde hesaplanır:

$$z^{(l)} = W^{(l)}a^{(l-1)} + b^{(l)}$$

$$a^{(l)} = f(z^{(l)})$$

Girdi verisi katman katman ağıdan geçirilir. Her katmanda, önce ağırlıklarla çarpılıp bias eklenerek bir değer elde edilir (z), ardından bu değer aktivasyon fonksiyonundan geçirilerek çıkış (a) hesaplanır.



ReLU aktivasyon fonksiyonu, hesaplama açısından basit ve hızlı olmasıyla öne çıkar. Derin sinir ağlarında gradyanların sıfırlanma sorununu büyük ölçüde azaltarak öğrenmeyi kolaylaştırır. Pozitif değerler üzerinden çalıştığı için bilgi akışı daha net sağlanır. Ancak negatif girdiler için sonuç sıfır olduğundan bazı nöronlar tamamen işlevsiz hale gelir; bu durum "dying ReLU" problemi olarak bilinir.

Şekil 1'de yer alan ReLU fonksiyonun grafiği, negatif girişlerde sıfır; pozitif girişlerde ise girişin kendisini döndürür. Bu özelliği sayesinde, ağı yalnızca anlamlı aktivasyonları öğrenmesini sağlar.

Pooling layer, elde edilen öznitelik haritalarının boyutunu küçültürken hesaplama maliyetini azaltır ve uzamsal genelleme sağlar. En yaygın kullanılan yöntem "max pooling" olup filtre penceresindeki maksimum değeri seçer. Son olarak fully connected layer, tüm önceki katmanlardan gelen bilgileri birleştirerek sınıflandırma veya regresyon gibi karar işlemlerini gerçekleştirir.

b. Kayıp fonksiyonu:

Yaygın kullanılan kayıp fonksiyonu şu şekildedir:

$$L(y, \hat{y}) = \frac{1}{2} (y - \hat{y})^2$$

Modelin tahmin ettiği sonuç ile gerçek sonuç arasındaki fark hesaplanır. Bu fark, ağırlığın ne kadar hata yaptığını gösterir.

c. Geri yayılım:

Ağırlık çıktısı ile gerçek değer arasındaki farkı kullanarak gradyanlar hesaplanır.

d. Çıkış katmanı hatası:

$$\delta^{(L)} = (a^{(L)} - y) \cdot f'(z^{(L)})$$

Modelin çıktısı ile gerçek değer arasındaki fark, aktivasyon fonksiyonunun türevi ile çarpılarak son katmandaki hata oranı elde edilir.

e. Gizli katman hataları:

$$\delta^{(l)} = (W^{(l+1)})^T \delta^{(l+1)} \cdot f'(z^{(l)})$$

Çıkıştaki hata, önceki katmanlara doğru yayılır. Bu yayılım sırasında her katmandaki hata, bir sonraki katmandan gelen hata kullanılarak hesaplanır.

f. Ağırlık ve bias güncellemesi:


$$W^{(l)} = W^{(l)} - \mu \cdot \delta^{(l)} \cdot (a^{(l-1)})^T$$

$$b^{(l)} = b^{(l)} - \mu \cdot \delta^{(l)}$$



Her katmandaki ağırlık ve bias değerleri, hesaplanan hataya göre küçük adımlarla güncellenir. Bu işlem öğrenme oranı sayesinde kontrollü şekilde yapılır.

CNN mimarileri genellikle üç temel katmandan oluşur: evrişimsel katmanlar, havuzlama katmanları ve tam bağlı katmanlar. Bu katmanların ardışık olarak düzenlenmesiyle derin ve güçlü bir öğrenme yapısı elde edilir. Aşağıda, gri seviyeli bir MRI görüntüsünün CNN mimarisi ile nasıl işlendiği görülmektedir.




Şekil 2. CNN mimarisi

Şekil 2’de yer alan yapı sayesinde, görüntüdeki temel kenar ve doku gibi düşük seviyeli özelliklerden başlayarak, daha soyut ve karmaşık desenlere kadar çeşitli bilgi düzeyleri çıkarılabilir. Özellikle tıbbi görüntülerde, CNN mimarileri bu çok katmanlı yapı sayesinde anormalliklerin ve hastalıkla ilişkili kalıpların otomatik olarak öğrenilmesine olanak tanır. Böylece, MRI gibi yüksek boyutlu ve detaylı görsel verilerden güvenilir tanı ve sınıflandırma sonuçları elde edilebilir.

CNN’ler, sağlık verilerindeki yüksek boyutlu ve karmaşık yapıları başarılı bir şekilde analiz edebilmeleri nedeniyle tercih edilmektedir. Derin yapıları sayesinde manuel özellik mühendisliği gereksinimini ortadan kaldırmaları ve büyük veri kümelerinde yüksek performans göstermelerini, tıbbi görüntü analizinden vazgeçilmez hale gelmelerini sağlamıştır.

2.2. Cerrahi Robotlar ve Otonom Sistemler

YZ destekli robotlar, cerrahların daha hassas ve minimal invaziv operasyonlar yapmasına olanak tanımaktadır. Bu robotlar, geçmiş operasyon verilerinden öğrenerek ameliyat sırasında karar verebilir ve hata oranını azaltabilirler. Bu uygulamalarda pekiştirmeli öğrenme (reinforcement learning-RL) önemli bir rol oynar. RL, bir ajanın (bu bağlamda cerrahi robotun) bir ortamla etkileşim kurarak ödül maksimizasyonu üzerinden karar verme becerisi geliştirdiği bir öğrenme paradigmasıdır. Ajan, her eylem sonrası ödül alır ve bu ödülü en üst düzeye çıkaracak stratejileri zamanla öğrenir (Sutton & Barto, 2018). Şekil 3, pekiştirmeli öğrenmenin temel bileşenlerini ve bunların birbiriyle olan etkileşimlerini göstermektedir.



Şekil 3. Pekiştirmeli öğrenme

Şekil 3’te, ajan (B), çevreden aldığı durumu (s) değerlendirerek bir eylem (a) üretmektedir. Bu eylemin sonucu olarak ortam (T), bir ödül (r) ve yeni bir durum (s') üretir. Bilgi ve ödül, ajan tarafından öğrenme sürecinde değerlendirilir ve bu süreçte ajan, politika (policy), değer fonksiyonu (value function) ve ödül yapısına (reward function) dayalı olarak kararlarını geliştirir. Bu yapı, RL algoritmalarının karar verme sürecinin temelini oluşturarak, karmaşık ortamlarda etkili öğrenmenin kapısını aralar (Kaelbling, 1996). RL, ajanların bir ortamda deneme-yanılma yoluyla öğrenmesini sağlayan bir yaklaşımdır. Ajan, bir durum algılar ve buna uygun bir eylem gerçekleştirir. Bu eylemin sonucunda ödül (reward) alır ve yeni bir duruma geçer. Politika, ajanın hangi durumda nasıl davranması gerektiğine karar veren stratejidir. Bu politika ya belirli kurala dayanabilir ya da öğrenilerek geliştirilebilir. Bazı RL algoritmaları şunlardır:

- Q-learning: Ajan, her durum-eylem çiftine karşılık gelen Q-değerini öğrenerek optimal politikayı bulmaya çalışır.
- Deep Q-Networks (DQN): Q-learning’i derin sinir ağlarıyla birleştirir.
- Policy Gradient Methods: Politika fonksiyonunun doğrudan optimizasyonunu sağlar (PPO, REINFORCE).


Bu süreçte, markov karar süreçleri (markov decision process-MDP) temel matematiksel çerçeveyi sağlar. RL’de kullanılan yöntemler arasında Q-öğrenme (Q-learning), SARSA, ve Deep Q-Networks (DQN) gibi algoritmalar yer alır. Özellikle derin pekiştirmeli öğrenme, karmaşık ortamlarda öğrenmeyi mümkün kılmış ve robotik, oyun, sağlık gibi birçok alanda uygulama alanı bulmuştur. Bu yöntemler sayesinde RL, örneğin cerrahi robotların çevresel koşullara göre adaptif kararlar almasına olanak tanır. Cerrahi robotik sistemlerde RL’nin tercih edilme nedeni, gerçek zamanlı adaptasyon yeteneğidir. Özellikle sürekli değişen operasyon ortamlarında en uygun eylemleri öğrenebilmesi, insan müdahalesi olmadan operasyonlara destek vermesini mümkün kılmaktadır.

2.3. Hastalık Tahmini ve Kişiselleştirilmiş Tedavi

YZ, hasta verilerinden (tıbbi geçmiş, yaşam tarzı, genetik bilgiler vb.) risk faktörlerini belirleyerek hastalıkların erken teşhisini mümkün kılar. Aynı zamanda hastaya özel tedavi planları önererek kişiselleştirilmiş sağlık çözümleri sunar. Bu uygulamalarda sıklıkla lojistik regresyon, destek vektör makineleri (support vector machine-SVM) ve yapay sinir ağları (artificial neural network-ANN) kullanılır. LR, doğrusal karar sınırları üzerinden ikili sınıflandırma yapan bir istatistiksel modeldir. Özellikle modelin parametrelerinin yorumlanabilir olması ve eğitim sürecinin hızlı gerçekleşmesi, klinik ortamlarda tercih edilmesini sağlar (Hosmer vd., 2013).

Lojistik regresyon, doğrusal bir model olup olasılık tahmini yapar. Giriş değişkenlerine karşılık gelen ağırlıkları kullanarak bir karar sınırı oluşturur. Çıktı, sigmoid aktivasyon fonksiyonu yardımıyla $[0,1]$ aralığında bir olasılık değeri olarak yorumlanır. Bu değer, örneğin bir hastada kanser olma olasılığını ifade edebilir. Lojistik regresyonun avantajı, modelin yorumlanabilirliğinin yüksek olmasıdır. Her bir değişkenin çıktıya olan katkısı doğrudan gözlemlenebilir.

Regresyon modelleri, veriler arasındaki ilişkileri analiz etmek ve tahminlerde bulunmak için yaygın olarak kullanılır. Lineer regresyon, sürekli bağımlı değişkenleri tahmin etmekte etkili olsa da ikili sınıflandırma gibi görevlerde yetersiz kalır. Bu gibi durumlarda, doğrusal olmayan bir karar sınırı sağlayan lojistik regresyon devreye girer. Şekilde 4'teki grafik, lineer regresyonun sınırlamalarını ve lojistik regresyonun sınıflandırma problemlerinde nasıl daha etkili bir çözüm sunduğunu göstermektedir.



Şekil 4. Lojistik regresyon




Grafikte görüldüğü gibi, lineer regresyon doğrusal bir çizgi ile veriyi modellemeye çalışırken, bu yaklaşım sınıflar arasında keskin bir ayırım yapmada başarısız olabilir. Özellikle 0 ve 1 gibi sınıf etiketleriyle çalışırken, tahmin değerlerinin bu aralık dışına çıkması anlamlı değildir. Lojistik regresyon ise sigmoid fonksiyonu sayesinde tahminleri 0 ile 1 arasında sınırlar ve verileri olasılık temelli olarak sınıflandırır. Bu nedenle, ikili sınıflandırma problemlerinde lineer regresyona kıyasla lojistik regresyon tercih edilir; çünkü daha gerçekçi ve güvenilir sonuçlar sunar.

SVM, yüksek boyutlu verilerde bile etkili çalışan ve margin optimizasyonu prensibiyle en iyi sınıflandırma sınırını bulan bir yöntemdir. Kernel trik sayesinde doğrusal olmayan verileri de doğrusal ayırabilme yeteneği vardır. Özellikle küçük veri setlerinde aşırı öğrenmeye (overfitting) karşı dayanıklıdır (Cortes & Vapnik, 1995).

SVM'ler, sınıflar arasında maksimum margini bulmaya çalışan bir algoritmadır. Bu margin, sınıflar arasındaki ayrımları mümkün olduğunca açık hale getirir. Destek vektörleri, bu margin üzerinde veya çok yakınında bulunan veri noktalarıdır ve karar sınırının belirlenmesinde kritik rol oynar. Veriler doğrusal olarak ayrılabilir değilse, Kernel trik sayesinde daha yüksek boyutlu uzaylara taşınarak ayırt edilebilir hale getirilir. En yaygın kullanılan kernel fonksiyonları arasında radial basis function (RBF) ve polinom yer alır. SVM'lerin regresyon problemlerine uyarlanabilir hale gelen versiyonu ise support vector regression (SVR) olarak adlandırılır.

ANN, insan beynindeki sinir ağlarından ilham alınarak geliştirilmiş bir makine öğrenme yapısıdır. Giriş katmanı, bir veya birden fazla gizli katman ve bir çıktı katmanından oluşur. Girdiler, ağırlıklarla çarpılarak bir sonraki katmana aktarılır. Girdi verilerinden soyut ve karmaşık örüntüler çıkarılabilir, bu da onu klinik veri analizinde oldukça güçlü kılar. Derin öğrenme yaklaşımlarıyla birleştğinde ANN'ler büyük veri kümelerinde oldukça yüksek doğruluk sağlayabilir (Goodfellow vd., 2016).

Şekil 5'te görselde yer alan üç katmanlı basit bir ileri beslemeli yapay sinir ağı (feedforward neural network-FNN), giriş katmanı, gizli katman ve çıkış katmanından oluşur. Bu yapı, FNN, restricted boltzmann machines (RBMs) ve recurrent neural networks (RNNs) gibi yaygın ANN mimarilerinin temelini oluşturur (O'Shea & Nash, 2015).



Şekil 5. ANN mimarisi

Şekil 5'te yer alan bu üç katmanlı yapı, genellikle sinir ağlarının temelini oluşturur ve özellikle derin öğrenme uygulamalarında önemli bir rol oynar. Giriş katmanında alınan veriler, gizli katmanlar tarafından işlenerek daha soyut temsil ve özellikler oluşturulur.

Çıkış katmanı ise bu işlenmiş verileri son kararlar için kullanır. Bu yapı, pek çok farklı yapay sinir ağı türü için temel oluşturur ve tıbbi görüntü analizi, ses tanıma gibi geniş bir yelpazede uygulama alanına sahiptir (O'Shea & Nash, 2015).

CNN'lerde olduğu gibi ANN'ler için de aktivasyon fonksiyonları bu katmanlar arasında kullanılarak modele doğrusal olmayanlık kazandırır, ancak derin ağlarda ReLU gibi fonksiyonlar daha fazla tercih edilir çünkü daha derin ağlarda gradyan problemlerini azaltır (Glorot vd., 2011). Aktivasyon fonksiyonları, modelin daha karmaşık karar sınırları oluşturmasını sağlar.

İleri Yayımlı süreçinde, veriler girişten çıktıya doğru akarken aktivasyon fonksiyonları kullanılır. Ardından Geri Yayımlı (backpropagation) yöntemi ile modelin yaptığı hatalar (loss) hesaplanarak bu hataların ağırlıklara nasıl yansıdığı belirlenir. Bu bilgiyle ağırlıklar güncellenerek modelin öğrenme süreci gerçekleştirilir. Öğrenme oranı ise, bu güncellemelerin büyüklüğünü kontrol eder. Son olarak dropout, normalizasyon gibi teknikler ile de aşırı öğrenme süreci stabilize edilmeye çalışılır. ANN'ler, çok yönlü oldukları için sağlık alanında yapısal veri analizi, electrocardiogram (EKG) sinyal sınıflandırması, hasta tahmin sistemleri gibi birçok alanda kullanılır (Zhang vd., 2020).



2.4. İlaç Geliştirme ve Klinik Araştırmalar


Yeni ilaçların keşif süreci zaman alıcı ve maliyetlidir. YZ bu süreci hızlandırmakta, özellikle moleküler düzeydeki etkileşimlerin modellenmesinde ve klinik araştırmaların planlanmasında kullanılarak maliyetleri düşürmektedir.

Genetik algoritmalar (GA), biyolojik evrimden ilham alınarak çalışan optimizasyon algoritmalarıdır. Her bir birey (kromozom), bir çözüm adayını temsil eder ve parametreleri genler olarak kodlanır. Popülasyon temelli bu algoritmalar, seçim, çaprazlama ve mutasyon gibi mekanizmalarla en uygun çözüm adaylarını üretir (Holland, 1975).


Algoritma, seçim (selection) ile başarılı bireyleri belirler, çaprazlama (crossover) ile genetik çeşitliliği artırır ve mutasyon ile rastgele değişiklikler yaparak çözüm alanını daha iyi keşfeder. Performans, her bireyin sunduğu çözümün kalitesini ölçen bir fitness function ile değerlendirilir. Bu yapı sayesinde GA'lar, çözüm uzayının çok büyük olduğu veya geleneksel yöntemlerle çözülmesi zor olan problemler için oldukça etkilidir. Moleküler etkileşim modellemelerinde yeni bileşiklerin keşfi için kullanılır.

Doğal Dil İşleme (natural language processing-NLP), metin ve dil verilerini analiz etmek için kullanılan bir alandır. Tokenization aşamasında metinler kelime veya alt kelime birimlerine ayrılır. Bu işlem, modelin dilin yapısını öğrenmesine olanak tanır. Ardından, bu kelimeler embedding teknikleriyle sayısal vektörlere dönüştürülür (Word2Vec, GloVe, BERT embedding). Bu özellikleri ile NLP, klinik notlar, bilimsel makaleler gibi büyük miktardaki metin verisini analiz ederek önemli bilgilerin çıkarılmasını sağlar. Bu sayede klinik araştırmalarında öncelikli hipotezlerin oluşturulmasına katkı sağlar (Jurafsky & Martin, 2021). NLP sistemlerinde son yıllarda büyük gelişmeler yaşanmış ve özellikle transformer tabanlı modeller, sağlık verisinin analizinde çığır açmıştır.

Scaled Dot-Product Attention



Multi-Head Attention



Dikkat (attention) mekanizması, özellikle doğal dil işleme modellerinde önemli bir yapıdır ve her bir giriş ögesinin diğer öğelerle olan ilişkisini öğrenerek daha anlamlı bağlam temsilleri oluşturmayı sağlar. Bu mekanizma, modelin hangi bilgilere ne kadar odaklanması gerektiğini öğrenmesini mümkün kılar. Şekil 6'da, temel attention yapısını gösteren bir şema yer almaktadır.

Şekil 6: (sol) Scaled dot-product attention. (sağ) multi-head attention

Şekil 6'nın sol kısmında, Scaled Dot-Product Attention mekanizması gösterilmektedir. İlk olarak giriş vektörleri üç farklı bileşene ayrılır: Query (Q), Key (K) ve Value (V). Dikkat skorları, Query ile Key matrislerinin çarpımıyla hesaplanır. Bu çarpım sonucu elde edilen skorlar, daha stabil gradyanlar elde etmek amacıyla (Key vektörünün boyutu) ile ölçeklenir. Ardından bu skorlar bir softmax fonksiyonuna tabi tutulur, böylece skorlar normalize edilir ve toplamı 1 olacak şekilde dikkat ağırlıkları elde edilir. Son olarak, bu ağırlıklar Value vektörleriyle çarpılarak dikkat çıktısı oluşturulur. Bu yapı, modelin belirli bilgilere odaklanmasını sağlar. Aşağıda matematiksel hesaplaması verilmiştir:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

Yukarıda yer alan Scaled Dot-Product Attention denklemi, giriş verisi üzerindeki ilişkileri hesaplamak için kullanılan temel bir yapıdır. Bu mekanizmada, aynı girişten türetilen Query (Q), Key (K) ve Value (V) vektörleri, farklı öğrenilebilir ağırlık matrisleri aracılığıyla elde edilir. Öncelikle Query ve Key vektörlerinin çarpımı gerçekleştirilerek benzerlik skorları hesaplanır. Ancak bu skorların çok büyük değerlere ulaşmasını ve softmax işleminin dengesiz çalışmasını engellemek için, bu çarpım sonuçları Key vektörlerinin boyutunun karekökü ile ölçeklenir. Ardından softmax fonksiyonu uygulanarak bu skorlar normalize edilir; böylece toplamı 1 olan bir olasılık dağılımı elde edilir. Son adımda ise, bu ağırlıklandırılmış skorlar Value vektörleriyle çarpılarak, dikkat (attention) çıktısı oluşturulur.

Sağ kısmında ise, Multi-Head Attention mekanizması detaylandırılmıştır. Tek bir attention mekanizması yerine, birden fazla (örneğin 8 adet) paralel attention başlığı aynı anda çalıştırılır. Her başlık kendi ağırlıklarıyla farklı Q, K, V projeksiyonları üzerinde scaled dot-product attention uygular. Böylece model, farklı bağlamsal ilişkileri aynı anda yakalayabilir. Her bir başlıktan elde edilen çıktılar birleştirilir (concatenation) ve ardından bir tam bağlı (fully connected) katmana gönderilir. Bu yaklaşım, modelin farklı bilgi alt uzaylarında dikkati öğrenebilmesini sağlayarak daha zengin temsiller üretmesine katkıda bulunur. Aşağıda matematiksel hesaplaması verilmiştir:


$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_n)W^O$$

$$where head_i = Attention(QW_i^Q, KW_i^K, VW_i^V)$$


Yukarıdaki Multi-Head Attention denklemi ise bu mekanizmanın daha zengin bilgi öğrenebilmesi için çoklu başlıklarla (head) çalışmasını sağlar. Bu yapıda, her bir başlık için farklı ağırlık matrisleri kullanılarak ayrı Q, K ve V vektörleri oluşturulur. Her başlık, kendi içerisinde scaled dot-product attention hesaplaması yapar. Tüm başlıkların çıktıları birleştirilir (concatenate) ve ardından son bir ağırlık matrisi ile çarpılarak nihai attention çıktısı elde edilir. Bu sayede model, aynı anda veriyi farklı temsil düzeylerinde inceleyebilir ve daha karmaşık ilişkileri yakalayabilir.

Transformer mimarisi, NLP’de devrim yaratmıştır. 2017 yılında Vaswani ve arkadaşları tarafından önerilmiş olup attention mekanizmasını temel alır ve modelin girdi cümlesinin farklı bölümlerine ne kadar dikkat etmesi gerektiğini öğrenmesini sağlar.

Transformer, geleneksel RNN veya long-short term memory (LSTM) yapılarının sıralı işleme zorunluluğunu ortadan kaldırarak paralel işlemeyi mümkün kılar. Bu mimari, aynı anda tüm giriş dizisini işleyerek hem eğitim sürecini hızlandırır hem de uzun bağımlılıkları daha etkili şekilde yakalayabilir. Yani bu yapı sayesinde, model bir metindeki her kelimenin diğerleriyle olan bağlam ilişkisini paralel biçimde öğrenebilir. Bu, uzun bağlamları anlamada büyük bir avantaj sağlar (Vaswani, 2017). Aşağıda, encoder-decoder yapısına sahip temel bir Transformer mimarisi şematik olarak gösterilmektedir:



Şekil 7. Transformer mimarisi



Şekil 7’de görüldüğü üzere Transformer mimarisi, çok katmanlı encoder ve decoder bloklarından oluşur. Her encoder bloğu, çoklu başlı dikkat (multi-head attention) ve feed-forward katmanlarından oluşurken; decoder blokları da benzer şekilde yapılandırılmıştır ancak encoder-decoder attention katmanını da içerir.

Pozisyonel kodlamalar (positional encodings), sıralı bilgi kaybını önlemek için girişlere eklenir. Bu yapı sayesinde Transformer’lar hem paralel işleme yetenekleri hem de güçlü bağlam modelleme kapasiteleriyle günümüzde pek çok NLP görevinde temel yapıtaşı haline gelmiştir.

Bidirectional encoder representations from transformers (BERT) ve generative pre-trained transformers (GPT) gibi modeller bu yapı üzerine kuruludur ve klinik metinlerin yorumlanmasında oldukça başarılıdır. Örneğin, BERT çift yönlü ağlamadan faydalanarak kelimelerin sağındaki ve solundaki bağlamı birlikte dikkate alır. Bu sayede klinik notlar gibi karmaşık metinlerdeki anlamsal ilişkiler daha doğru analiz edilebilir.

2.5. Hasta Takibi ve Dijital Sağlık Asistanları

Giyilebilir teknolojiler ve mobil sağlık uygulamaları sayesinde hastaların nabız, tansiyon, kan şekeri gibi yaşamsal verileri sürekli izlenebilir hale gelmiştir. Bu verilerin analizinde NLP ve diyalog sistemleri etkin biçimde kullanılmaktadır.

Bu sistemler, hastalarla doğal dil üzerinden etkileşime girerek sorularını cevaplayabilir, sağlık durumlarını analiz edebilir ve gerekli durumlarda alarm oluşturulabilir. NLP teknikleri ile semptomlar yorumlanabilir, geçmiş tıbbi veriler anlamlandırılabilir ve kişiye özel tavsiyeler verilebilir. Ayrıca transformer tabanlı büyük dil modelleri ile güçlendirilmiş sağlık asistanları, hastaların ihtiyaçlarını daha doğru biçimde anlayabilir ve gelişmiş öneriler sunabilir.

Çizelge 1. Yapay zeka modellerinin karşılaştırması

Model/Yöntem	Teknik Avantajları	Sağlık Alanındaki Gücü
CNN	Otomatik özellik çıkarımı, yüksek doğruluk	Tıbbi görüntülerin analizinde yüksek doğruluk
Pekiştirmeli Öğrenme	Gerçek zamanlı öğrenme, belirsizlik altında karar verme yeteneği	Cerrahi robotik sistemlerde dinamik ortam uyumu
Lojistik Regresyon	Hızlı eğitim, parametre yorumlanabilirliği	Hastalık tahmininde yorumlanabilir ve hızlı sonuç üretimi
Destek Vektör Makineleri (SVM)	Kernel fonksiyonları sayesinde doğrusal olmayan sınıflandırma	Küçük örneklemli tıbbi verilerde etkili
ANN	Çok katmanlı yapı, karmaşık örüntü öğrenme	Büyük hasta verilerinde kişiselleştirilmiş tedavi planları
Genetik Algoritmalar	Evrimsel arama stratejisi, global optimumu bulma	İlaç keşfinde moleküler yapıların optimizasyonu
LLM	Metin verisinin anlamsal analizi, transformer temelli modeller	Klinik notlardan bilgi çıkarımı, dijital sağlık asistanları

Yukarıdaki tabloda, her bir modelin teknik avantajlarını ve sağlık sektöründeki uygulama gücünü özetlemektedir. Modellerin seçimi, veri tipi ve uygulama alanına bağlı olarak değişiklik gösterebilir. Ancak tüm bu sistemlerin ortak amacı, sağlık hizmetlerini daha erişilebilir, hızlı ve doğru hale getirmektir.

3. GELECEK PERSPEKTİFİ

Yapay zekânın sağlık alanındaki uygulamaları giderek genişlemekte ve derinleşmektedir. Ancak bu teknolojilerin sağlık hizmetlerine daha etkin ve güvenilir biçimde entegre edilebilmesi için gelecekte çok yönlü araştırmalara ihtiyaç duyulmaktadır.

Öncelikli olarak, yapay zekâ sistemlerinin karar verme süreçlerinin daha şeffaf ve anlaşılır hâle getirilmesi gerekmektedir. Özellikle klinik uygulamalarda, modellerin yalnızca doğru sonuçlar üretmesi değil, aynı zamanda bu sonuçları nasıl ve neden ürettiğinin de açıkça ortaya konulması önem taşımaktadır. Açıklanabilir ve yorumlanabilir yapay zekâ yöntemlerinin geliştirilmesi hem sağlık profesyonellerinin hem de hastaların bu teknolojilere olan güvenini artıracaktır.



Bunun yanında, sağlık verilerinin çeşitliliği ve temsil adaleti önemli bir diğer çalışma alanıdır. Mevcut birçok yapay zekâ modeli sınırlı popülasyonlardan elde edilen verilerle eğitilmekte, bu da genelleme yeteneklerini sınırlayabilmektedir. Farklı yaş grupları, etnik kökenler ve sosyoekonomik düzeylerden gelen bireyleri kapsayan daha dengeli veri kümelerinin oluşturulması, geliştirilen sistemlerin tüm toplum kesimlerine adil şekilde hizmet sunmasını sağlayacaktır.

Veri gizliliği ve güvenliği de önümüzdeki dönemde daha fazla önem kazanacaktır. Sağlık verilerinin hassasiyeti göz önünde bulundurulduğunda, yapay zekâ sistemlerinin mahremiyeti koruyacak yöntemlerle geliştirilmesi ve uygulanması kritik bir gerekliliktir. Özellikle merkezi olmayan, veri paylaşımını minimize eden yaklaşımlar üzerinde durulması beklenmektedir. Gelecekte ayrıca, çok modlu veri kaynaklarını (görüntü, sinyal, metin vb.) bir arada kullanabilen yapay zekâ modellerinin geliştirilmesi de önemli bir odak noktası olacaktır. Klinik karar süreçleri çok farklı veri türlerinin birlikte değerlendirilmesini gerektirdiği için, bu tür entegre sistemlerin sağlık hizmetlerinde doğruluk ve etkinliği artıracağı öngörülmektedir.

Son olarak, yapay zekâ teknolojilerinin sadece teknik açıdan geliştirilmesi yeterli olmayacaktır; bu sistemlerin sağlık profesyonellerinin eğitim süreçlerine de entegre edilmesi gerekmektedir. Hekimlerin yapay zekâ destekli araçları doğru bir şekilde yorumlayıp kullanabilmeleri için gerekli bilgi ve becerilerle donatılması, bu teknolojilerin klinik pratikte başarılı bir şekilde uygulanmasının ön koşuludur.

Özetle, yapay zekânın sağlık alanındaki geleceği büyük fırsatlar barındırmakla birlikte, bu fırsatların sorumlu, adil ve güvenli bir şekilde hayata geçirilmesi için disiplinler arası iş birliklerine ve bütüncül yaklaşımlara ihtiyaç duyulmaktadır.

4. GİZLİLİK VE ETİK

Yapay zekânın sağlık hizmetlerine entegrasyonu, önemli etik ve gizlilik kaygılarını da beraberinde getirmiştir. Sağlık verileri, kişisel mahremiyet açısından en hassas veri türlerinden biri olup, bu bilgilerin işlenmesi ve paylaşımı sürecinde yüksek düzeyde özen ve sorumluluk gerekmektedir (Goodman, 2020). YZ sistemlerinin veri güvenliğini sağlamak amacıyla gelişmiş şifreleme yöntemleri ve anonimleştirme teknikleri kullanması zorunludur. Ancak anonimleştirilen verilerin bile ileri analiz teknikleriyle yeniden tanımlanabileceği gösterilmiştir; bu durum, veri koruma stratejilerinin sürekli olarak güncellenmesini ve sıkı yasal düzenlemelerle desteklenmesini gerekli kılmaktadır (Shokri & Shmatikov, 2015).

Bununla birlikte, YZ sistemlerinde karar verme süreçlerinin şeffaf olmaması, sağlık alanında ciddi etik sorunlar doğurmaktadır. "Kara kutu" olarak tanımlanan bu yapılar, hem hekimlerin hem de hastaların sistemlere olan güvenini zedeleyebilmekte, alınan kararların gerekçelendirilmesini güçleştirmektedir (Lipton, 2016).

Sağlık hizmetlerinde güvenin temel bir unsur olduğu düşünüldüğünde, yapay zekâ modellerinin açıklanabilirliğini artırmaya yönelik çalışmaların önemi daha da artmaktadır. Ayrıca, YZ sistemlerinde algoritmik önyargıların varlığı da etik bir tehdit oluşturmaktadır. Özellikle eğitim verilerinde yer alan ırksal, cinsiyete dayalı veya sosyoekonomik eşitsizlikler, modellerin belirli gruplara karşı sistematik hatalı kararlar üretmesine yol açabilir (Buolamwini & Gebru, 2018).

Stanford Üniversitesi'nde yapılan bir çalışmada, tıbbi sohbet robotlarının azınlık gruplara yönelik ayrımcı söylemler üretebildiği gösterilmiştir; bu durum, veri setlerinin çeşitliliğinin artırılması ve model geliştirme sürecinde etik gözetimin sağlanmasının zorunluluğunu vurgulamaktadır (Williams vd., 2023).

Hasta mahremiyeti konusu da sağlıkta yapay zekâ uygulamalarının merkezinde yer almaktadır. Kişisel sağlık bilgilerinin toplanması, işlenmesi ve saklanması süreçlerinde bilgilendirilmiş onam ilkesine sıkı sıkıya bağlı kalınması gerekmektedir (Goodman, 2020). Hastaların verilerinin nasıl kullanılacağı ve kimlerle paylaşılacağı konusunda açık ve anlaşılır bilgilendirme yapılması, hem etik bir yükümlülük hem de yasal bir gerekliliktir.



Tüm bu etik ve gizlilik sorunlarının etkin bir şekilde yönetilebilmesi için disiplinler arası iş birliklerine ihtiyaç vardır. Sağlık bilişimi, hukuk, etik ve yapay zekâ mühendisliği gibi alanların uzmanları birlikte çalışarak, şeffaflık, adalet, hesap verebilirlik ve güvenlik ilkelerine dayalı düzenleyici çerçeveler geliştirmelidir (Topol, 2019). Ayrıca, uluslararası standartlar doğrultusunda etik denetim mekanizmalarının oluşturulması, YZ sistemlerinin insan haklarına saygılı bir biçimde sağlık alanına entegre edilmesini kolaylaştıracaktır.

Sonuç olarak, yapay zekânın sağlık alanındaki potansiyelinden tam anlamıyla yararlanılabilmesi için, güvenlik tehditleri ve etik risklerin ciddiyetle ele alınması ve bu alanlarda sürekli iyileştirme çabalarının sürdürülmesi elzemdir. Etik ilkelere bağlı, şeffaf ve adil yapay zekâ uygulamaları hem bireysel hasta güvenliğini hem de toplum sağlığını koruyarak sağlık hizmetlerinde sürdürülebilir bir dönüşümün önünü açacaktır.

5. SONUÇLAR

Yapay zekâ, sağlık sektöründe yalnızca teknolojik bir gelişme değil, aynı zamanda sağlık hizmetlerinin sunum şeklini köklü biçimde dönüştüren bir paradigma değişimidir. Tanı koyma süreçlerinden tedavi planlamasına, hasta takibinden kaynak yönetimine kadar birçok alanda etkili olan bu teknolojiler, sağlık sistemlerinin verimliliğini ve kalitesini artırmakta büyük rol oynamaktadır. Özellikle yapay zekâ destekli görüntü işleme sistemleri, radyoloji gibi alanlarda doktorlara daha hassas ve hızlı kararlar alma imkânı tanırken, doğal dil işleme uygulamaları hasta kayıtlarının analizinde büyük kolaylık sağlamaktadır. Bununla birlikte, biyosinyal analizi ve uzaktan hasta izleme sistemleri sayesinde hastalıkların erken teşhisi mümkün hale gelmiş, kronik hastalıkların takibi kolaylaşmıştır.

Yapay zekânın sunduğu bu olanaklar, sadece hekimlerin karar verme süreçlerini iyileştirmekle kalmamakta; aynı zamanda hastaların sağlık hizmetlerine erişimini artırarak bireyselleştirilmiş sağlık çözümleri sunmaktadır. Kişiye özel tedavi planlarının geliştirilmesi, hasta memnuniyetini ve tedavi başarısını önemli ölçüde yükseltmektedir. Bu gelişmeler, özellikle sağlık hizmetlerine erişimin sınırlı olduğu bölgelerde büyük önem taşımaktadır.

Ancak yapay zekânın sağlık alanında yaygınlaşması beraberinde bazı zorlukları da getirmektedir. Mahremiyetin korunması, veri güvenliği, algoritmik önyargılar ve şeffaflık gibi konular, bu teknolojilerin etik ve güvenli kullanımı açısından titizlikle ele alınmalıdır. Ayrıca, sağlık profesyonellerinin bu teknolojilere uyum sağlaması, gerekli eğitimleri alması ve yapay zekâ sistemlerini etkin bir şekilde kullanabilmesi için kapsamlı altyapı yatırımları ve politikalar gereklidir.

Tüm bu unsurlar göz önünde bulundurulduğunda, yapay zekâ destekli sağlık sistemleri gelecekte çok daha kapsamlı, etkili ve insana odaklı bir sağlık hizmeti sunma potansiyeline sahiptir. Teknolojinin insan sağlığıyla buluştuğu bu noktada, hem hasta hem sağlık çalışanı açısından daha erişilebilir, güvenli ve sürdürülebilir bir sağlık sistemi inşa etmek mümkün hale gelmektedir.

6. KAYNAKÇA

- Esteva, A. et al. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24–29.
- Topol, E. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25, 44–56.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60–88.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT Press.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237–285.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. John Wiley & Sons.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273–297.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep sparse rectifier neural networks. In *AISTATS*.
- Zhang, Y. et al. (2020). Deep learning in echocardiography: A review. *Knowledge-Based Systems*, 188, 105006.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems*. University of Michigan Press.
- Jurafsky, D., & Martin, J. H. (2021). *Speech and language processing*. Pearson.

- Vaswani, A., et al. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118.
- Axios. (2025). University of Pittsburgh, Leidos team up to address health equity with AI.
- BMC Medical Education. (2024). The integration of artificial intelligence into medical education: A review of recent developments. *BMC Medical Education*, 24, Article 112.
- Buolamwini, J., & Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. *Proceedings of the 1st Conference on Fairness, Accountability and Transparency*, 81, 77–91.
- Goodman, B. (2020). Ethical challenges of machine learning in healthcare. *Journal of Ethics in Health Informatics*, 15(2), 45–56.
- Lekadir, K., Litjens, G., & Marti, R. (2023). Artificial intelligence in medical imaging: Current status and future directions. *Nature Reviews Biomedical Engineering*, 1(1), 1–14.
- Lipton, Z. C. (2016). The mythos of model interpretability. *arXiv preprint arXiv:1606.03490*.
- MDPI. (2023). Artificial Intelligence in Healthcare: Opportunities and Challenges. *Journal of Personalized Medicine*, 13(4), Article 523.
- Topol, E. (2019). *Deep medicine: How artificial intelligence can make healthcare human again*. Basic Books.
- Williams, B., Nouri, S., & Kim, D. (2023). Algorithmic bias in AI-powered health chatbots: A racial equity perspective. *Journal of Biomedical Informatics*, 135, 104295.
- Zhang, Y., Wang, J., & Lee, D. (2024). Cybersecurity risks of connected medical devices: A systematic review. *Computers & Security*, 134, 103158.