

OSTİM TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK FAKÜLTESİ
YAPAY ZEKA MÜHENDİSLİĞİ

DERS İZLENCE FORMU
2024-2025 BAHAR

Dr.Öğr.Üyesi Murat ŞİMŞEK, murat.simsek@ostimteknik.edu.tr

YZM 303 MAKİNE ÖĞRENMESİ							
Ders Adı	Ders Kodu	Dönemi	Teori Saati	Uygulama Saati	Laboratuvar Saati	Kredi	AKTS
Makine Öğrenmesi	YZM 303	5	3	0	0	3	6

Dersin Dili	Türkçe
Dersin Türü	Alan Dersi
Dersin Seviyesi	Lisans
Ders Verme Şekli	Yüz Yüze
Dersi veren Öğretim Eleman(ları)	Dr.Öğr.Üyesi Murat ŞİMŞEK
Dersin Öğrenme ve Öğretme Teknikleri	Anlatım, Sunum, Ödev, Sınav

Dersin Amacı
<p>Bu dersin amacı öğrencilerin temel makine öğrenmesi kavramlarını, algoritmalarını ve uygulama süreçlerini anlamalarını sağlamayı amaçlar. Ders kapsamında, doğrusal regresyon, sınıflandırma, kümeleme, karar ağaçları, destek vektör makineleri ve k-en yakın komşu gibi temel makine öğrenme algoritmaları teorik ve pratik açıdan ele alınacaktır. Bu sayede öğrencilerin, karşılaştıkları problemlere uygun algoritma seçimi yapabilmeleri ve bu algoritmaları çeşitli veri kümeleri üzerinde başarıyla uygulayabilmeleri hedeflenmektedir. Makine öğrenmesi modellerinin değerlendirilmesi ve performans ölçümleri ile ilgili kavramları öğrenerek model başarımlarını optimize etmelerine katkıda bulunmayı amaçlar. Gerçek hayat senaryolarında kullanılacak projeler ve örnek veri setleri üzerinden analiz yaparak, öğrencilerin makine öğrenmesinin mühendislik, bilişim ve veri bilimi alanlarında nasıl bir rol oynadığını ve bu teknolojilerin sorun çözme süreçlerine olan etkisini kavramaları sağlanacaktır.</p>

Dersin Eğitim/Öğrenim Çıktıları

Bu dersi başarıyla tamamlayabilen öğrencilerin;

1. Makine öğrenmesi algoritmalarını teorik ve uygulamalı düzeyde anlamlandırarak mühendislik problemlerinin modellenmesinde ve çözümünde kullanabilirler.
2. Farklı makine öğrenmesi algoritmalarını analiz edebilir, uygun olanları seçebilir ve karmaşık problemleri formüle ederek çözümler geliştirebilirler.
3. Gerçekçi kısıtlar ve koşullar altında makine öğrenmesi modellerini tasarlayabilir, öğrenme sürecinde karşılaşılan zorlukları yönetebilir ve uygun modelleme yöntemlerini uygulayabilirler.
4. Modern veri işleme ve analiz teknolojilerini etkin bir şekilde kullanarak veri toplama, işleme ve sonuçları değerlendirme becerisine sahip olabilirler.
5. Farklı veri kümeleri üzerinde makine öğrenmesi algoritmalarını uygulayarak, model performansını optimize etme ve sonuçları yorumlama yetkinliği kazanırlar.

Dersin İçeriği

Bu dersin içeriği; 1. Makine öğrenmesinin temel kavramları ve tarihsel gelişimi 2. Denetimli ve Denetimsiz öğrenme algoritmaları 3. Doğrusal regresyon ve lojistik regresyon 4. K-en yakın komşu algoritması 5. Destek vektör makineleri 6. Karar ağaçları ve rastgele ormanlar 7. Kümeleme yöntemleri (K-ortalama, hiyerarşik kümeleme) 8. Boyut indirgeme yöntemleri (PCA, LDA) 9. Model değerlendirme ve performans metrikleri (doğruluk, F1 skoru, ROC eğrisi) 10. Aşırı öğrenme ve doğrulama stratejileri (cross-validation) konuları içerir.

Haftalık Konular ve İlgili Ön Hazırlık Çalışmaları

Hafta	Konular	Açıklama
1	Makine öğrenmesinin temel kavramları ve tarihsel gelişimi	Makine öğrenmesi kavramları, türleri ve uygulamalarına genel bakış gibi konular anlatılır.
2	Denetimli Öğrenme	Denetimli öğrenme kavramı, etiketli verilerle model eğitimi ve sınıflandırma, regresyon gibi uygulamalar tanıtılır. Model değerlendirme ve performans metrikleri açıklanır.
3	Doğrusal regresyon ve lojistik regresyon	Doğrusal regresyon ve lojistik regresyon teknikleri tanıtılır; doğrusal regresyonun sürekli verilerde tahmin yapma, lojistik regresyonun ise sınıflandırma problemlerinde kullanımı üzerinde durulur.
4	Maliyet Fonksiyonu hesaplama ve Gradyan İnişi	Maliyet fonksiyonunun model hatasını ölçmedeki rolü ve gradient descent algoritmasının bu hatayı minimize ederek en iyi model parametrelerini bulma süreci anlatılır.
5	Doğrusal Olmayan (Non-Linear) Algoritmalar	Doğrusal olmayan algoritmaların özellikleri, doğrusal olmayan veri ilişkilerini modellemedeki rolleri ve karar ağaçları, K-en yakın komşu, destek vektör makineleri (SVM) gibi yaygın kullanılan doğrusal olmayan algoritmalar tanıtılır.

6	K-En Yakın Komşu (K-Nearest Neighbors - KNN) Algoritması	K-en yakın komşu algoritmasının temel prensipleri, sınıflandırma ve regresyondaki kullanımı ile yeni verilerin en yakın komşularına göre nasıl sınıflandırıldığı veya tahmin edildiği açıklanır.
7	Destek Vektör Makineleri (SVM) ve Naive Bayes Yöntemi	Destek vektör makinelerinin sınıflandırma problemlerinde veri ayırma prensibi ile Naive Bayes yönteminin olasılıklara dayalı sınıflandırma yaklaşımı tanıtılır. İki yöntemin avantajları, kullanım alanları ve farklı veri türlerinde nasıl uygulandığı açıklanır.
8	Ara Sınav	
9	Ağaç Tabanlı Regresyon ve Sınıflandırma Yöntemleri	Karar ağaçları, rastgele ormanlar ve gradyan artırma (gradient boosting) gibi ağaç tabanlı yöntemlerin hem regresyon hem de sınıflandırma problemlerinde kullanımı anlatılır. Bu yöntemlerin veri bölme, model esnekliği ve yüksek doğruluk sağlamadaki rolleri açıklanır.
10	Ağaç Tabanlı Regresyon ve Sınıflandırma Yöntemleri	Karar ağaçları, rastgele ormanlar ve gradyan artırma (gradient boosting) gibi ağaç tabanlı yöntemlerin hem regresyon hem de sınıflandırma problemlerinde kullanımı anlatılır. Bu yöntemlerin veri bölme, model esnekliği ve yüksek doğruluk sağlamadaki rolleri açıklanır.
11	Topluluk (Ensemble) Öğrenme Yöntemleri	Topluluk öğrenme yöntemlerinin temel prensipleri, birden fazla modeli bir araya getirerek tahmin doğruluğunu artırma yaklaşımları tanıtılır. Bagging, boosting ve stacking gibi yaygın topluluk yöntemleri ve bu yöntemlerin sınıflandırma ve regresyon problemlerindeki kullanımı üzerinde durulur.
12	Denetimsiz Öğrenme	Denetimsiz öğrenmenin temel prensipleri, etiketlenmemiş veri ile model oluşturma süreçleri tanıtılır. Kümeleme (clustering) ve boyut indirgeme (dimensionality reduction) gibi yöntemlerin keşif ve veri yapısını anlamadaki rolü açıklanır. Model değerlendirme ve performans metrikleri açıklanır.
13	Kümeleme Algoritmaları	Kümeleme algoritmalarının temel prensipleri, veri noktalarını benzerliklerine göre gruplama yöntemleri tanıtılır. K-ortalama (K-means), Hiyerarşik Kümeleme ve DBSCAN gibi yaygın kümeleme algoritmaları ve farklı veri yapılarında nasıl uygulandıkları açıklanır.
14	Boyut İndirme Yöntemleri (PCA, LDA)	Boyut indirgeme yöntemlerinin veri analizi ve görselleştirmedeki önemi, temel bileşen analizi (PCA) ve lineer ayrıştırıcı analiz (LDA)

		algoritmaları tanıtılır. PCA'nın veri varyansını maksimize ederek boyutları azaltma, LDA'nın ise sınıf ayrımını iyileştirerek özellik uzayını daraltma amaçları üzerinde durulur.
15	Final Sınavı	

Kaynaklar (Ders Kitabı ile Yardımcı Kitaplar)	
Marc Peter Deisenroth, A. Aldo Faisal, Cheng Soon Ong, Mathematics for Machine Learning, Cambridge University Press (23 April 2020)	
Tom M. Mitchell- Machine Learning - McGraw Hill Education, International Edition	
Aurélien Géron Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, O'Reilly Media, Inc. 2nd Edition	

Değerlendirme Sistemi		
Çalışmalar	Sayı	Katkı Payı
Devam		
Laboratuvar		
Uygulama		
Alan Çalışması		
Derse Özgü Staj (varsa)		
Küçük Sınavlar/Stüdyo/Kritik		
Ödev		
Sunum		
Projeler		
Rapor		
Seminer		
Ara Sınavlar/Ara Jüri	1	%40
Genel Sınav/Final Jüri/Teslim	1	% 60
	Toplam	% 100
Yarıyıl İçi Çalışmalarının Başarı Notu Katkısı		% 40
Yarıyıl Sonu Çalışmalarının Başarı Notuna Katkısı		% 60
	Toplam	% 100

Kurs Kategorisi	
Temel Meslek Dersleri	
Uzmanlık/Alan Dersleri	X
Destek Dersleri	
İletişim ve Yönetim Becerileri Dersleri	
Aktarılabılır Beceri Dersleri	

Dersin Öğrenim Çıktılarının Program Yeterlilikleri ile İlişkisi
--

No	Program Yeterlilikleri / Çıktıları	Katkı Düzeyi				
		1	2	3	4	5
1	Makine öğrenmesinin temel kavramlarını, tarihçesini ve uygulama alanlarını genel olarak tanımlar.					X
2	Denetimli öğrenme kavramını ve etiketli verilerle model oluşturma süreçlerini kavrar, sınıflandırma ve regresyon uygulamalarını anlar.					X
3	Doğrusal ve lojistik regresyon tekniklerinin temel prensiplerini açıklar, hangi durumlarda kullanıldığını öğrenir.					X
4	Maliyet fonksiyonunun ve gradyan inişi algoritmasının model eğitimi üzerindeki etkisini kavrar.		X			
5	Doğrusal olmayan algoritmaların, veri ilişkilerini modellemedeki rollerini öğrenir ve karar ağaçları, KNN, SVM gibi algoritmaları tanıtır.			X		
6	K-en yakın komşu algoritmasının temel prensiplerini ve kullanım alanlarını açıklar.			X		
7	Destek vektör makineleri ve Naive Bayes yöntemlerinin sınıflandırma problemlerindeki rollerini karşılaştırır.					X
8	Ağaç tabanlı regresyon ve sınıflandırma yöntemlerini açıklar ve uygulama alanlarını öğrenir.			X		
9	Ağaç tabanlı yöntemlerin veri bölme, model esnekliği ve doğruluk sağlamadaki rollerini anlar.					X
10	Topluluk (ensemble) öğrenme yöntemlerinin temel prensiplerini öğrenir, bagging, boosting ve stacking gibi yöntemleri kavrar.					X
11	Denetimsiz öğrenmenin temel kavramlarını, kümeleme ve boyut indirgeme gibi teknikleri kavrar.			X		
12	Kümeleme algoritmalarının veri noktalarını gruplamadaki rollerini öğrenir; K-ortalama, Hiyerarşik Kümeleme ve DBSCAN algoritmalarını tanıtır.					X
13	Boyut indirgeme yöntemleri olan PCA ve LDA'nın veri analizi ve görselleştirmedeki önemini kavrar; bu yöntemlerin uygulama alanlarını öğrenir.				X	

AKTS/İş Yüğü Tablosu			
Aktiviteler	Sayı	Süresi (Saat)	Toplam İş Yüğü
Ders saati (14 hafta x teorik ders saati)	14	3	42
Laboratuvar			
Uygulama (14 hafta x uygulama ders saati)			
Derse Özgü Staj			
Alan Çalışması			

Sunum/Seminer Hazırlama			
Projeler			
Raporlar			
Ödevler	6	3	18
Küçük Sınavlar			
Ara Sınavlara Hazırlanma Süresi	1	15	15
Genel Sınava Hazırlanma Süresi	1	15	15
Toplam İş Yüğü	(AKTS 90/15 = 6)	90	