



**2024
NOBEL FİZİK ÖDÜLÜ
SAHİPLERİNİ BULDU!**

Özge Altıntaş ve Dr. Adil DENİZLİ

Hacettepe Üniversitesi, Kimya Bölümü, Beytepe, Ankara

**İSVEÇ KRALİYET BİLİMLER AKADEMİSİ,
2024 NOBEL FİZİK ÖDÜLÜ'NÜ;
“MAKİNE ÖĞRENMESİNİ YAPAY
SİNİR AĞLARIYLA MÜMKÜN KILAN
TEMEL KEŞİF VE İCATLAR” İÇİN
JOHN J. HOPFIELD'A
VE
GEOFFREY E. HINTON'A
VERME KARARI ALDI.**




JOHN J. HOPFIELD

1933 yılında Chicago, IL, ABD’de doğdu. 1958 yılında Cornell Üniversitesi, Ithaca, NY, ABD’den doktora derecesini aldı. Princeton Üniversitesi’nde profesör olarak görev yapmaktadır.

GEOFFREY E. HINTON

1947 yılında Londra, Birleşik Krallık’ta doğdu. 1978 yılında Edinburgh Üniversitesi, Birleşik Krallık’tan doktora derecesini aldı. Toronto Üniversitesi, Kanada’da profesör olarak görev yapmaktadır.






FİZİK KULLANARAK BİLGİDEKİ DESENLERİ BULDULAR

Bu yılki ödül sahipleri, günümüzün güçlü makine öğrenmesinin temelini atmaya yardımcı olan yöntemler geliştirmek için fizik alanından araçlar kullanmıştır. John Hopfield, bilgiyi depolayabilen ve yeniden yapılandırabilen bir yapı geliştirmiştir. Geoffrey Hinton ise verideki özellikleri bağımsız olarak keşfedebilen ve şu anda kullanılan büyük yapay sinir ağları için önemli hale gelmiş bir yöntem icat etmiştir.

Birçok kişi, bilgisayarların diller arasında çeviri yapabildiğini, görüntüleri yorumlayabildiğini ve hatta makul diyaloglar kurabildiğini deneyimlemiştir. Ancak, bu tür teknolojilerin uzun zamandır araştırmalarda, büyük miktarda veriyi sıralama ve analiz etmede önemli olduğu belki de daha az bilinen bir gerçektir. Son on beş ila yirmi yıl içinde makine öğrenmesi büyük bir gelişim göstermiş ve yapay sinir ağı adı verilen bir yapıdan yararlanmıştır. Günümüzde yapay zekâdan bahsederken genellikle bu tür bir teknolojiyi kastediyoruz. Bilgisayarlar düşünemeseler de artık bellek ve öğrenme gibi işlevleri taklit edebilmektedir. Bu yılki fizik ödülü sahipleri, bunu mümkün kılmaya

yardımcı olmuştur. Fizikteki temel kavramlar ve yöntemler kullanarak, bilgiyi işlemek için ağ yapılarını kullanan teknolojiler geliştirmişlerdir. Makine öğrenmesi, geleneksel yazılımdan farklıdır; geleneksel yazılım bir tarif gibi çalışır. Yazılım, veriyi alır, net bir açıklamayagöre işler ve bir sonuç üretir, tıpkı birinin malzemeleri toplaması ve bir tarifi takip ederek bir kek yapması gibi. Bunun yerine, makine öğrenmesinde bilgisayar örneklerden öğrenir, böylece adım adım talimatlarla yönetilemeyecek kadar belirsiz ve karmaşık sorunlarla başa çıkabilir. Bir örnek, bir resimdeki nesneleri tanımlamak için görüntüyü yorumlamaktır.



BEYİNİ TAKLİT EDİYOR

Yapay bir sinir ağı, bilgiyi tüm ağ yapısını kullanarak işler. Bu alandaki ilk ilham kaynağı, beynin nasıl çalıştığını anlama isteğiydi. 1940'larda araştırmacılar, beynin nöronlar ve sinapslar arasındaki bağlantılardan oluşan ağını matematiksel açıdan anlamaya çalışmaya başladılar. Bu yapbozun bir diğer parçası ise, sinirbilimci Donald Hebb'in, bir-


likte çalışan nöronlar arasındaki bağlantıların güçlenmesiyle öğrenmenin gerçekleştiğine dair hipotezi sayesinde psikolojiden geldi. Daha sonra, beynin ağı nasıl işliyorsa, onu yapay sinir ağları olarak bilgisayar simülasyonlarıyla yeniden yaratma girişimleri ortaya çıktı. Bu sistemlerde, beynin nöronları, farklı değerler atanan düğümlerle taklit edilirken, sinapslar ise düğümler arasındaki bağlantılarla temsil edilir ve bu bağlantılar güçlendirilebilir veya zayıflatılabilir. Donald Hebb'in hipotezi, bugün hâlâ yapay ağları güncelleme sürecinde kullanılan temel kural-

lardan biri olarak kabul edilmektedir; bu sürece "eğitim" adı verilir.


1960'ların sonlarına doğru, bazı olumsuz teorik sonuçlar birçok araştırmacının bu sinir ağlarının gerçek bir yararı olmayacağına inanmasına neden oldu. Ancak 1980'lerde, aralarında bu yılki ödül sahiplerinin de bulunduğu önemli isimlerin çalışmalarıyla birkaç önemli fikir öne çıktı ve yapay sinir ağlarına olan ilgi yeniden canlandı.

Doğal ve yapay nöronlar

Beynin sinir ağı, gelişmiş iç mekanizmaya sahip canlı hücreler olan nöronlardan oluşur. Bu nöronlar, sinapslar yoluyla birbirlerine sinyaller gönderebilirler. Bir şeyler öğrendiğimizde, bazı nöronlar arasındaki bağlantılar güçlenirken, diğerleri zayıflar.



Yapay sinir ağları, bir değere kodlanmış düğümlerden oluşur. Bu düğümler birbirine bağlıdır ve ağ eğitildiğinde, aynı anda aktif olan düğümler arasındaki bağlantılar güçlenir; aksi halde zayıflar.



ÇAĞRIŞIMCI BELLEK

Diyelim ki, nadiren kullandığınız bir kelimeyi hatırlamaya çalışıyorsunuz; örneğin, sinemalarda ve konferans salonlarında sıklıkla bulunan eğimli zeminler için kullanılan bir terim. Hafızanızda bu kelimeyi arıyorsunuz. Benzer kelimeler arasında arama süreci, fizikçi John Hopfield'in 1982'de keşfettiği çağrışımıcı belleği anımsatır. Hopfield ağı, desenleri saklayabilir ve bunları yeniden oluşturmak için bir yöntemle sahiptir. Ağa eksik veya hafifçe bozulmuş bir desen verildiğinde, yöntem en benzer saklanmış deseni bulabilir.

Hopfield daha önce moleküler biyolojideki teorik problemleri keşfetmek için fizik alanındaki geçmişini kullanmıştı. Nörobilim hakkında bir toplantıya davet edildiğinde beyin yapısına yönelik araştırmalarla karşılaştı. Öğrendikleri onu büyüledi ve basit sinir ağlarının dinamikleri üzerinde düşünmeye başladı. Nöronlar birlikte çalıştıklarında, yalnızca ağın ayrı bileşenlerine bakan birine açık olmayan yeni ve güçlü özellikler ortaya çıkarabilirler. 1980'de Princeton Üniversitesi'ndeki görevinden ayrılarak, araştırma alanları meslektaşlarının fizik çalışmaları dışında kalan bir yöne kaydı için, kıtayı baştan başa kat ederek Caltech'de (California Teknoloji Enstitüsü) kimya ve biyoloji profesörlüğü teklifini kabul etti. Güney Kaliforniya'daki

Pasadena'da, yapay sinir ağlarıyla ilgili fikirlerini geliştirmek için kullanabileceği bilgisayar kaynaklarına erişimi vardı. Ancak, fiziğe dayalı temel bilgilerini terk etmedi; birbirleriyle etkileşime giren birçok küçük bileşene sahip sistemlerin nasıl yeni ve ilginç fenomenler ortaya çıkarabileceğine dair anlayışında fizikten ilham aldı. Özellikle, her atomu küçük bir mıknatıs haline getiren atomik spinleri olan manyetik materyaller hakkında öğrendiklerinden yararlandı. Komşu atomların spinleri birbirlerini etkileyebilir; bu, aynı yönde spin içeren alanların oluşmasına izin verebilir. Hopfield, spinlerin birbirlerini nasıl etkilediğini tanımlayan fiziği kullanarak, düğümler ve bağlantılar içeren bir model ağı oluşturmayı başardı.

AĞ, GÖRÜNTÜLERİ BİR PEYZAJDA SAKLAR

Hopfield'in inşa ettiği ağ, farklı güçlü bağlantılarla birbirine bağlı düğümlerden oluşur. Her düğüm, bireysel bir değeri saklayabilir. Hopfield'in ilk çalışmalarında bu değer 0 veya 1 olabiliyordu, tıpkı siyah beyaz bir resimdeki pikseller gibi. Hopfield, ağın genel durumunu, fizikteki spin sistemindeki enerjiye eşdeğer bir özellik olarak tanımladı; enerji, düğümlerin tüm değerlerini ve aralarındaki bağlantıların tüm güçlerini kullanan bir formül ile hesaplanır. Hopfield ağı, düğümlere siyah (0) veya beyaz (1) değerleri verilerek bir görüntü yüklenerek programlanır. Ardından ağın bağlantıları enerji formülü kullanılarak

ayarlanır, böylece kaydedilen görüntü düşük enerji seviyesine ulaşır. Ağa başka bir desen yüklendiğinde, düğümlerden birinin değeri değişirse ağın enerjisini düşürüp düşürmediğini kontrol etmek için düğümler tek tek incelenir. Eğer enerji, siyah bir pikselin beyaz olması durumunda düşüyorsa, pikselin rengi değiştirilir. Bu işlem, daha fazla iyileştirme bulunana kadar devam eder. Bu noktaya ulaşıldığında, ağ genellikle üzerinde eğitildiği orijinal görüntüyü yeniden oluşturur.

Bu yalnızca bir deseni saklamakla sınırlı olsa belki de dikkat çekici olmazdı. Bir görüntüyü doğrudan kaydedip test edilen başka bir görüntüyle karşılaştırmamak neden diye düşünülebilir; fakat Hopfield'in yöntemi özeldir çünkü aynı anda birden fazla görüntü kaydedilebilir ve ağ genellikle bunları birbirinden ayırt edebilir. Hopfield, kaydedilen bir durumu bulmak için ağı araştırmayı, tepe ve vadilerle dolu bir peyzajda hareket eden sürtünmeli bir topa benzetmiştir. Top belirli bir konumdan bırakıldığında, en yakın vadiye durana kadar yuvarlanır. Ağa kaydedilmiş desenlerden birine yakın bir desen yüklendiğinde, aynı şekilde ağın enerji peyzajındaki bir vadinin dibine yerleşene kadar ilerlemeye devam eder ve böylece belleğindeki en yakın deseni bulur. Hopfield ağı, gürültü içeren veya kısmen silinmiş verileri yeniden oluşturmak için kullanılabilir.


Anılar bir peyzajda saklanır

John Hopfield'in ilişkilendirme belleği, bilgiyi bir peyzaj oluşturmaya benzer bir şekilde saklar. Ağ eğitildiğinde, her kaydedilen desen için sanal bir enerji peyzajında bir vadi oluşturur.




- 1 Ağ, bozulmuş veya eksik bir desenle beslendiğinde, bu durum bir topu bu peyzaja bırakarak yokuş aşağı yuvarlanması gibi düşünülebilir.
- 2 Top, etrafının yokuşlarla çevrili olduğu bir yere ulaşana kadar yuvarlanır. Aynı şekilde ağ da daha düşük enerji seviyesine doğru hareket eder ve en yakın kaydedilmiş deseni bulur.

GİRDİ DESENİ



KAYDEDİLMİŞ DESEN



HOPFIELD AĞININ GELİŞİMİ VE YENİ YÖNTEMLER

Hopfield ve diğer araştırmacılar, Hopfield ağının işleyişini geliştirmeye devam ederek, yalnızca sıfır veya bir değil, herhangi bir değeri saklayabilen düğümler de eklediler. Düğümleri bir resimdeki pikseller gibi düşünürsek, bu pikseller sadece siyah ve beyaz olmak zorunda değildir; farklı renklerde de olabilirler. Bu geliştirilmiş yöntemler sayesinde daha fazla resim saklamak ve birbirine oldukça benzeyen resimleri dahi ayırt etmek mümkün hale gelmiştir. Birçok veri noktasından oluştuğu sürece, herhangi bir bilginin tanımlanması veya yeniden oluşturulması mümkündür.

19. YÜZYIL FİZİĞİYLE SINIFLANDIRMA

Bir görüntüyü hatırlamak bir şeydir; ancak onun neyi tasvir ettiğini yorumlamak biraz daha fazlasını gerektirir. Çok küçük yaştaki

çocuklar bile çeşitli hayvanlara bakıp, bunların bir köpek mi, kedi mi yoksa sincap mı olduğunu rahatlıkla söyleyebilir. Bu esnada hata yapabilirler, ancak kısa sürede neredeyse her seferinde doğru tahminde bulunurlar. Çocuklar bunu, tür veya memeli gibi kavramlarla ilgili herhangi bir diyagram veya açıklama görmeden de öğrenebilir. Her hayvan türünden birkaç örnek gördükten sonra, farklı kategoriler çocuğun zihninde yerine oturur. İnsanlar, çevrelerinde karşılaştıkları deneyimlerle bir kediyi tanımayı, bir kelimeyi anlamayı veya bir odaya girip bir şeylerin değiştiğini fark etmeyi öğrenirler.

Hopfield, çağrışımcı bellek üzerine makalesini yayımladığında, Geoffrey Hinton Carnegie Mellon Üniversitesi'nde çalışıyordu. Daha önce İngiltere ve İskoçya'da deneysel psikoloji ve yapay zekâ üzerine çalışmalar yapmış olan Hinton, makinelerin insanlara benzer şekilde kalıpları öğrenip öğrenemeyeceğini, bilgiyi sınıflandırıp yorumlamak için kendi kategorilerini oluşturup oluşturamayacaklarını merak ediyordu. Meslektaşları Terrence Sejnowski ile birlikte Hopfield ağından yola çıkarak yeni bir şey inşa etmeye başladılar ve bu süreçte istatistiksel fizikten faydalandılar.

BOLTZMANN MAKİNESİ VE İSTATİSTİKSEL FİZİK

İstatistiksel fizik, gazdaki moleküller gibi benzer birçok elementten oluşan sistemleri tanımlar. Gazdaki tüm molekülleri ayrı ayrı takip etmek zor veya imkansızdır; ancak onları topluca inceleyerek basınç veya sıcaklık gibi genel özellikler belirlebilir. Gaz moleküllerinin aynı toplu özellikleri koruyarak farklı hızlarda ve konumlarda olabilmesi mümkündür. Bireysel bileşenlerin birlikte var olabileceği durumlar istatistiksel fizik kullanılarak analiz edilebilir ve bunların meydana gelme olasılığı hesaplanabilir. Bazı durumların oluşma olasılığı daha yüksektir; bu olasılık, 19. yüzyıl fizikçisi Ludwig Boltzmann'ın bir denkleminde açıklanan enerji miktarına bağlıdır. Hinton'un ağı bu denklemi kullanıyordu ve yöntem 1985'te "Boltzmann Makinesi" adıyla yayımlandı.

AYNI TÜRDE YENİ ÖRNEKLERİ TANIMA

Boltzmann makinesi, genellikle iki farklı düğüm tipiyle çalışır. Bilgi, görünür düğümler olarak adlandırılan bir gruba verilir. Diğer düğümler ise gizli bir katman oluşturur. Gizli düğümlerin değerleri ve bağlantıları da ağıın genel enerjisine katkıda bulunur. Makine, düğümlerin değerlerini birer birer güncelleme kuralı uygulanarak çalıştırılır. Zamanla, makine düğümlerin desenini değiştirebilir, ancak ağıın genel özellikleri aynı kalır. Her olası desen, Boltzmann'ın denklemiyle ağıın enerjisi tarafından belirlenen spesifik bir olasılığa sahip olacaktır. Makine durduğunda yeni bir desen yaratır ve böylece Boltzmann makinesi, jeneratif bir modelin erken bir örneği olur.

BOLTZMANN MAKİNESİNİN ÖĞRENME SÜRECİ

Boltzmann makinesi, komutlarla değil, örneklerle öğrenir. Eğitim sürecinde, mak-

ineye görünür düğümler üzerinden beslenen örnek desenlerin, makine çalıştırıldığında ortaya çıkma olasılığını en yüksek seviyeye çıkarmak için ağıdaki bağlantıların değerleri güncellenir. Eğer aynı desen, eğitim sırasında tekrar tekrar verilirse, bu desenin olasılığı daha da artar. Eğitim süreci, makinenin eğitildiği örneklerle benzeyen yeni desenlerin üretilme olasılığını da etkiler. Eğitilmiş bir Boltzmann makinesi, daha önce görmediği bilgilerde tanıdık özellikleri tanıyabilir. Örneğin, bir arkadaşınızın kardeşiyle tanıştığınızda onların akraba olduklarını hemen anlayabilmeniz gibi, Boltzmann makinesi de, eğitim materyalinde yer alan bir kategoriye ait olan tamamen yeni bir örneği tanıyabilir ve benzemeyen materyalleri ayırt edebilir.


Boltzmann makinesinin orijinal formu oldukça verimsizdir ve çözümler bulması uzun sürer. Makine çeşitli şekillerde geliştirildiğinde daha ilginç hale gelir, ki Hinton bu alanda çalışmalarını sürdürmüştür. Daha sonraki versiyonlarında bazı bağlantılar çıkarılarak makine inceltilmiş ve bu durum, makinenin daha verimli olmasına katkı sağlamıştır. 1990'larda birçok araştırmacı yapay sinir ağlarına olan ilgisini kaybetmiş olsa da, Hinton bu alanda çalışmaya devam edenlerden biri olmuştur. 2006 yılında, Simon Osindero, Yee Whye Teh ve Ruslan Salakhutdinov ile

birlikte, ağıları katman katman bir dizi Boltzmann makinesi ile önceden eğitmek için bir yöntem geliştirdi. Bu ön eğitim, ağıdaki bağlantılara daha iyi bir başlangıç noktası sağlayarak, resimlerdeki öğeleri tanımaya yönelik eğitim sürecini optimize etti. Boltzmann makinesi genellikle daha büyük bir ağıın parçası olarak kullanılır. Örneğin, izleyicinin tercihlerine göre film veya dizi önerileri sunmak için kullanılabilir.


MAKİNE ÖĞRENMESİ- BUGÜN VE GELECEK

1980'lerden bu yana yaptıkları çalışmalar sayesinde, John Hopfield ve Geoffrey Hinton, 2010 civarında başlayan makine öğrenmesi devriminin temelini atmaya katkıda bulunmuştur. Bugün tanık olduğumuz gelişmeler, ağıları eğitmek için kullanılan büyük miktardaki veriye erişim ve bilgisayar gücündeki muazzam artış sayesinde mümkün olmuştur. Günümüzün yapay sinir ağları genellikle büyük boyuttadır ve birçok katmandan oluşur. Bu ağlar, "derin sinir ağları" olarak adlandırılır ve eğitim yöntemine "derin öğrenme" denir.

Farklı ağ türleri




John Hopfield'in ilişkilendirme belleği, tüm düğümlerin birbirine bağlı olacak şekilde inşa edilmiştir. Bilgi, tüm düğümlerden içeriye ve dışarıya doğru alınır.



görünür düğümler gizli düğümler

Geoffrey Hinton'ın Boltzmann makinesi genellikle iki katmanlı olarak inşa edilir; bilgi, "görünür düğümler" kullanılarak içeriye ve dışarıya alınır. Bu düğümler, ağıın tamamının nasıl çalıştığını etkileyen "gizli düğümler"e bağlıdır.




Kısıtlı bir Boltzmann makinesinde, aynı katmandaki düğümler arasında bağlantı yoktur. Makineler genellikle zincir şeklinde, art arda kullanılır. İlk kısıtlı Boltzmann makinesi eğitildikten sonra, gizli düğümlerin içeriği bir sonraki makineyi eğitmek için kullanılır ve bu böyle devam eder.

Hopfield'in 1982'de yayınladığı çağrışımıcı bellek üzerine makalesine hızlı bir bakış, bu gelişimin boyutunu anlamaya yardımcı olabilir. Makalede 30 düğüm içeren bir ağ kullanılmıştır. Tüm düğümler birbirine bağlıysa, 435 bağlantı vardır. Düğümler kendi değerlerine, bağlantılar farklı güçlere sahiptir ve toplamda 500'den az parametre bulunmaktadır. Ayrıca 100 düğümlü bir ağ denemiş, ancak o dönemin bilgisayarıyla bu, çok karmaşık hale gelmiştir. Bunu, bugün milyar parametreyi aşan yapılarla inşa edilen büyük dil modelleriyle karşılaştırabiliriz. Günümüzde birçok araştırmacı, mak-

ine öğrenmesinin uygulama alanlarını geliştirmektedir. Hangisinin en iyi sonucu vereceği henüz belirsizken, bu teknolojinin gelişimi ve kullanımı ile ilgili etik konular da geniş kapsamda tartışılmaktadır.

Fizik, makine öğrenmesinin gelişimine araçlar sunduğu için, bu teknolojinin fiziğe sağladığı katkılar görmek de ilginçtir. Makine öğrenmesi, geçmiş Nobel Fizik Ödüllerinden aşına olduğumuz alanlarda uzun zamandır kullanılmaktadır. Bunlar arasında, Higgs parçacığının keşfi için gerekli olan büyük miktardaki veriyi elemek ve işlemek yer alır.

Diğer uygulamalar arasında, çarpışan kara deliklerden gelen kütleçekimsel dalgaların ölçümlerindeki gürültüyü azaltmak veya öte gezegen arayışı bulunur. Son yıllarda, bu teknoloji moleküllerin ve malzemelerin özelliklerini hesaplamak ve tahmin etmek için de kullanılmaya başlanmıştır. Örneğin, protein moleküllerinin yapısını (ki bu yapılar fonksiyonlarını belirler) hesaplamak veya daha verimli güneş panellerinde kullanılabilecek en iyi özelliklere sahip yeni malzeme versiyonlarını belirlemek gibi çalışmalar yapılmaktadır.



1901-2024 NOBEL FİZİK ÖDÜLÜ İSTATİSTİKLERİ



Nobel Fizik Ödülü

1901-2024

Bir ödül sahibi daha
önce iki kez bu ödüle
layık görüldü.

En yaşlı

96



En genç

25

Fizik ödülünün
bir/iki/üç kişiye
paylaştırıldığı sayı

38



33



47



Fizik ödülleri

118

Fizik ödülü sahipleri

226

NOBEL ÖDÜLÜ

