# Makine Öğrenmesi

## Yapay Zekâ ve Veri Dersleri Rehberi · Kısım I: Çekirdek

Öğrenme türleri | Model ve kayıp | Genelleme | Değerlendirme | Temel algoritmalar | 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_03_Makine_Ogrenmesi.html

GİRİŞ

# Ders Hangi Soruyu Sorar?

## Bir program örneklerden nasıl genelleme yapar?

Makine öğrenmesi, açıkça programlanmadan **örneklerden öğrenen** ve öğrendiğini yeni örneklere genelleyen algoritmaları inceler. Mitchell'in tanımıyla bir program, T görevindeki P ile ölçülen başarımı E deneyimiyle artıyorsa öğreniyordur.

### Bir bakışta

| | | |
|---|---|---|
| **YAKLAŞIM**<br>istatistiksel öğrenme | **GİRDİ**<br>etiketli ya da etiketsiz örnekler | **ÇIKTI**<br>tahmin yapan model |
| **BAŞARI ÖLÇÜTÜ**<br>görülmemiş veride hata | **MATEMATİK YÜKÜ**<br>yüksek: doğrusal cebir, olasılık, optimizasyon | **VERİ İHTİYACI**<br>orta ve çok |

# Kısa Tarihçe

**1957**
Rosenblatt algılayıcıyı (perceptron) tanıtır: ağırlıklarını örneklerden ayarlayan ilk modellerden.

**1959**
Samuel'in dama programı kendi kendine oynayarak gelişir; "makine öğrenmesi" adı yaygınlaşır.

**1986**
Quinlan'ın ID3 karar ağacı yayımlanır; aynı yıl geri yayılım sinir ağlarını yeniden canlandırır.

**1995**
Cortes ve Vapnik destek vektör makinelerini (SVM) yayımlar.

**2001**
Breiman rastgele ormanları tanıtır: çok sayıda ağacın oylaması.

**2012**
AlexNet ImageNet yarışmasını büyük farkla kazanır; derin öğrenme dönemi başlar.

DERS

# Temel Kavramlar

**Denetimli öğrenme**
Etiketli örneklerle sınıflandırma ve regresyon.

**Denetimsiz öğrenme**
Etiketsiz veride kümeleme ve boyut indirgeme.

**Model ve hipotez**
Öğrenilecek fonksiyonun biçimi ve parametreleri.

**Kayıp fonksiyonu**
Tahminin ne kadar yanlış olduğunu ölçer; eğitim onu küçültür.

**Genelleme**
Eğitimde görülmeyen örneklerde de doğru tahmin.

**Aşırı uydurma**
Eğitim verisini ezberleme; yanlılık-varyans dengesi.

**Doğrulama**
Eğitim, doğrulama ve test kümeleri; çapraz doğrulama.

**Öznitelikler**
Ham veriyi modele uygun sayılara dönüştürmek.

# Tipik İş Akışı




**Örnek:** İstenmeyen e-posta süzgeci geçmiş iletileri ve etiketlerini toplar, sözcük sayılarını öznitelik yapar, lojistik regresyon eğitir, ayrılmış test iletilerinde doğruluğu ölçer ve gelen yeni iletileri sınıflandırır. Kurallar elle yazılmaz, veriden öğrenilir.

DERS

# Derste Neler İşlenir?

1. Öğrenme problemi; denetimli ve denetimsiz öğrenme
2. Doğrusal regresyon ve gradyan inişi
3. Lojistik regresyon ve sınıflandırma
4. Değerlendirme: eğitim/test ayrımı, çapraz doğrulama
5. Aşırı uydurma, düzenlileştirme, yanlılık-varyans
6. Karar ağaçları
7. Topluluk yöntemleri: rastgele orman, gradyan artırma
8. Destek vektör makineleri ve çekirdekler
9. k-en yakın komşu ve Naive Bayes
10. Kümeleme: k-ortalama, hiyerarşik kümeleme
11. Boyut indirgeme: PCA
12. Öznitelik mühendisliği ve model seçimi

## Kazandırdığı beceriler

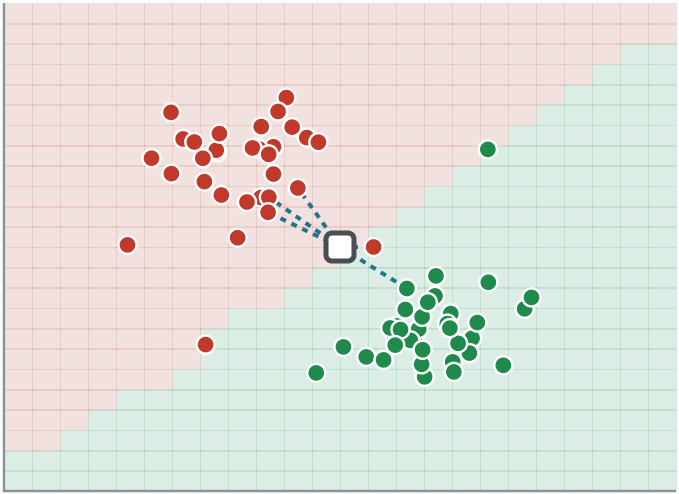
Python ve NumPy | pandas ile veri hazırlama | scikit-learn | çapraz doğrulama | doğru metriği seçmek | sonuçları grafik ve tabloyla raporlamak

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

DENE

# Krediyi Verelim mi?

Banka, geçmiş başvuruların gelirini, borç oranını ve krediyi geri ödeyip ödemediğini biliyor. Grafiğe tıklayarak yeni bir başvuru ekleyin; model ona en çok benzeyen **k** eski başvuruya bakarak karar verir.




Komşu sayısı k = **5**

**Karar bölgesini göster**

k = 5: en yakın 5 başvurunun 1 tanesi ödedi, 4 tanesi ödemedi.
Karar: **kredi verilmez** (çoğunluk oyu).

● geri ödedi ● ödemedi. k = 1 seçince bölgenin tek tek örneklere göre parçalandığına bakın: bu **aşırı uydurmadır**.

Kuralı kimse yazmadı: karar tamamen **örneklerden** geliyor. k küçükse model gürültüyü ezberler, çok büyükse ayrıntıyı kaçırır; doğru k, ayrı tutulmuş test verisinde seçilir.

KONUM

# Ön Koşullar

Bu dersten önce bilinmesi yararlı olan dersler ve neden gerektikleri.

| Ders | Neden gerekir |
|---|---|
| Yapay Zekâ | veriden öğrenen etmen; arama yerine istatistiksel genelleme |
| Doğrusal Cebir | öznitelik vektörleri, matris çarpımı, PCA |
| Olasılık ve İstatistik | genelleme hatası, yanlılık-varyans, olasılıksal modeller |
| Optimizasyon | kayıp en küçükleme, düzenlileştirme |
| Programlama | Python ya da Java ile veri okuma, döngü ve fonksiyonlar |
| Analiz (Kalkülüs) | türev, kısmi türev ve zincir kuralı: gradyan inişinin dili |

KONUM

# Bu Ders Sana Göre mi?

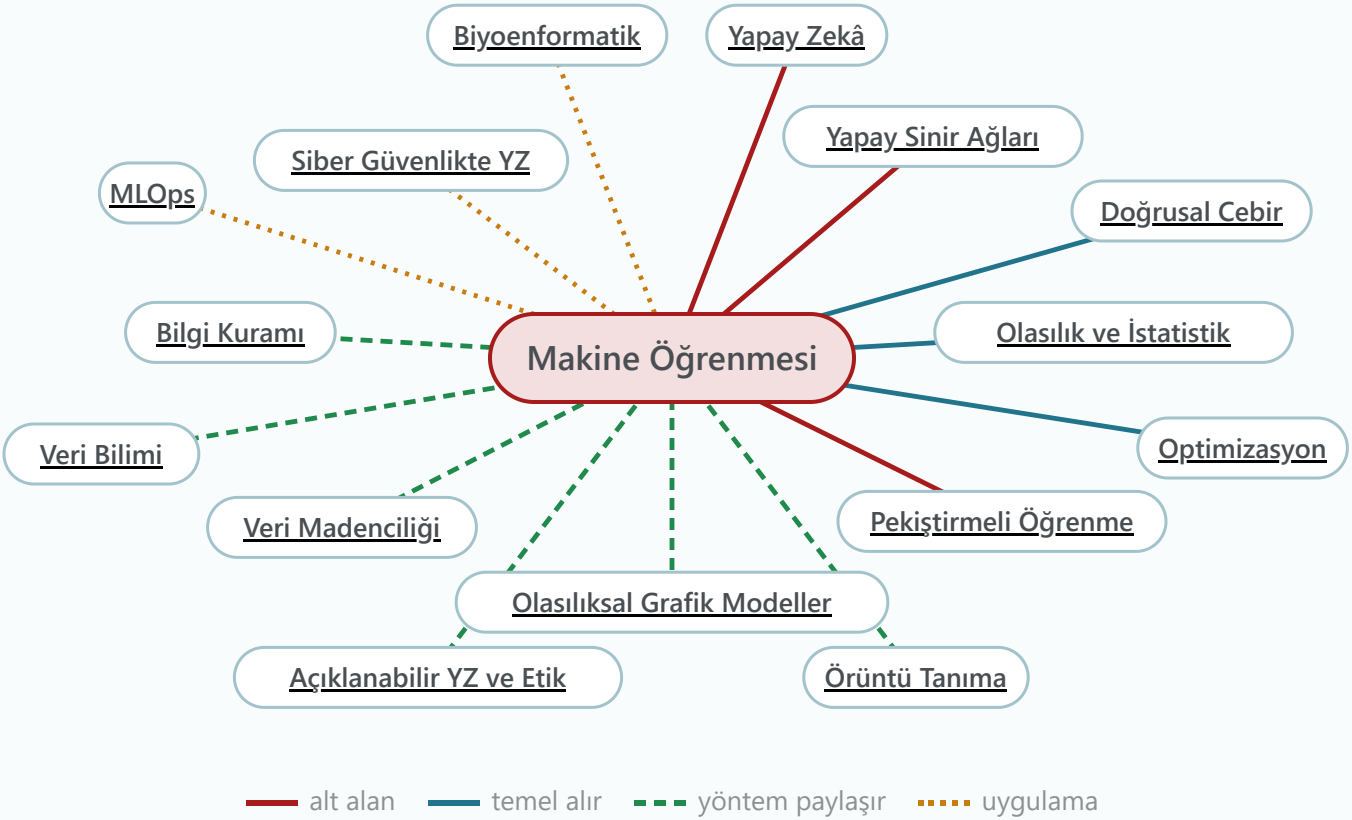
Kendine sor; "hayır" dediklerin için sağdaki sütun nereden başlayacağını gösterir.

| Kendine sor | Hayırsa önce |
|---|---|
| Bir fonksiyonun türevini ve kısmi türevini alabiliyor musun? | Analiz dersindeki türev ve zincir kuralı konuları |
| Matris çarpımı ve vektör iç çarpımı yapabiliyor musun? | Doğrusal Cebir |
| Ortalama, varyans ve koşullu olasılığı açıklayabiliyor musun? | Olasılık ve İstatistik |
| Python'da döngü ve fonksiyon yazıp bir CSV dosyası okuyabiliyor musun? | Programlamaya giriş, ardından pandas'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 Zekâ dersinin alt alanıdır | veriden öğrenen etmen; arama yerine istatistiksel genelleme |
| alt alan | Yapay Sinir Ağları, bu dersin alt alanıdır | parametrik model, kayıp fonksiyonu, gradyan inişi |
| alt alan | Pekiştirmeli Öğrenme, bu dersin alt alanıdır | etiket yerine ödülle öğrenme |
| temel alır | Bu ders Doğrusal Cebir dersini temel alır | öznitelik vektörleri, matris çarpımı, PCA |
| temel alır | Bu ders Olasılık ve İstatistik dersini temel alır | genelleme hatası, yanlılık-varyans, olasılıksal modeller |
| temel alır | Bu ders Optimizasyon dersini temel alır | kayıp en küçükleme, düzenlileştirme |
| uygulama | Makine Öğrenmesi Sistemleri ve MLOps bu dersin yöntemlerini uygular | modeli dağıtma, izleme, yeniden eğitme |
| uygulama | Siber Güvenlikte Yapay Zekâ bu dersin yöntemlerini uygular | saldırı tespiti, kötü amaçlı yazılım sınıflandırma |

# Örtüştüğü Dersler (2/2)

| İlişki | Ders | Ortak konu |
|---|---|---|
| uygulama | Biyoenformatik bu dersin yöntemlerini uygular | gen ifadesi sınıflandırma, protein yapısı |
| yöntem paylaşır | Örüntü Tanıma ile yöntem paylaşır | sınıflandırıcılar, karar sınırları |
| yöntem paylaşır | Olasılıksal Grafik Modeller ile yöntem paylaşır | olasılıksal sınıflandırıcılar, EM algoritması |
| yöntem paylaşır | Açıklanabilir Yapay Zekâ ve Yapay Zekâ Etiği ile yöntem paylaşır | model açıklama, öznitelik önemi |
| yöntem paylaşır | Veri Madenciliği ile yöntem paylaşır | aynı algoritmalar; amaç tahmin değil keşif |
| yöntem paylaşır | Veri Bilimi ile yöntem paylaşır | tahmin modelleri |
| yöntem paylaşır | Bilgi Kuramı ile yöntem paylaşır | çapraz entropi kaybı, karar ağacı bölme ölçütü |

# Ayrıştığı Noktalar (1/2)

| Ölçüt | Makine Öğrenmesi | Yapay Zekâ | Veri Madenciliği |
|---|---|---|---|
| **Temel soru** | Bir program örneklerden nasıl genelleme yapar? | Bir makine arayarak, çıkarım yaparak ve plan kurarak nasıl akıllıca davranır? | Büyük veri yığınlarındaki gizli ve işe yarar örüntüler nasıl bulunur? |
| **Yaklaşım** | istatistiksel öğrenme | arama, mantık, olasılık ve öğrenme bir arada | keşfe dayalı çözümleme |
| **Girdi** | etiketli ya da etiketsiz örnekler | problem tanımı: durumlar, eylemler, hedef | büyük tablo ya da işlem verisi |
| **Çıktı** | tahmin yapan model | eylem dizisi, plan ya da karar | kural, küme, aykırı değer |
| **Başarı ölçütü** | görülmemiş veride hata | hedefe ulaşma, maliyet, rasyonellik | ilginçlik, destek, güven |
| **Matematik yükü** | yüksek: doğrusal cebir, olasılık, optimizasyon | orta: mantık, olasılık, çizge | orta |
| **Veri ihtiyacı** | orta ve çok | az; çoğu zaman model ve bilgi yeter | çok |

- **Yapay Zekâ:** YZ çerçevedir; MÖ bu çerçevede yalnızca veriden öğrenmeye odaklanır.
- **Veri Madenciliği:** Aynı algoritmaları kullanırlar; MÖ yeni örnekte tahmini, veri madenciliği veride keşfi amaçlar.

# Ayrıştığı Noktalar (2/2)

| Ölçüt | Makine Öğrenmesi | Olasılık ve İstatistik | Derin Öğrenme |
|---|---|---|---|
| **Temel soru** | Bir program örneklerden nasıl genelleme yapar? | Belirsizlik nasıl ölçülür ve sınırlı veriden nasıl güvenilir sonuç çıkarılır? | Çok katmanlı ağlar ham veriden kullanışlı temsilleri nasıl kendisi öğrenir? |
| **Yaklaşım** | istatistiksel öğrenme | olasılık modeli ve çıkarım | çok katmanlı temsil öğrenme |
| **Girdi** | etiketli ya da etiketsiz örnekler | örneklem verisi | ham veri: görüntü, metin, ses |
| **Çıktı** | tahmin yapan model | kestirim, güven aralığı, test sonucu | öğrenilmiş temsil ve tahmin |
| **Başarı ölçütü** | görülmemiş veride hata | yansızlık, güç, anlamlılık | doğruluk, kayıp, ölçeklenme |
| **Matematik yükü** | yüksek: doğrusal cebir, olasılık, optimizasyon | kuramın kendisi | yüksek: türev, matris, olasılık |
| **Veri ihtiyacı** | orta ve çok | örneklem | çok; GPU gerekir |

- **Olasılık ve İstatistik:** İstatistik modelin anlamını ve belirsizliğini, MÖ tahmin başarımını öne çıkarır.
- **Derin Öğrenme:** Derin öğrenme MÖ'nün bir koludur; öznitelikleri elle tasarlamak yerine ham veriden öğrenir.

UYGULAMA

# Uygulama Alanları

**İstenmeyen ileti süzme**
E-postaları içeriğine göre sınıflandırmak.

**Kredi puanlama**
Başvuranın geri ödeme riskini tahmin etmek.

**Öneri**
Kullanıcının beğenebileceği ürün ya da içerik.

**Tıbbi tahmin**
Hasta verisinden hastalık riskini kestirmek.

**Talep tahmini**
Satış ve stok planlaması.

**Sahtekârlık tespiti**
Olağandışı kart işlemlerini yakalamak.

UYGULAMA

# Riskler ve Etik

**Yanlı veri, yanlı karar**

Geçmiş verideki ayrımcılık modele aynen geçer: işe alım ya da kredi modelleri bazı grupları sistematik olarak dışlayabilir.

**Veri sızıntısı**

Test bilgisinin eğitime karışması modeli kâğıt üzerinde kusursuz, sahada işe yaramaz gösterir.

**Mahremiyet**

Eğitim verisindeki kişisel bilgiler modelden geri çıkarılabilir; KVKK ve GDPR verinin nasıl kullanılacağını sınırlar.

**Yersiz güven**

Yüksek doğruluk, veri dağılımı değişince çöker; model bilmediği durumda da kendinden emin görünür.

Ayrıntılı tartışma: Açıklanabilir Yapay Zekâ ve Yapay Zekâ Etiği.

UYGULAMA

# Araçlar ve Örnek Veriler

## Araçlar ve kütüphaneler

scikit-learn | pandas | NumPy | XGBoost | Weka | R

## Tanınmış veri setleri

Iris | MNIST | UCI Machine Learning Repository | Titanic (Kaggle) | Adult (gelir) | Wine

UYGULAMA

# Sık Karıştırılanlar

| Yaygın düşünce | Doğrusu |
|---|---|
| Daha karmaşık model her zaman daha iyidir. | Karmaşık model eğitim verisini ezberleyebilir (aşırı uydurma) ve yeni veride kötüleşir. |
| Eğitim doğruluğu başarıyı gösterir. | Başarı, eğitimde hiç kullanılmamış test verisinde ölçülür. |
| Çok veri her sorunu çözer. | Yanlı ya da gürültülü veri çoğaldıkça yanlışı da çoğaltır. |
| Model neden-sonuç ilişkisini öğrenir. | MÖ ilinti bulur; nedensellik için deney ya da nedensel çıkarım gerekir. |

SONRASI

# Bu Dersten Sonra

## Bu dersi temel alan ya da genişleten dersler

Yapay Sinir Ağları | Pekiştirmeli Öğrenme | Makine Öğrenmesi Sistemleri ve MLOps | Siber Güvenlikte Yapay Zekâ | Biyoenformatik

## İlgili meslekler

Makine öğrenmesi mühendisi | Veri bilimci | Araştırmacı | MLOps mühendisi

Makine öğrenmesi haritanın kavşağıdır: sinir ağları ve pekiştirmeli öğrenme onun dallarıdır; MLOps, siber güvenlik ve biyoenformatik onun yöntemlerini uygular. Bu dersten sonra ister derinleşmek (YSA, derin öğrenme), ister bir uygulama alanına geçmek mümkündür.

SONRASI

# Kaynaklar


- Mitchell, *Machine Learning*, McGraw-Hill, 1997.
- Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- Hastie, Tibshirani ve Friedman, *The Elements of Statistical Learning*, 2. baskı, Springer, 2009.
- Alpaydın, *Introduction to Machine Learning*, 4. baskı, MIT Press, 2020.
- Géron, *Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow*, 3. baskı, O'Reilly, 2022.

# Son

## Bölüm 3: Makine Öğrenmesi

← Önceki bölüm · Alanın haritası · Sonraki bölüm →