



ANKARA
HACI BAYRAM VELİ ÜNİVERSİTESİ
UZAKTAN EĞİTİM UYGULAMA VE
ARAŞTIRMA MERKEZİ

YAPAY ZEKÂ TEKNOLOJİLERİ VE YÖNETİMİ

2. YAPAY ZEKÂ UYGULAMALARI

2.1. Uzman Sistemler

Uzman Sistemler, belirli bir alanda insan uzmanlarının bilgi ve deneyimlerini simüle eden yapay zeka sistemleridir. Bu sistemler, belirli bir uzmanlık alanındaki kararları desteklemek ve sorunları çözmek için tasarlanmışlardır. Uzman sistemler, genellikle iki ana bileşenden oluşur: bir bilgi tabanı ve bir çıkarım motoru. Bilgi tabanı, uzmanlık alanındaki kuralları, verileri ve bilgileri içerirken, çıkarım motoru bu bilgileri kullanarak belirli problemleri çözmek için mantıksal çıkarımlar yapar. Bu yapılar, uzmanların bilgi ve tecrübelerini sistematik bir biçimde kodlayarak, kullanıcılara profesyonel seviyede önerilerde bulunabilir ve karar alma süreçlerini destekler.

Uzman sistemler, tıp, mühendislik, finans ve hukuk gibi çeşitli alanlarda uygulanabilir. Örneğin, tıp alanında bir uzman sistem, hastaların semptomlarına ve test sonuçlarına dayanarak olası hastalıkları teşhis edebilir ve tedavi önerileri sunabilir. Mühendislikte ise, bir uzman sistem, tasarım problemlerini çözebilir veya bakım gereksinimlerini belirleyebilir. Finans sektöründe, uzman sistemler, yatırım stratejileri oluşturma ve risk analizi yapma gibi görevlerde kullanılabilir.

Bu sistemler, özellikle bilgi tabanlı ve tekrarlanan kararlar gerektiren durumlarda oldukça etkili olabilir. Ancak, uzman sistemlerin sınırlamaları da vardır. Bilgi tabanı genellikle belirli bir alanla sınırlı olduğu için, sistemin bilgi kapsamı dışında kalan durumlarda etkili olamayabilir. Ayrıca, bilgi tabanındaki güncellemeler ve genişletmeler, sistemin sürekli olarak güncel ve doğru kalmasını gerektirir. Uzman sistemler, insan uzmanlarının bilgi ve deneyimlerini dijital bir formata dönüştürerek, geniş bir kullanıcı kitlesine erişim sağlama potansiyeline sahiptir, ancak sınırlı esneklikleri ve bilgi tabanı bağımlılıkları nedeniyle, dinamik ve belirsiz ortamlarda zorluklar yaşanabilir.

Son yıllarda, uzman sistemler, yapay zeka ve makine öğrenmesi gibi daha dinamik ve adaptif yaklaşımlarla entegre edilmiştir. Bu entegrasyon, sistemlerin daha geniş veri kümeleri ile öğrenmelerine ve adaptif hale gelmelerine olanak tanır, böylece uzman sistemlerin sınırlamalarını aşmalarına ve daha kapsamlı ve etkili çözüm önerileri sunmalarına yardımcı olur. Bu gelişmeler, uzman sistemlerin potansiyelini artırarak, çeşitli endüstrilerde daha akıllı ve uyumlu çözümler sunmalarını sağlamaktadır.

2.2. Makine Öğrenmesi

Makine öğrenmesi, bilgisayarların deneyimlerinden öğrenme ve performanslarını iyileştirme yeteneğini geliştiren bir yapay zeka dalıdır. Makine öğrenmesi, bilgisayar sistemlerinin verilerden öğrenmelerine ve bu öğrenmelerini kullanarak belirli görevlerde daha iyi sonuçlar elde etmelerine olanak tanır. Bu süreç, algoritmalar ve istatistiksel modeller kullanılarak gerçekleştirilir.

Makine öğrenmesinin uygulama alanları oldukça geniştir ve sağlık, finans, pazarlama, ulaşım ve daha birçok sektörde önemli rol oynar. Örneğin, sağlık sektöründe, makine öğrenmesi algoritmaları hastalıkların erken teşhisinde ve kişiselleştirilmiş tedavi planlarının geliştirilmesinde kullanılabilir. Finans sektöründe, dolandırıcılık tespiti ve risk yönetimi gibi görevlerde etkili olabilir. Ayrıca, makine öğrenmesi, müşteri davranışlarını analiz etme, öneri sistemleri oluşturma ve doğal dil işleme gibi alanlarda da geniş bir kullanım yelpazesi sunar. Bu teknolojinin sürekli gelişimi, daha doğru tahminler ve daha etkili çözümler sağlama potansiyelini artırmaktadır.

Makine öğrenmesi genellikle üç ana kategoriye ayrılır: denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve takviye öğrenme (reinforcement learning).

2.2.1 Denetimli Öğrenme

Denetimli öğrenme, makine öğrenmesinde kullanılan bir yöntem olup, modelin belirli bir görevi öğrenmesi için etiketlenmiş veri setleri kullanır. Bu süreçte, model, giriş verileri ve bu verilerle ilişkili doğru sonuçlar (etiketler) içeren bir eğitim seti ile eğitilir. Model, bu eğitim verilerini analiz ederek, giriş-veri ilişkisini öğrenir ve ardından yeni, etiketlenmemiş veriler üzerinde tahminlerde bulunma yeteneği kazanır. Denetimli öğrenme, sınıflandırma (örneğin, e-posta spam filtresi) ve regresyon (örneğin, bir evin değerini tahmin etme) gibi çeşitli uygulamalarda kullanılır. Bu yöntem, doğruluğu yüksek tahminler yapmak ve sistematik olarak problem çözmek için geniş bir veri tabanına ihtiyaç duyar.

2.2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, makine öğrenmesinde verilerin etiketlenmediği durumlarda kullanılan bir yöntemdir. Bu yöntemde, model, yalnızca giriş verileriyle çalışır ve bu verilerden yapısal bilgileri veya desenleri keşfetmeye çalışır. Denetimsiz öğrenme, veriler arasındaki ilişkileri anlamak ve gruplama, boyut indirgeme veya özetleme gibi görevleri yerine getirmek için

kullanılır. Örneğin, kümelenme algoritmaları (k-means, hiyerarşik kümelenme) verileri benzerliklerine göre gruplandırarak, veri içindeki doğal kümeleri belirlemeye çalışır. Ayrıca, boyut indirgeme teknikleri (PCA, t-SNE) verinin karmaşıklığını azaltarak, daha anlamlı ve anlaşılır bir temsil sağlar. Denetimsiz öğrenme, etiketlenmiş veri olmadan veri yapılarının keşfi ve veri analizi için önemli bir araçtır.

2.2.3 Takviyeli Öğrenme

Takviyeli öğrenme, makine öğrenmesinde, bir ajanın çevresiyle etkileşime girerek ve ödül veya ceza alarak öğrenmesini sağlayan bir yaklaşımdır. Bu yöntemde, ajan, bir dizi eylemi denemek ve çevresinden geri bildirim almak suretiyle en iyi stratejiyi öğrenir. Her eylem sonucunda, ajan bir ödül veya ceza alır ve bu geri bildirim, gelecekteki eylemlerini iyileştirmek için kullanılır. Takviyeli öğrenme, oyun oynama, robot kontrolü, öneri sistemleri ve otonom araçlar gibi alanlarda etkili bir şekilde kullanılabilir. Ajan, öğrenme sürecinde, uzun vadeli ödülleri maksimize etmeye çalışırken, genellikle keşif ve sömürü arasında bir denge kurar. Bu yöntem, öğrenme sürecinde başarılı stratejiler geliştirmek için sürekli olarak çevresel verileri analiz eder ve optimize eder.

2.3. Yapay Sinir Ağları

Yapay sinir ağları, biyolojik sinir sistemlerinin işleyişini taklit eden bir yapay zeka modelidir ve özellikle karmaşık veri ilişkilerini öğrenme ve modelleme yeteneği ile bilinir. Bir yapay sinir ağı, bir dizi birbirine bağlı "nöron"dan oluşur. Bu nöronlar, genellikle üç ana katmandan oluşur: giriş katmanı, gizli katmanlar ve çıkış katmanı. Giriş katmanı, verileri ağına sunar; gizli katmanlar, verileri işleyip, özellikleri öğrenir; ve çıkış katmanı, işlenmiş bilgileri sonuç olarak sunar. Her bağlantı, nöronlar arasındaki etkileşimleri temsil eder ve bu bağlantılara "ağırlık" atanır, bu ağırlıklar öğrenme sürecinde güncellenir.

Yapay sinir ağları, öğrenme sürecinde verileri ağırlıklar ve aktivasyon fonksiyonları aracılığıyla işler. Eğitim sırasında, model, verilerden öğrenme yaparak ağırlıkları günceller ve sonuçları doğruluk açısından optimize eder. Bu süreç genellikle geri yayılım algoritması (backpropagation) kullanılarak gerçekleştirilir. Geri yayılım, hata hesaplamaları yaparak ve bu hatayı ağırlıklara geri yayarak modelin öğrenmesini sağlar. Sinir ağları, bu şekilde, verilen veri setine uygun bir model oluşturur ve gelecekteki veriler üzerinde tahminlerde bulunabilir.

Yapay sinir ağları, özellikle büyük veri setleri ve güçlü hesaplama kaynakları ile etkili bir şekilde performans gösterebilir. Ancak, bu

ağların eğitimi ve optimizasyonu genellikle yüksek hesaplama gücü ve uzun süreli işlem süreleri gerektirebilir. Ayrıca, sinir ağlarının "kara kutu" doğası, içsel çalışma mekanizmalarının ve karar alma süreçlerinin anlaşılmasını zorlaştırabilir. Bu nedenle, sinir ağlarının sonuçlarını açıklamak ve yorumlamak, araştırmacılar ve mühendisler için önemli bir zorluk olmaya devam etmektedir.

2.4. Derin Öğrenme

Derin öğrenme, yapay sinir ağlarının genişletilmiş ve derinleştirilmiş bir versiyonudur ve genellikle çok sayıda gizli katman içeren sinir ağlarını ifade eder. Derin öğrenme, bu derin yapılar sayesinde, verilerdeki karmaşık ve soyut ilişkileri öğrenme yeteneğine sahiptir. Derin sinir ağları, özellikle büyük veri setleri ve yüksek hesaplama gücü ile etkili sonuçlar elde edebilir. Bu yöntem, görüntü tanıma, ses işleme, doğal dil işleme ve oyun oynama gibi alanlarda önemli başarılar elde etmiştir. Derin öğrenme, çok katmanlı yapıları sayesinde, verilerin her seviyesinde özellikleri ve desenleri öğrenme kapasitesine sahiptir.

Derin öğrenme ağları, genellikle konvolüsyonel sinir ağları (Convolutional Neural Networks - CNNs) ve tekrarlayan sinir ağları (Recurrent Neural Networks - RNNs) gibi özel yapılandırmalar içerir. Konvolüsyonel sinir ağları, özellikle görüntü verilerini işlemek için kullanılır ve verilerin yerel özelliklerini öğrenmekte etkilidir. Bu ağlar, görüntülerdeki kenarları, köşeleri ve diğer temel özellikleri tanımak için konvolüsyon işlemleri uygular. Tekrarlayan sinir ağları ise zaman serisi verileri veya doğal dil işleme gibi sıralı verilerle çalışmak için tasarlanmıştır. Bu ağlar, önceki zaman adımlarındaki bilgileri kullanarak mevcut zaman adımındaki verileri işler.

Derin öğrenme, verileri yüksek seviyeli soyutlamalarla işleme kapasitesine sahip olduğu için, bu yöntemle elde edilen modeller genellikle daha doğru ve etkili sonuçlar verir. Örneğin, derin öğrenme kullanılarak geliştirilen görüntü tanıma sistemleri, insan gözünden bile daha hassas sonuçlar elde edebilir. Ancak, derin öğrenme ağlarının eğitimi büyük miktarda veri ve yüksek hesaplama gücü gerektirir. Bu nedenle, güçlü grafik işlemci birimleri (GPU'lar) ve özel donanımlar, derin öğrenme projelerinde yaygın olarak kullanılır.

Bir diğer zorluk, derin öğrenme modellerinin "kara kutu" doğasıdır; yani, bu modellerin içsel çalışma mekanizmalarını

anlamak ve sonuçların neden böyle olduğunu açıklamak zor olabilir. Bu durum, modelin karar alma süreçlerini yorumlamayı ve güvenilirliğini değerlendirmeyi zorlaştırabilir. Derin öğrenme araştırmaları, bu zorlukları aşmak için model şeffaflığı ve açıklanabilirlik gibi konulara da odaklanmaktadır. Genel olarak, derin öğrenme, karmaşık veri setleri ile başa çıkabilen güçlü bir araçtır ve yapay zeka alanındaki birçok yeniliğin temelini oluşturur.

2.5. Genetik Algoritma

Genetik algoritma, evrimsel biyolojiden esinlenerek geliştirilmiş bir optimizasyon ve arama algoritmasıdır. Genetik algoritmalar, çözümler popülasyonlarını genetik prensiplere dayalı olarak evrimleştirir ve bu süreçte "seçilim", "çaprazlama" ve "mutasyon" gibi genetik operatörleri kullanır. Temel olarak, bu algoritmalar, başlangıçta rastgele oluşturulan bir çözüm havuzuyla başlar ve her bir çözümün (birey) kalitesini değerlendirir. Daha sonra, daha iyi performans gösteren bireyler seçilir, çaprazlama (iki bireyi birleştirerek yeni bireyler oluşturma) ve mutasyon (bireylerin rastgele değiştirilmesi) işlemleri uygulanarak yeni bir popülasyon oluşturulur. Bu süreç, popülasyonun zamanla daha iyi çözümler üretmesini sağlar.

Genetik algoritmalar, karmaşık ve büyük çözüm uzaylarında etkili bir şekilde çalışabilir ve birçok farklı uygulama alanında kullanılır. Örneğin, genetik algoritmalar, mühendislik tasarım problemlerinde, optimizasyon görevlerinde, yapay zeka oyunlarında ve hatta finansal modelleme gibi alanlarda kullanılabilir. Bu algoritmalar, hem sürekli hem de ayrık problemlerde iyi performans gösterebilir ve çok sayıda çözüm alternatifi sunarak, global optimuma ulaşma olasılığını artırır. Ancak, genetik algoritmaların performansı, genellikle parametre ayarlarına ve problemin doğasına bağlıdır. Yine de, genetik algoritmaların evrimsel süreçlere dayalı yaklaşımları, karmaşık problemlere yaratıcı çözümler bulmada güçlü bir araç olarak kabul edilir.

2.6. Doğal Dil İşleme

Doğal Dil İşleme (NLP), bilgisayarların insan dilini anlaması, işlemesi ve üretmesi amacıyla geliştirilen yapay zeka tekniklerinin bir alanıdır. NLP, dilin çeşitli yönlerini analiz eden ve anlayan algoritmalar ve modeller kullanır; bu, dilin anlamını, yapısını ve bağlamını anlamayı içerir. NLP, metin ve konuşma verilerini analiz ederek, bilgi çıkarımı, duygu analizi, dil çevirisi, metin özetleme ve sorulara yanıt verme gibi görevleri gerçekleştirebilir. Bu

alandaki teknolojiler, metin tabanlı verilerle etkileşim kurma ve insan benzeri dil anlayışını simüle etme yeteneği ile geniş bir uygulama yelpazesine sahiptir.

NLP'nin temel bileşenleri arasında morfo-sentaktik analiz, anlam analizi ve bağlam analizi bulunur. Morfo-sentaktik analiz, dilin yapısal yönlerini, kelime türlerini ve dilbilgisel kuralları inceler. Anlam analizi, kelimelerin ve cümlelerin anlamını belirlemeye çalışır ve bağlam analizi, dilin kullanıldığı bağlamı anlamayı hedefler. Bu analizler, dilin çeşitli yönlerini anlamak ve işlemek için gereklidir ve genellikle makine öğrenmesi ve derin öğrenme teknikleri ile desteklenir.

Son yıllarda, derin öğrenme tabanlı modeller, NLP'nin ilerlemesinde büyük bir rol oynamıştır. Özellikle, transformer tabanlı modeller (örneğin, BERT, GPT) dil anlama ve üretme konularında devrim yaratmıştır. Bu modeller, büyük veri kümeleri üzerinde eğitim alarak dilin daha derin ve bağlamsal yönlerini öğrenebilir. Transformer mimarileri, metinlerin ve konuşmaların anlamını ve ilişkilerini daha iyi anlamak için kullanılır ve dil görevlerinde yüksek başarı oranları sağlar.

NLP'nin uygulama alanları geniş bir yelpazeyi kapsar. Arama motorları, sesli asistanlar, metin analizi, duygu analizi, dil çevirisi ve sohbet robotları gibi teknolojiler, NLP'nin sağladığı avantajlardan yararlanır. Ancak, NLP'nin zorlukları arasında dilin çok anlamlılığı, bağlamın karmaşıklığı ve kültürel farklılıklar gibi faktörler yer alır. Bu zorluklarla başa çıkmak için sürekli araştırma ve gelişmeler yapılmakta ve NLP'nin potansiyeli genişlemektedir.

2.7. Bilgisayarlı Görü

Bilgisayarlı görü, bilgisayarların ve yapay zeka sistemlerinin görüntüleri analiz etme ve anlamlandırma yeteneğini geliştiren bir yapay zeka alanıdır. Bu alan, görüntü işleme ve analiz tekniklerini kullanarak, bilgisayarların fotoğraflar, videolar ve diğer görsel veriler üzerinden bilgi çıkarabilmesini sağlar. Bilgisayarlı görü, nesne tanıma, yüz tanıma, görüntü segmentasyonu ve hareket analizi gibi görevlerde kullanılır. Bu teknolojiler, bir görüntüdeki nesneleri, desenleri ve diğer önemli bilgileri tanımlamak ve bu bilgileri anlamlı veriler haline getirmek için gelişmiş algoritmalar ve modeller kullanır.

Bilgisayarlı görü, genellikle derin öğrenme teknikleriyle desteklenir. Özellikle, konvolüsyonel sinir ağları (CNN'ler), görüntülerin analizinde büyük başarı sağlamıştır. CNN'ler, görüntülerdeki temel özellikleri (örneğin kenarlar, köşeler) algılayarak daha karmaşık desenleri ve nesneleri tanımak için

kullanılabilir. Derin öğrenme modelleri, büyük veri setleri üzerinde eğitildiğinde, yüksek doğruluk ve hassasiyetle görüntüleri işleyebilir ve çeşitli uygulamalarda etkili sonuçlar elde edebilir.

Bilgisayarlı görü, sağlık, güvenlik, otomotiv ve tüketici teknolojileri gibi birçok alanda geniş uygulama alanlarına sahiptir. Örneğin, sağlık sektöründe, bilgisayarlı görü teknolojileri, medikal görüntülerde hastalıkları teşhis etmek ve tedavi planlarını geliştirmek için kullanılabilir. Güvenlik alanında, yüz tanıma sistemleri, kişilerin kimliklerini doğrulamak için uygulanabilir. Otomotiv sektöründe, otonom araçlarda çevreyi algılamak ve güvenli sürüş sağlamak amacıyla kullanılır. Bu teknoloji, sürekli olarak gelişmekte ve daha fazla uygulama ve iyileştirme sağlamak için araştırmalar yapılmaktadır.

KAYNAKÇA

- Russell, S. J., & Norvig, P. (2016). Artificial intelligence: a modern approach. Pearson.
- Burkov, A. (2019). The hundred-page machine learning book (Vol. 1, p. 32).
- Quebec City, QC, Canada: Andriy Burkov.
- Smola, A. (2008). Introduction to machine learning. Link: <https://alex.smola.org/drafts/thebook.pdf>

BÖLÜM SORULARI

- 1) Uzman sistemlerin temel işlevi nedir ve hangi alanlarda kullanılır?
- 2) Makine öğreniminin uygulama alanlarından birkaçını ve bu alanlardaki faydalarını açıklayınız.
- 3) Yapay sinir ağları ve derin öğrenme arasındaki fark nedir?
- 4) Derin öğrenmenin veri desenlerini anlama ve öğrenme kapasitesi neden yüksektir?
- 5) Doğal dil işleme (NLP) teknolojilerinin günümüzdeki bazı pratik uygulamalarını açıklayınız.