Derin Öğrenme

Yapay Zekâ ve Veri Dersleri Rehberi · Kısım I: Çekirdek

Temsil öğrenme | Evrişimli ağlar | Yinelemeli ağlar | Dönüştürücüler | Eğitim teknikleri | Komşu dersler

Sercan KÜLCÜ · Giresun Üniversitesi · Bilgisayar Mühendisliği

© Sercan Külcü. Tüm hakları saklıdır. · Sunumun etkileşimli HTML sürümü: https://sercankulcu.github.io/files/ai_courses/sunumlar/Bolum_05_Derin_Ogrenme.html

GİRİŞ

Ders Hangi Soruyu Sorar?

> **Çok katmanlı ağlar ham veriden kullanışlı temsilleri nasıl kendisi öğrenir?**

Derin öğrenme, çok katmanlı sinir ağlarının ham veriden (piksel, ses, metin) işe yarar ara temsilleri katman katman kendisinin öğrenmesini inceler. Öznitelikleri elle tasarlamak yerine **temsil öğrenme** esastır; bunu büyük veri, GPU ve iyi mimariler mümkün kılar.

Bir bakışta

YAKLAŞIM	GİRDİ	ÇIKTI
çok katmanlı temsil öğrenme	ham veri: görüntü, metin, ses	öğrenilmiş temsil ve tahmin

BAŞARI ÖLÇÜTÜ	MATEMATİK YÜKÜ	VERİ İHTİYACI
doğruluk, kayıp, ölçeklenme	yüksek: türev, matris, olasılık	çok; GPU gerekir

Kısa Tarihçe

1997
Hochreiter ve Schmidhuber LSTM'yi önerir: uzun dizilerde gradyanın sönmesine çare.

1998
LeCun ve arkadaşlarının LeNet-5 evrişimli ağı el yazısı rakamları tanır.

2006
Hinton ve arkadaşları derin inanç ağlarını katman katman ön eğitimle eğitir; ilgi yeniden canlanır.

2012
AlexNet, GPU'da eğitilen evrişimli ağla ImageNet yarışmasını büyük farkla kazanır.

2015
He ve arkadaşlarının artık ağları (ResNet) 152 katmanla ImageNet yarışmasını kazanır.

2017
Vaswani ve arkadaşları dönüştürücü (transformer) mimarisini tanıtır: yalnız dikkat mekanizması.

DERS

Temel Kavramlar

Temsil öğrenme
Katmanlar kenardan nesneye giderek soyut öznitelikler öğrenir.

Evrişim
Küçük süzgeçler görüntü üzerinde kayar; ağırlıklar paylaşılır.

Havuzlama
Uzamsal boyutu küçültür, küçük kaymalara dayanıklılık sağlar.

Yinelemeli ağ
RNN ve LSTM: diziyi adım adım işler, durum taşır.

Dikkat
Her öğe dizinin hangi öğelerine bakacağını ağırlıkla seçer.

Artık bağlantı
Katmanı atlayan yol; çok derin ağları eğitilebilir kılar.

Normalizasyon
Toplu (batch) ve katman normalizasyonu eğitimi kararlı kılar.

Aktarım öğrenmesi
Büyük veride eğitilmiş modeli yeni göreve uyarlamak.

Tipik İş Akışı



Örnek: Bitki hastalığı tanıyan bir uygulama yaprak fotoğraflarını toplar, ImageNet'te önceden eğitilmiş bir ResNet alır, son katmanını hastalık sınıflarıyla değiştirir ve GPU'da veri artırmayla ince ayar yapar. Hiçbir öznitelik elle tanımlanmaz.

DERS

Derste Neler İşlenir?

1. Derin ileri beslemeli ağlar ve hesaplama çizgesi
2. Optimizasyon: SGD, momentum, Adam
3. Düzenlileştirme: dropout, ağırlık cezası, veri artırma
4. Toplu ve katman normalizasyonu
5. Evrişimli ağlar: evrişim ve havuzlama
6. CNN mimarileri: LeNet, AlexNet, VGG, ResNet
7. Aktarım öğrenmesi ve ince ayar
8. Yinelemeli ağlar: RNN, LSTM, GRU
9. Diziden diziye modeller ve dikkat
10. Dönüştürücüler ve öz dikkat
11. Otokodlayıcılar ve öz denetimli öğrenme
12. Derin ağları yorumlamak: belirginlik haritaları

Kazandırdığı beceriler

PyTorch ile model kurup eğitmek

GPU'da eğitim ve mini yığın ayarı

önceden eğitilmiş modele ince ayar

TensorBoard ile eğitimi izlemek

Hugging Face modellerini kullanmak

hiperparametre denemesi tasarlamak

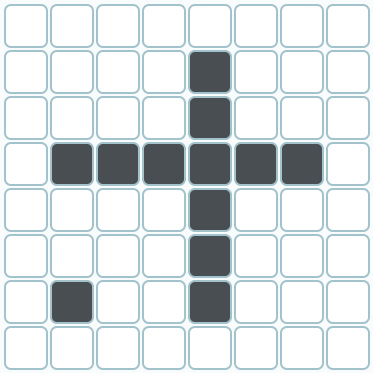
Tipik bir dönemin akışıdır; sıra ve kapsam üniversiteden üniversiteye değişir.

DENE

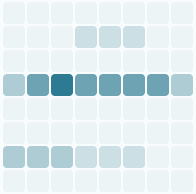
Süzgeçler Çizgiyi Nasıl Görür?

Bir okul uygulaması çocukların çizdiği işaretleri tanıyacak. Sol ızgaraya tıklayarak çizin; iki evrişim süzgeci resmi tarar, öznitelik haritalarından sınıf puanı çıkar.

Girdi (tıklayıp çizin)



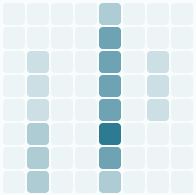
Yatay süzgeç



çekirdek

−1	−1	−1
2	2	2
−1	−1	−1

Dikey süzgeç



çekirdek

−1	2	−1
−1	2	−1
−1	2	−1

Sağda: evrişim + ReLU.
Koyu kare = güçlü tepki.

Yatay | Dikey | Artı | Temizle

Yatay haritanın toplamı **42**, dikeyin **42**.
Tahmin: **artı** (%95)

Sınıf olasılıkları (softmax)

yatay çizgi	%2
dikey çizgi	%2
artı	%95

Çapraz bir çizgi çizin: iki süzgeç de neredeyse **tepki vermez**. Ağın başka desenler için başka süzgeçlere ihtiyacı var.

Süzgeçteki dokuz sayı elle yazıldı; derin ağ ise bu sayıları **verilerden öğrenir** ve katmanları üst üste koyarak kenardan şekle, şekilden nesneye çıkar.

KONUM

Ön Koşullar

Bu dersten önce bilinmesi yararlı olan dersler ve neden gerektikleri.

Ders	Neden gerekir
Yapay Sinir Ağları	çok katmanlı ağlar, geri yayılım, etkinleştirme fonksiyonları
GPU Programlama ve Paralel Hesaplama	büyük ağların paralel eğitimi, tensör işlemleri
Analiz (Kalkülüs)	çok değişkenli türev ve zincir kuralı
Programlama	Python, NumPy ve bir derin öğrenme kütüphanesine alışkanlık

KONUM

Bu Ders Sana Göre mi?

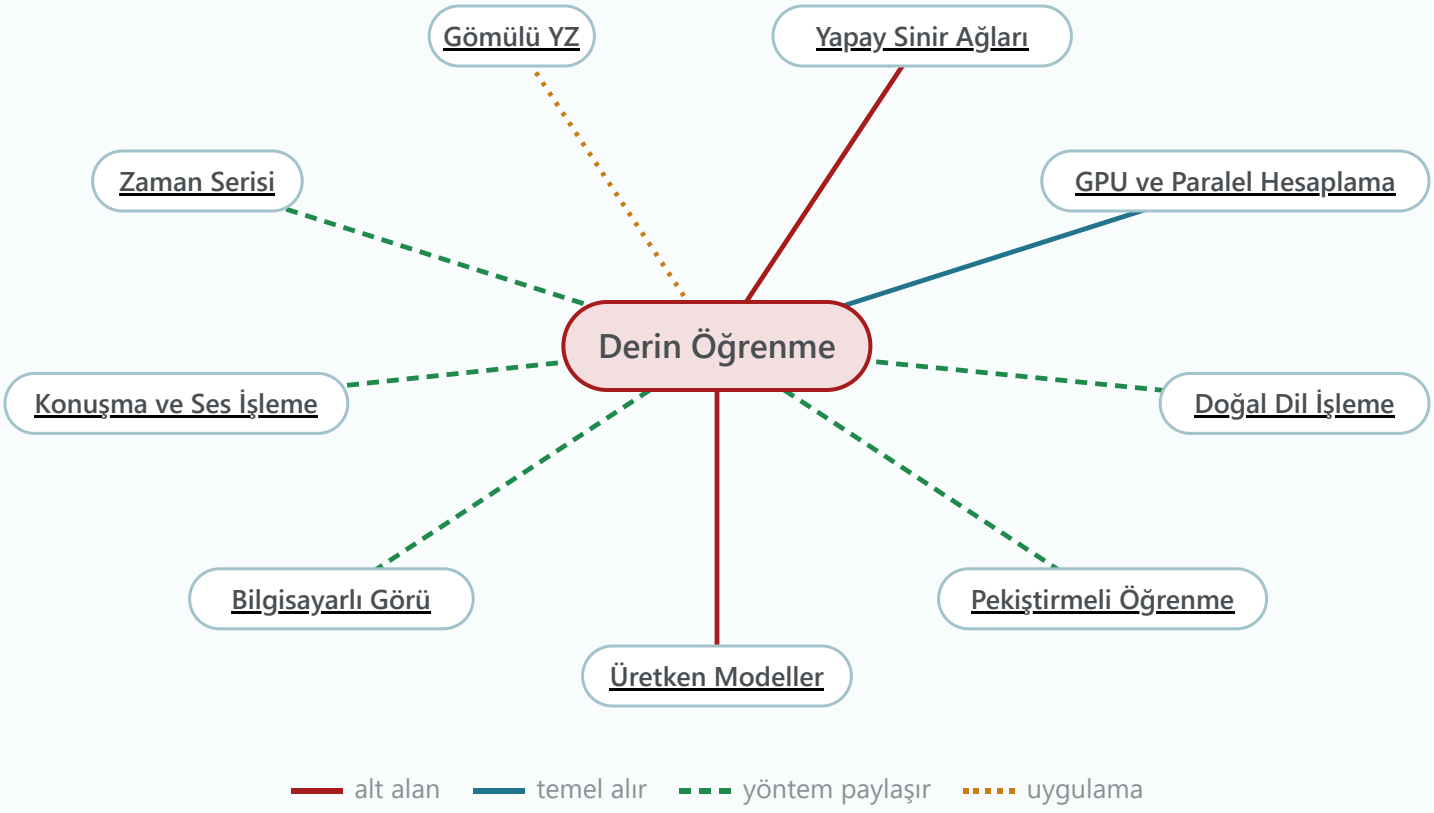
Kendine sor; "hayır" dediklerin için sağdaki sütun nereden başlayacağını gösterir.

Kendine sor	Hayırsa önce
Küçük bir ağda geri yayılımı adım adım açıklayabiliyor musun?	Yapay Sinir Ağları
Çok değişkenli bir fonksiyonun gradyanını hesaplayabiliyor musun?	Analiz dersindeki kısmi türev ve zincir kuralı
Matris çarpımında boyutların nasıl uyması gerektiğini söyleyebiliyor musun?	Doğrusal Cebir
Python'da sınıf yazıp NumPy dizileriyle çalışabiliyor musun?	Programlamaya giriş, ardından NumPy'a kısa bir giriş

Çoğuna "evet" diyebiliyorsan derse hazırsın; bir ya da iki "hayır" dönem içinde kapanabilir.

KONUM

Dersin Komşuları



Örtüştüğü Dersler (1/2)

İlişki	Ders	Ortak konu
alt alan	Bu ders, Yapay Sinir Ağları dersinin alt alanıdır	çok katmanlı ağlar, geri yayılım, etkinleştirme fonksiyonları
alt alan	Üretken Modeller, bu dersin alt alanıdır	GAN, VAE, difüzyon, büyük dil modelleri
temel alır	Bu ders GPU Programlama ve Paralel Hesaplama dersini temel alır	büyük ağların paralel eğitimi, tensör işlemleri
uygulama	Gömülü Yapay Zekâ bu dersin yöntemlerini uygular	nicemleme, budama, küçük modeller
yöntem paylaşır	Doğal Dil İşleme ve Metin Madenciliği ile yöntem paylaşır	sözcük gömmeleri, dönüştürücü (transformer) mimarisi
yöntem paylaşır	Pekiştirmeli Öğrenme ile yöntem paylaşır	derin Q-ağları, derin politika ağları
yöntem paylaşır	Bilgisayarlı Görü ile yöntem paylaşır	evrişimli sinir ağları, görüntü dönüştürücüleri
yöntem paylaşır	Konuşma Tanıma ve Ses İşleme ile yöntem paylaşır	uçtan uca konuşma tanıma

Örtüştüğü Dersler (2/2)

İlişki	Ders	Ortak konu
yöntem paylaşır	Zaman Serisi Analizi ve Tahmin ile yöntem paylaşır	yinelemeli ağlar, dikkat temelli tahmin

Ayrıştığı Noktalar (1/2)

Ölçüt	Derin Öğrenme	Yapay Sinir Ağları	Makine Öğrenmesi
Temel soru	Çok katmanlı ağlar ham veriden kullanışlı temsilleri nasıl kendisi öğrenir?	Basit birimlerden kurulan ağlar ağırlıklarını ayarlayarak nasıl öğrenir?	Bir program örneklerden nasıl genelleme yapar?
Yaklaşım	çok katmanlı temsil öğrenme	ağırlıklı basit birimlerden ağ	istatistiksel öğrenme
Girdi	ham veri: görüntü, metin, ses	sayısal öznitelik vektörü	etiketli ya da etiketsiz örnekler
Çıktı	öğrenilmiş temsil ve tahmin	sınıf ya da sayı tahmini	tahmin yapan model
Başarı ölçütü	doğruluk, kayıp, ölçeklenme	kayıp ve doğruluk	görülmemiş veride hata
Matematik yükü	yüksek: türev, matris, olasılık	orta-yüksek: türev, matris	yüksek: doğrusal cebir, olasılık, optimizasyon
Veri ihtiyacı	çok; GPU gerekir	orta	orta ve çok

- **Yapay Sinir Ağları:** YSA nöron, kayıp ve geri yayılımı küçük ağlarda kurar; bu ders derin mimarileri ve onları eğitmenin pratiğini işler.
- **Makine Öğrenmesi:** Klasik MÖ elle tasarlanmış özniteliklerle çalışır; derin öğrenme öznitelikleri ham veriden kendisi öğrenir.

Ayrıştığı Noktalar (2/2)

Ölçüt	Derin Öğrenme	Bilgisayarlı Görü	Üretken Modeller
Temel soru	Çok katmanlı ağlar ham veriden kullanışlı temsilleri nasıl kendisi öğrenir?	Bilgisayar bir görüntüde ya da videoda ne olduğunu nasıl anlar?	Bir model gerçek veriye benzeyen yeni örnekleri nasıl üretir?
Yaklaşım	çok katmanlı temsil öğrenme	görüntüden anlam çıkarma	veri dağılımını öğrenme
Girdi	ham veri: görüntü, metin, ses	görüntü ya da video	çok büyük, çoğu etiketsiz veri
Çıktı	öğrenilmiş temsil ve tahmin	etiket, kutu, derinlik, 3B yapı	yeni örnek: görüntü, metin, ses
Başarı ölçütü	doğruluk, kayıp, ölçeklenme	doğruluk, mAP, IoU	gerçekçilik ve çeşitlilik (FID vb.)
Matematik yükü	yüksek: türev, matris, olasılık	yüksek: geometri, doğrusal cebir	yüksek
Veri ihtiyacı	çok; GPU gerekir	çok etiketli görüntü	çok fazla

- **Bilgisayarlı Görü:** Bilgisayarlı görü görüntüyü anlama problemidir; derin öğrenme ise görü, dil ve seste ortak kullanılan araç takımıdır.
- **Üretken Modeller:** Üretken modeller veri dağılımından örnek üretmeyi amaçlar; bu ders çoğunlukla ayırt edici, tahmin yapan ağlara odaklanır.

UYGULAMA

Uygulama Alanları

Görüntü sınıflandırma
Fotoğraftaki nesneyi ya da hastalığı tanımak.

Konuşma tanıma
Ses kaydını metne dönüştürmek.

Makine çevirisi
Dönüştürücü tabanlı çeviri sistemleri.

Nesne tespiti
Otonom araçta yaya ve araç bulmak.

Protein yapısı
Amino asit dizisinden üç boyutlu yapı tahmini.

Oyun oynama
Derin pekiştirmeli öğrenmeyle Atari ve Go.

UYGULAMA

Riskler ve Etik

Hesaplama ve enerji maliyeti

Büyük modelleri eğitmek binlerce GPU saati ve ciddi karbon salımı ister; bu araştırmayı birkaç büyük kurumun tekeline sokar.

Düşmanca örnekler

Göze görünmeyen piksel değişikliği sınıflandırıcıyı yanıltır; dur levhasına yapıştırılan çıkartmalarla da bu gösterildi.

Web'den toplanan veri

ImageNet gibi web'den toplanan veriler izinsiz fotoğraflar ve kişileri aşağılayan etiketler içerebilir; ImageNet bunları sonradan ayıkladı.

Sahte ilerleme

Test kümesine göre ayarlanan hiperparametreler ve tek tohumla raporlanan sonuçlar küçük farkları gerçek iyileşme gibi gösterir.

Ayrıntılı tartışma: Açıklanabilir Yapay Zekâ ve Yapay Zekâ Etiği.

UYGULAMA

Araçlar ve Örnek Veriler

Araçlar ve kütüphaneler

PyTorch | TensorFlow | Keras | JAX | Hugging Face | CUDA | TensorBoard

Tanınmış veri setleri

ImageNet | CIFAR-10/100 | MNIST | COCO | LibriSpeech | Wikipedia metinleri

UYGULAMA

Sık Karıştırılanlar

Yaygın düşünce	Doğrusu
Derin öğrenme her problemde en iyisidir.	Küçük tablo verisinde gradyan artırmalı ağaçlar çoğu zaman daha iyi ve daha ucuzdur.
Derin ağ kara kutudur, hiç incelenemez.	Gradyan tabanlı belirginlik haritaları, dikkat ağırlıkları gibi araçlar kısmi açıklama verir.
Derin öğrenme 2012'de icat edildi.	Fikirler onlarca yıllıktır; 2012'deki sıçramayı büyük veri ve GPU getirdi.
Katman sayısı arttıkça başarı artar.	Artık bağlantı ve normalizasyon olmadan çok derin ağlar eğitilemeyebilir.

SONRASI

Bu Dersten Sonra

Bu dersi temel alan ya da genişleten dersler

Üretken Modeller | Gömülü Yapay Zekâ

İlgili meslekler

Derin öğrenme mühendisi | Bilgisayarlı görü mühendisi | Araştırmacı | ML altyapı mühendisi | Uygulamalı bilimci

Derin öğrenme bugün haritanın en çok kullanılan aracıdır: bilgisayarlı görü, doğal dil işleme, konuşma tanıma, üretken modeller ve derin pekiştirmeli öğrenme onun üzerine kurulur. Sistem tarafında GPU programlama, gömülü YZ ve MLOps bu modelleri hızlandırmayı ve üretime taşımayı öğretir.

SONRASI

Kaynaklar

- Goodfellow, Bengio ve Courville, *Deep Learning*, MIT Press, 2016.
- Zhang, Lipton, Li ve Smola, *Dive into Deep Learning*, Cambridge University Press, 2023.
- Prince, *Understanding Deep Learning*, MIT Press, 2023.
- Chollet, *Deep Learning with Python*, 2. baskı, Manning, 2021.
- LeCun, Bengio ve Hinton, "Deep learning", *Nature* 521, 2015.

Son

Bölüm 5: Derin Öğrenme

← Önceki bölüm · Alanın haritası · Sonraki bölüm →