



DERS BİLGİ FORMU

FAKÜLTE / ENSTİTÜ ADI	Fen Edebiyat Fakültesi
BÖLÜM / PROGRAM / ANABİLİM DALI ADI	İstatistik
DERSİN ADI	Makine Öğrenmesi
DERSİN KODU	IST1011
YEREL KREDİSİ	3
AKTS KREDİSİ	5
HAFTALIK DERS SAATİ	3
HAFTALIK UYGULAMA SAATİ	0
HAFTALIK LABORATUVAR SAATİ	0
ÖNKOŞULLAR	Yok
YARIYIL	Güz, Bahar
DERSİN DİLİ	İngilizce, Türkçe
DERSİN SEVİYESİ	Lisans
DERSİN TÜRÜ	Zorunlu @İstatistik Lisans Programı Zorunlu @Matematik Lisans Programı Zorunlu @Moleküler Biyoloji ve Genetik Lisans Programı
DERSİN KATEGORİSİ	Uzmanlık/Alan Dersleri
DERSİN VERİLİŞ ŞEKLİ	Yüz Yüze
DERSİ SUNAN AKADEMİK BİRİM	İstatistik Bölümü
DERSİN KOORDİNATÖRÜ	Ersay ÖZ
ASİSTAN(LAR)	Zuhal Fatma CELLAT
DERSİN AMACI	Bu dersin amacı, öğrencilerin makine öğrenmesinin temel kavramlarını ve prensiplerini anlamalarını, çeşitli algoritma türlerini ve model eğitimi ile test süreçlerini öğrenmelerini sağlamaktır. Öğrenciler, en yaygın makine öğrenmesi algoritmalarını tanıyarak, bu teknikleri gerçek dünya veri setlerine uygulayabilecek ve teorik bilgilerin pratikte nasıl kullanıldığını kavrayabileceklerdir. Ayrıca, farklı makine öğrenmesi yöntemlerinin avantajlarını ve dezavantajlarını değerlendirme yetkinliği kazanarak, belirli bir problem için en uygun algoritmayı seçme ve algoritmaların performanslarını karşılaştırma becerisi geliştireceklerdir. Öğrenciler bu sayede, makine öğrenmesi tekniklerini çeşitli problemlere etkin bir şekilde uygulayabilecek düzeye ulaşacaktır.
DERSİN İÇERİĞİ	Veri ön işleme; Öznitelik Seçimi ve Öznitelik Çıkarma; Lojistik Regresyon; Karar Ağaçları; Destek Vektör Makineleri; K-En Yakın Komşu; Naive Bayes; Kümeleme algoritmaları; Python ile makine öğrenmesi algoritmalarına yönelik uygulamalar.
DERS KİTABI / MALZEMESİ / ÖNERİLEN KAYNAKLAR	Ders Kitapları: ALP, Selçuk; ÖZ, Ersay. <i>Makine Öğrenmesinde Sınıflandırma Yöntemleri ve R Uygulamaları</i> . Nobel Akademik Yayıncılık, Ankara, 2019. ALPAYDIN, Ethem. <i>Introduction to Machine Learning</i> . MIT press, 2020. BONACCORSO, Giuseppe. <i>Machine Learning Algorithms: Popular algorithms for data science and machine learning</i> . Packt Publishing Ltd, 2018.

**Ders Öğrenim Çıktıları**

Bu dersi başarıyla tamamlayan öğrenciler,

1. Makine öğrenmesinin temel kavramlarını ve prensiplerini açıklayabileceklerdir.
2. Makine öğrenmesi algoritmalarının türleri, model eğitimi ve model test etme konularını kavrayabileceklerdir.
3. Makine öğrenmesi algoritmalarının performanslarını analiz edebileceklerdir.
4. Öğrendikleri teknikleri gerçek veri setlerine uygulama fırsatı bulabileceklerdir.
5. Verilen bir problem için farklı makine öğrenmesi yöntemlerinin avantajlarını ve dezavantajlarını değerlendirerek, hangi algoritmanın en uygun olduğunu değerlendirebileceklerdir.

DEĞERLENDİRME SİSTEMİ

Etkinlikler	Sayı	Katkı Payı
Devam/Katılım		
Laboratuvar		
Uygulama (Sözlü Sınav)		
Arazi Çalışması		
Derse Özgü Staj		
Kısa Sınavlar/Stüdyo Kritiği (Zorunlu): • İçerik: Sınav haftasına kadar işlenen konuların tümünü kapsayan sorular. • Format: Yüz yüze. Çoktan seçmeli kısa Sınav (5-10 dakika). • Detaylı Değerlendirme Kriterleri: - Derste işlenen uygulamalar ile ilgili problemleri çözebilme.	4	%20
Ödev		
Sunum/Jüri: • İçerik: Öğrenilerin kendi öğrenme süreçlerini değerlendirmelerinin ve grup sunumları yapmalarının istenmesi • Format: Grup sunumları • Detaylı Değerlendirme Kriterleri: - Öğrenilen konuların doğru bir şekilde açıklanabilmesi. - Sunum tekniklerinin doğru kullanılması.	1	%20
Proje		
Seminer/Workshop		
Ara Sınavlar: • İçerik: Sınav haftasına kadar işlenen konuların tümünü kapsayan kapsamlı sorular. • Format: Yüz yüze. Sınav (60 dakika). • Detaylı Değerlendirme Kriterleri: - Dersin temel kavramlarının anlaşıldığının gösterilmesi. - Teorik konularla ilgili problemlerin çözülebilmesi. - Teorik düşünme süreçlerinin yürütülmesi.	1	%20



Final: • İçerik: Dersin tüm içeriğini kapsayan sorular. • Format: Yüz yüze. Sınav (90 dakika). • Detaylı Değerlendirme Kriterleri: - Derste işlenen tüm konuların derinlemesine kavranmış olduğunun gösterilmesi. - İleri düzey problem çözme becerilerinin kullanılabilmesi.		1	%40
Dönem İçi Çalışmaların Başarı Notuna Katkısı			%60
Final Sınavının Başarı Notuna Katkısı			%40
TOPLAM			%100
HAFTALIK KONULAR VE İLGİLİ ÖN HAZIRLIK ÇALIŞMALARI			
HAFTALAR	KONULAR	Ön Hazırlık	
1	Konu Anlatımı: Giriş, Makine Öğrenmesi'nin tanımı ve tarihçesi Sınıf-içi Uygulama (30 dk): Makine öğrenmesinin temel kavramlarını anlamaları için basit bir veri seti üzerinden (örneğin, meyve türlerini ayırma) nasıl sınıflandırma yapılabileceği üzerine fikirlerde bulunmaları. Sınıf-içi Tartışma (10 dk): Makine öğrenmesinin tarihsel gelişimi ve günümüz teknolojilerindeki (örneğin, yapay zeka asistanları, otonom araçlar) etkisinin tartışılması.	1. Makine öğrenmesinin tanımı, temel kavramları ve tarihsel gelişimi hakkında bilgi edinilmesi; sınıflandırma problemlerine dair basit veri setleriyle yapılan örnek uygulamalar ve makine öğrenmesinin yapay zeka asistanları ile otonom araçlar gibi günümüz teknolojilerindeki kullanımının gözden geçirilmesi. Kaynak: Ders Kitabı 2, Bölüm 1.	
2	Konu Anlatımı: Veri Ön İşleme, Öznitelik Seçimi, Öznitelik Çıkarma ve Performans Ölçüm Metrikleri, Parametre Optimizasyonu – İzgara Arama (Grid Search) Yöntemi. Sınıf-içi Uygulama (30 dk): Bir veri setinde eksik verilerin doldurulması ve izgara arama yöntemiyle basit bir makine öğrenmesi modelinin hiperparametrelerinin optimize edilmesi. Sınıf-içi Tartışma (10 dk): Veri ön işlemenin ve öznitelik seçiminin model performansına etkisi ile izgara arama yönteminin pratik uygulamalarının tartışılması.	1. Veri ön işleme teknikleri, öznitelik seçimi ve çıkarma yöntemleri, performans ölçüm metrikleri ile izgara arama (Grid Search) yönteminin temel prensiplerinin incelenmesi; bu yöntemlerin makine öğrenmesi model performansına etkilerine dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 2, Bölüm 4; Ders Kitabı 3, Bölüm 3.	
3	Konu Anlatımı: Denetimli Öğrenme Algoritmaları: K-En Yakın Komşu ve Python Uygulamaları. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde K-En Yakın Komşu (KNN) algoritmasının uygulanarak basit bir sınıflandırma probleminin çözülmesi. Sınıf-içi Tartışma (10 dk): K-En Yakın Komşu algoritmasının pratik uygulamaları ve diğer denetimli öğrenme algoritmalarıyla karşılaştırılması. Kısa Sınav 1 (15 dk): Ders sonunda, derste işlenen konuları içeren bir kısa sınavın yapılması.	1. K-En Yakın Komşu (KNN) algoritmasının temel prensipleri, çalışma mantığı ve Python'da uygulamasının incelenmesi; algoritmanın pratik uygulamaları ve diğer denetimli öğrenme algoritmalarıyla karşılaştırmalarına dair örneklerin gözden geçirilerek kısa sınava hazırlık yapılması. Kaynak: Ders Kitabı 1, Bölüm 3.	
4	Konu Anlatımı: Denetimli Öğrenme Algoritmaları: Lojistik Regresyon ve Python Uygulamaları. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde lojistik regresyon modelinin uygulanması, ikili sınıflandırma probleminin çözülmesi. Sınıf-içi Tartışma (10 dk): Lojistik regresyonun sınıflandırma problemlerindeki kullanım alanları ve diğer denetimli öğrenme algoritmalarıyla avantaj/dezavantajlarının tartışılması.	1. Lojistik regresyonun temel prensipleri, ikili sınıflandırma problemlerinde kullanımı ve Python'da uygulamasının incelenmesi; algoritmanın pratik uygulama alanları ile diğer denetimli öğrenme algoritmalarına göre avantaj ve dezavantajlarına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 3, Bölüm 5.	



5	Konu Anlatımı: Denetimli Öğrenme Algoritmaları: Karar Ağaçları, Rasgele Orman ve Python Uygulamaları. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde karar ağacı veya rasgele orman modelini uygulayarak bir sınıflandırma probleminin ağaç tabanlı yöntemlerle çözülmesi. Sınıf-içi Tartışma (10 dk): Karar ağaçları ve rasgele orman algoritmalarının gerçek dünya problemlerindeki uygulamaları ve performans avantajlarının tartışılması.	1. Karar ağaçları ve rasgele orman algoritmalarının temel prensipleri, Python'da uygulamaları ve sınıflandırma problemlerindeki kullanımlarının incelenmesi; bu algoritmaların gerçek dünya uygulamaları ve performans avantajlarına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 2, Bölüm 9; Ders Kitabı 3, Bölüm 8.
6	Konu Anlatımı: Denetimli Öğrenme Algoritmaları: Naive Bayes ve Python Uygulamaları. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde Naive Bayes algoritmasının uygulanarak bir metin sınıflandırma probleminin çözülmesi. Sınıf-içi Tartışma (10 dk): Naive Bayes algoritmasının metin işleme ve olasılıksal tahminlerdeki kullanım alanları düşünüldüğünde, diğer denetimli öğrenme algoritmalarıyla karşılaştırılması. Kısa Sınav 2 (15 dk): Ders sonunda, derste işlenen konuları içeren bir kısa sınavın yapılması.	1. Naive Bayes algoritmasının temel prensipleri, özellikle metin sınıflandırma gibi olasılıksal tahminlerde kullanımı ve Python'da uygulamasının incelenmesi; algoritmanın metin işleme alanındaki uygulamaları ile diğer denetimli öğrenme algoritmalarına göre avantaj ve dezavantajlarına dair örneklerin gözden geçirilerek kısa sınava hazırlık yapılması. Kaynak: Ders Kitabı 2, Bölüm 16; Ders Kitabı 3, Bölüm 6.
7	Konu Anlatımı: Makine Öğrenmesi Genel Uygulamalar I. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde bir makine öğrenmesi algoritması uygulayarak basit bir tahmin probleminin çözülmesi. Sınıf-içi Tartışma (10 dk): Makine öğrenmesinin sağlık, finans ve e-ticaret gibi farklı sektörlerdeki genel uygulama alanlarının tartışılması.	1. Makine öğrenmesi algoritmalarının genel uygulama prensipleri ve Python'da bir veri seti üzerinde tahmin problemi çözümü için temel adımların incelenmesi; sağlık, finans ve e-ticaret sektörlerinde makine öğrenmesinin kullanımına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 1; Ders Kitabı 3.
8	Ara Sınav 1	Sınav haftasına kadar işlenen konuların tümünün tekrar edilmesi.
9	Konu Anlatımı: Denetimli Öğrenme Algoritmaları: Destek Vektör Makineleri ve Python Uygulamaları. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde Destek Vektör Makineleri (SVM) algoritmasının uygulanarak bir sınıflandırma problemi çözülmesi. Sınıf-içi Tartışma (10 dk): Destek Vektör Makinelerinin görüntü tanıma ve metin sınıflandırma gibi alanlardaki kullanımı düşünüldüğünde, diğer algoritmalarla karşılaştırılması.	1. Destek Vektör Makineleri (SVM) algoritmasının temel prensipleri, sınıflandırma problemlerinde kullanımı ve Python'da uygulamasının incelenmesi; SVM'nin görüntü tanıma ve metin sınıflandırma gibi alanlardaki uygulamaları ile diğer denetimli öğrenme algoritmalarına göre avantaj ve dezavantajlarına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 2, Bölüm 13; Ders Kitabı 3, Bölüm 7.
10	Konu Anlatımı: Topluluk Öğrenmesi Algoritmaları. Sınıf-içi Uygulama (30 dk): Python'da bir veri seti üzerinde topluluk öğrenmesi yöntemlerinden biriyle (örneğin, AdaBoost veya Gradient Boosting) bir sınıflandırma problemi çözülmesi. Sınıf-içi Tartışma (10 dk): Topluluk öğrenmesi algoritmalarının (bagging ve boosting) yüksek doğruluk sağlayan uygulamaları ve diğer makine öğrenmesi yöntemleriyle karşılaştırılması.	1. Topluluk öğrenmesi algoritmalarının (bagging ve boosting) temel prensipleri ve Python'da uygulamasının incelenmesi; bu yöntemlerin yüksek doğruluk sağlayan uygulamaları ile diğer makine öğrenmesi algoritmalarına göre avantaj ve dezavantajlarına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 3, Bölüm 8.



11	Konu Anlatımı: Denetimsiz Öğrenme Algoritmaları: K-Means Kümeleme, Hiyerarşik Kümeleme ve Python Uygulamaları. Sınıf-İçi Uygulama (30 dk): Python'da bir veri seti üzerinde K-Means veya hiyerarşik kümeleme algoritmasının uygulanarak verilerin kümelere ayrılması. Sınıf-İçi Tartışma (10 dk): K-Means ve hiyerarşik kümelemenin müşteri segmentasyonu ve veri analizi gibi alanlardaki pratik uygulamalarının tartışılması. Kısa Sınav 3 (15 dk): Ders sonunda, derste işlenen konuları içeren bir kısa sınavın yapılması.	1. K-Means ve hiyerarşik kümeleme algoritmalarının temel prensipleri, Python'da uygulamaları ve veri kümelendirme süreçlerinin incelenmesi; bu algoritmaların müşteri segmentasyonu ve veri analizi gibi pratik uygulama alanlarına dair örneklerinin gözden geçirilerek kısa sınava hazırlık yapılması. Kaynak: Ders Kitabı 2, Bölüm 7; Ders Kitabı 3, Bölüm 10.
12	Konu Anlatımı: Denetimsiz Öğrenme Algoritmaları: Temel Bileşenler Analizi (PCA) ve Python Uygulamaları. Sınıf-İçi Uygulama (30 dk): Python'da bir veri seti üzerinde Temel Bileşenler Analizi (PCA) uygulanarak veri boyutunun azaltılması ve görselleştirilmesi. Sınıf-İçi Tartışma (10 dk): PCA'nın veri sıkıştırma, görselleştirme ve makine öğrenmesi modellerinde ön işleme olarak kullanım alanlarının tartışılması.	1. Temel Bileşenler Analizi (PCA) algoritmasının temel prensipleri, veri boyutu azaltma ve görselleştirme süreçleri ile Python'da uygulamasının incelenmesi; PCA'nın veri sıkıştırma, görselleştirme ve makine öğrenmesi ön işlemindeki kullanımına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 2, Bölüm 6; Ders Kitabı 3, Bölüm 15.
13	Konu Anlatımı: Denetimsiz Öğrenme Algoritmaları: Doğrusal Diskriminant Analizi (LDA) ve Python Uygulamaları. Sınıf-İçi Uygulama (30 dk): Python'da bir veri seti üzerinde Doğrusal Diskriminant Analizi (LDA) uygulanarak sınıflar arası ayrımı maksimize eden bir boyut indirgeme yapılması. Sınıf-İçi Tartışma (10 dk): LDA'nın sınıflandırma problemlerinde ve özellik ayırt etme süreçlerinde PCA ile karşılaştırmalı kullanımının tartışılması.	1. Doğrusal Diskriminant Analizi (LDA) algoritmasının temel prensipleri, sınıflar arası ayrımı maksimize etme süreci ve Python'da uygulamasının incelenmesi; LDA'nın sınıflandırma problemlerinde ve özellik ayırt etmedeki kullanımı ile PCA'ya göre avantaj ve dezavantajlarına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 2, Bölüm 6.
14	Konu Anlatımı: Makine Öğrenmesi Genel Uygulamalar II. Sınıf-İçi Uygulama (30 dk): Python'da bir veri seti üzerinde denetimli ve denetimsiz makine öğrenmesi modellerinin uygulanması ve gerçek dünya tabanlı bir problemin çözüme kavuşturulması. Sınıf-İçi Tartışma (10 dk): Makine öğrenmesinin otomasyon, sağlık hizmetleri ve doğal dil işleme gibi alanlardaki yenilikçi uygulamalarının tartışılması. Kısa Sınav 4 (15 dk): Ders sonunda, derste işlenen konuları içeren bir kısa sınavın yapılması.	1. Denetimli ve denetimsiz makine öğrenmesi modellerinin temel prensipleri ve Python'da uygulamalarının incelenmesi; otomasyon, sağlık hizmetleri ve doğal dil işleme gibi alanlarda makine öğrenmesinin yenilikçi uygulamalarına dair örneklerin gözden geçirilerek kısa sınava hazırlık yapılması. Kaynak: Ders Kitabı 1; Ders Kitabı 3.
15	Konu Anlatımı: Makine Öğrenmesi Genel Uygulamalar III. Sınıf-İçi Uygulama (30 dk): Python'da bir veri seti üzerinde topluluk öğrenmesi algoritmalarının uygulanması ve sonuçların denetimli makine öğrenmesi yöntemleriyle karşılaştırılması. Sınıf-İçi Tartışma (10 dk): Makine öğrenmesinin otonom sistemler, görüntü işleme ve öneri sistemleri gibi ileri düzey uygulamalarının tartışılması.	1. Topluluk öğrenmesi algoritmalarının temel prensipleri, Python'da uygulamaları ve denetimli makine öğrenmesi yöntemleriyle karşılaştırmalarının incelenmesi; makine öğrenmesinin otonom sistemler, görüntü işleme ve öneri sistemleri gibi ileri düzey uygulamalarına dair örneklerin gözden geçirilmesi. Kaynak: Ders Kitabı 1; Ders Kitabı 3.
16	Final	İşlenen konuların tümünün tekrar edilmesi.

AKTS İŞYÜKÜ TABLOSU

Etkinlikler	Sayı	Süresi (Saat)	Toplam İşyükü
Ders Saati	14	3	42
Laboratuvar			



Uygulama (sözlü sınav)			
Arazi Çalışmaları			
Sınıf Dışı Ders Çalışması	14	1	14
Derse Özgü Staj			
Ödev			
Küçük Sınavlar/Stüdyo Kritiği	4	8	32
Projeler			
Sunum/Seminer	1	20	20
Ara Sınavlar (Sınav Süresi + Sınav Hazırlık Süresi)	1	20	20
Final (Sınav Süresi + Sınav Hazırlık Süresi)	1	25	25
Toplam İş yükü:			153
Toplam İş yükü / 30(s):			5.1
AKTS Kredisi:			5



COURSE INFORMATION FORM

FACULTY / GRADUATE SCHOOL	Faculty of Arts and Sciences
DEPARTMENT / PROGRAMME	Statistics
TITLE OF COURSE	Machine Learning
CODE	IST1011
LOCAL CREDIT	3
ECTS	5
LECTURE HOUR / WEEK	3
PRACTICAL HOUR / WEEK	0
LABORATORY HOUR / WEEK	0
PREREQUISITE	None
SEMESTER	Fall, Spring
COURSE LANGUAGE	English, Turkish
LEVEL OF COURSE	First Cycle
COURSE TYPE	Elective @ Bachelor Programme in Statistics Elective @ Bachelor Programme in Mathematics Elective @ Bachelor Programme in Molecular Biology and Genetics
COURSE CATEGORY	Major Area Courses
MODE OF DELIVERY	Face-to-Face
OWNER ACADEMIC UNIT	Department of Statistics
COURSE COORDINATOR	Ersay ÖZ
ASSISTANT(S)	Zuhal Fatma CELLAT
COURSE OBJECTIVES	The objective of this course is to enable students to comprehend the fundamental concepts and principles of machine learning, including various algorithm types and the processes of model training and testing. Students will become familiar with the most commonly used machine learning algorithms, gaining the ability to apply these techniques to real-world datasets and understand the practical implementation of theoretical knowledge. Furthermore, they will develop the competence to evaluate the advantages and disadvantages of different machine learning methods, select the most suitable algorithm for a given problem, and compare the performance of various algorithms. Through these skills, students will achieve the capability to effectively apply machine learning techniques to a diverse range of problems.
COURSE CONTENT	Data preprocessing; Feature Selection and Feature Extraction; Logistic Regression; Decision Trees; Support Vector Machines; K-Nearest Neighbor; Naive Bayes; Clustering algorithms; Applications of machine learning algorithms with Python.
RECOMMENDED OR REQUIRED READINGS	Coursebooks: ALP, Selçuk; ÖZ, Ersay. <i>Makine Öğrenmesinde Sınıflandırma Yöntemleri ve R Uygulamaları</i> . Nobel Akademik Yayıncılık, Ankara, 2019. ALPAYDIN, Ethem. <i>Introduction to Machine Learning</i> . MIT press, 2020. BONACCORSO, Giuseppe. <i>Machine Learning Algorithms: Popular algorithms for data science and machine learning</i> . Packt Publishing Ltd, 2018.



Course Learning Outcomes

Upon successful completion of the course, students will be able to

1. Explain the fundamental concepts and principles of machine learning.
2. Comprehend the types of machine learning algorithms, as well as topics related to model training and model testing.
3. Analyze the performance of machine learning algorithms.
4. Apply the techniques acquired to real datasets.
5. Evaluate the advantages and disadvantages of different machine learning methods for a given problem and determine which algorithm is most suitable.

EVALUATION SYSTEM

Activities	Number	Percentage of Grade
Attendance/Participation		
Laboratory		
Application (Oral Examination)		
Field Work		
Special Course Internship (Work Placement)		
Quizzes/Studio Critics: • Content: Comprehensive questions covering all topics addressed up to the exam week • Format: Face-to-face multiple-choice quiz (5-10 minutes) • Detailed Assessment Criteria: - Ability to solve problems related to the theoretical topics covered in the course	4	%20
Homework Assignments		
Presentations/Jury: • Content: Students will be asked to evaluate their own learning processes and deliver group presentations • Format: Group presentations • Detailed Assessment Criteria: - Ability to accurately explain the topics learned - Proper use of presentation techniques	1	%20
Project		
Seminar/Workshop		
Midterms: • Content: Comprehensive questions covering all topics addressed up to the exam week • Format: Face-to-face written exam. (90 minutes). • Detailed Assessment Criteria: - Demonstration of understanding of the fundamental concepts of the course - Ability to solve problems related to theoretical topics - Ability to carry out theoretical reasoning processes	1	%20
Final: • Content: Comprehensive questions covering the entire content of the course • Format: Face-to-face written exam. (90 minutes). • Detailed Assessment Criteria: - Ability to apply advanced problem-solving skills - Demonstration of a thorough understanding of all topics covered in the course	1	%40
Percentage of In-Term Studies		%60
Percentage of Final Examination		%40
TOTAL		%100



WEEKLY SUBJECTS AND RELATED PREPARATION STUDIES

WEEKS	COURSE OUTLINE	Related Preparation
1	Lecture: Introduction, Definition and History of Machine Learning. Quick Practice (30 min): Engaging students in exploring how classification can be performed on a simple dataset (e.g., distinguishing fruit types) to understand the fundamental concepts of machine learning. In-Class Discussion (10 min): Discussing the historical development of machine learning and its impact on contemporary technologies (e.g., artificial intelligence assistants, autonomous vehicles).	1. Acquisition of knowledge about the definition, fundamental concepts, and historical development of machine learning; examination of example applications using simple datasets for classification problems and review of machine learning's applications in contemporary technologies, such as artificial intelligence assistants and autonomous vehicles. Source: Recommended Reading 2, Chapter 1.
2	Lecture: Data Preprocessing, Feature Selection, Feature Engineering, Performance Evaluation Metrics ve Parameter Optimization – Grid Search Method. Quick Practice (30 min): Handling missing data in a dataset and optimizing the hyperparameters of a simple machine learning model using the grid search method. In-Class Discussion (10 min): Discussing the impact of data preprocessing and feature selection on model performance, as well as the practical applications of the grid search method.	1. Examination of the fundamental principles of data preprocessing techniques, feature selection and extraction methods, performance evaluation metrics, and the grid search method; review of examples related to the impact of these methods on machine learning model performance. Source: Recommended Reading 2, Chapter 4; Recommended Reading 3, Chapter 3.
3	Lecture: Supervised Learning Algorithms: K-Nearest Neighbors and Python Applications. Quick Practice (30 min): Implementing the K-Nearest Neighbors (KNN) algorithm in Python on a dataset to solve a simple classification problem. In-Class Discussion (10 min): Discussing the practical applications of the K-Nearest Neighbors algorithm and its comparison with other supervised learning algorithms. Quiz 1 (15 dk.): A quiz at the end of the class covering the topics taught during the session.	1. Examination of the fundamental principles, operational logic, and implementation of the K-Nearest Neighbors (KNN) algorithm in Python; review of examples related to its practical applications and comparisons with other supervised learning algorithms, in preparation for a short quiz. Source: Recommended Reading 1, Chapter 3.
4	Lecture: Supervised Learning Algorithms: Logistic Regression and Python Applications. Quick Practice (30 min): Implementing a logistic regression model in Python on a dataset to solve a binary classification problem. In-Class Discussion (10 min): Discussing the applications of logistic regression in classification problems and its advantages and disadvantages compared to other supervised learning algorithms.	1. Examination of the fundamental principles of logistic regression, its application in binary classification problems, and its implementation in Python; review of examples related to its practical applications and its advantages and disadvantages compared to other supervised learning algorithms. Source: Recommended Reading 3, Chapter 5.
5	Lecture: Supervised Learning Algorithms: Decision Trees, Random Forest and Python Applications. Quick Practice (30 min): Implementing a decision tree or random forest model in Python on a dataset to solve a classification problem using tree-based methods. In-Class Discussion (10 min): Discussing the applications of decision trees and random forest algorithms in real-world problems and their performance advantages.	1. Examination of the fundamental principles of decision trees and random forest algorithms, their implementation in Python, and their applications in classification problems; review of examples related to their real-world applications and performance advantages. Source: Recommended Reading 2, Chapter 9; Recommended Reading 3, Chapter 8.



6	Lecture: Supervised Learning Algorithms: Naive Bayes and Python Applications. Quick Practice (30 min): Implementing the Naive Bayes algorithm in Python on a dataset to solve a text classification problem. In-Class Discussion (10 min): Comparing the Naive Bayes algorithm with other supervised learning algorithms, considering its applications in text processing and probabilistic predictions. Quiz 2 (15 dk.): A quiz at the end of the class covering the topics taught during the session.	1. Examination of the fundamental principles of the Naive Bayes algorithm, particularly its application in probabilistic predictions such as text classification, and its implementation in Python; review of examples related to its applications in text processing, as well as its advantages and disadvantages compared to other supervised learning algorithms, in preparation for a short quiz. Source: Recommended Reading 2, Chapter 16; Recommended Reading 3, Chapter 6.
7	Lecture: Machine Learning Applications I. Quick Practice (30 min): Implementing a machine learning algorithm in Python on a dataset to solve a simple prediction problem. In-Class Discussion (10 min): Discussing the general applications of machine learning in various sectors, such as healthcare, finance, and e-commerce.	1. Examination of the general application principles of machine learning algorithms and the fundamental steps for solving a prediction problem on a dataset using Python; review of examples related to the use of machine learning in the healthcare, finance, and e-commerce sectors. Source: Recommended Reading 1; Recommended Reading 3.
8	Midterm 1	Review of all topics covered up to the exam week.
9	Lecture: Supervised Learning Algorithms: Support Vector Machines and Python Applications. Quick Practice (30 min): Implementing the Support Vector Machines (SVM) algorithm in Python on a dataset to solve a classification problem. In-Class Discussion (10 min): Comparing Support Vector Machines with other algorithms, considering their applications in areas such as image recognition and text classification.	1. Examination of the fundamental principles of the Support Vector Machines (SVM) algorithm, its application in classification problems, and its implementation in Python; review of examples related to SVM's applications in areas such as image recognition and text classification, along with its advantages and disadvantages compared to other supervised learning algorithms. Source: Recommended Reading 2, Chapter 13; Recommended Reading 3, Chapter 7.
10	Lecture: Ensemble Learning Algorithms. Quick Practice (30 min): Implementing an ensemble learning method (e.g., AdaBoost or Gradient Boosting) in Python on a dataset to solve a classification problem. In-Class Discussion (10 min): Discussing the high-accuracy applications of ensemble learning algorithms (bagging and boosting) and their comparison with other machine learning methods.	1. Examination of the fundamental principles of ensemble learning algorithms (bagging and boosting) and their implementation in Python; review of examples related to their high-accuracy applications and their advantages and disadvantages compared to other machine learning algorithms. Source: Recommended Reading 3, Chapter 8.
11	Lecture: Unsupervised Learning Algorithms: K-Means Clustering, Hierarchical Clustering and Python Application. Quick Practice (30 min): Implementing the K-Means or hierarchical clustering algorithm in Python on a dataset to segment data into clusters. In-Class Discussion (10 min): Discussing the practical applications of K-Means and hierarchical clustering in areas such as customer segmentation and data analysis. Quiz 3 (15 dk.): A quiz at the end of the class covering the topics taught during the session.	1. Examination of the fundamental principles of K-Means and hierarchical clustering algorithms, their implementation in Python, and the data clustering process; review of examples related to their practical applications in areas such as customer segmentation and data analysis, in preparation for a short quiz. Source: Recommended Reading 2, Chapter 7; Recommended Reading 3, Chapter 10.



12	Lecture: Unsupervised Learning Algorithms: Principal Component Analysis (PCA) and Python Application. Quick Practice (30 min): Applying Principal Component Analysis (PCA) in Python on a dataset to reduce data dimensionality and visualize the results. In-Class Discussion (10 min): Discussing the applications of PCA in data compression, visualization, and as a preprocessing step in machine learning models.	1. Examination of the fundamental principles of the Principal Component Analysis (PCA) algorithm, its processes for data dimensionality reduction and visualization, and its implementation in Python; review of examples related to PCA's applications in data compression, visualization, and preprocessing for machine learning. Source: Recommended Reading 2, Chapter 6; Recommended Reading 3, Chapter 15.
13	Lecture: Unsupervised Learning Algorithms: Linear Discriminant Analysis (LDA) and Python Application. Quick Practice (30 min): Applying Linear Discriminant Analysis (LDA) in Python on a dataset to perform dimensionality reduction that maximizes class separability. In-Class Discussion (10 min): Discussing the comparative use of LDA in classification problems and feature discrimination processes relative to PCA.	1. Examination of the fundamental principles of the Linear Discriminant Analysis (LDA) algorithm, its process for maximizing class separability, and its implementation in Python; review of examples related to LDA's applications in classification problems and feature discrimination, along with its advantages and disadvantages compared to PCA. Source: Recommended Reading 2, Chapter 6.
14	Lecture: Machine Learning Applications II. Quick Practice (30 min): Applying supervised and unsupervised machine learning models in Python on a dataset to address a real-world problem. In-Class Discussion (10 min): Discussing the innovative applications of machine learning in fields such as automation, healthcare, and natural language processing. Quiz 4 (15 dk.): A quiz at the end of the class covering the topics taught during the session.	1. Examination of the fundamental principles of supervised and unsupervised machine learning models and their implementation in Python; review of examples related to the innovative applications of machine learning in fields such as automation, healthcare, and natural language processing, in preparation for a short quiz. Source: Recommended Reading 1; Recommended Reading 3.
15	Lecture: Machine Learning Applications III. Quick Practice (30 min): Applying ensemble learning algorithms in Python on a dataset and comparing the results with supervised machine learning methods. In-Class Discussion (10 min): Discussing advanced applications of machine learning in areas such as autonomous systems, image processing, and recommendation systems.	1. Examination of the fundamental principles of ensemble learning algorithms, their implementation in Python, and their comparison with supervised machine learning methods; review of examples related to the advanced applications of machine learning in areas such as autonomous systems, image processing, and recommendation systems. Source: Recommended Reading 1; Recommended Reading 3.
16	Final	Review of all topics covered.

ECTS WORKLOAD TABLE

Activities	Number	Duration (Hour)	Total Workload
Course Hours	14	3	42
Laboratory			
Application			
Field Work			
Study Hours Out of Class	14	1	14
Special Course Internship (Work Placement)			
Homework Assignments			
Quizzes/Studio Critics	4	8	32
Project			
Presentations / Seminar	1	20	20



Mid-Terms (Examination Duration + Examination Prep. Duration)	1	20	20
Final (Examination Duration + Examination Prep. Duration)	1	1	25
Total Workload:			153
Total Workload / 30(h):			5.1
ECTS Credit:			5



Ders Öğrenim Çıktısı & Program Çıktısı Matrisi

	<u>DÖC-1</u>	<u>DÖC-2</u>	<u>DÖC-3</u>	<u>DÖC-4</u>	<u>DÖC-5</u>
<u>PC-1</u> İstatistik biliminin temelini oluşturan teorik ve uygulamalı alanlardaki bilgilerini, alanla ilgili problemleri tanımlama, modelleme ve çözüm üretmede kullanabileceklerdir. / Use their theoretical and applied knowledge in the science of statistics to identify, model, and solve problems related to the field.					
<u>PC-2</u> İstatistiksel problemlerin belirlenmesi, uygun veri toplama yöntemlerinin seçilmesi, verinin düzenlenmesi ve yorumlanması süreçlerinde yeterlilik gösterecek ve bu problemlerin çözümünde gerekli analiz ve modelleme yöntemlerini seçip uygulayabileceklerdir. / Demonstrate competence in identifying statistical problems, selecting appropriate data collection methods, organizing and interpreting data, and select and apply necessary analysis and modelling methods to solve these problems.	<u>5</u>	<u>5</u>	<u>5</u>	<u>5</u>	<u>5</u>
<u>PC-3</u> Herhangi bir olgu, süreç ya da ürünü istatistiksel bakış açısıyla analiz edip yorumlayabilecek ve karşılaştıkları sorunlara uygun modern istatistiksel yöntemlerle çözüm geliştirebileceklerdir. / Analyse and interpret a phenomenon, process, or product from a statistical perspective and develop solutions to encountered problems using appropriate modern statistical methods.					
<u>PC-4</u> Disiplinlerarası bir yaklaşımla, farklı alanlarda edinmiş oldukları bilgileri sentezleyebileceklerdir. / Synthesise knowledge acquired from different disciplines through an interdisciplinary approach.					
<u>PC-5</u> İstatistik alanında edindikleri bilgi birikimlerini ve istatistiksel düşünme becerilerini, teorik istatistik, veri bilimi, finansal istatistik, sağlık bilimlerinde istatistik gibi disiplin-îçi ve disiplinlerarası uzmanlık alanlarında geliştirebileceklerdir. / Advance their acquired knowledge in statistics and statistical thinking skills in both disciplinary and interdisciplinary areas of specialisation such as theoretical statistics, data science, financial statistics, and statistics in health sciences.	<u>4</u>	<u>4</u>	<u>4</u>	<u>4</u>	<u>4</u>
<u>PC-6</u> İstatistik alanında yaygın olarak kullanılan en az bir programlama dili ile bilgisayar ve yapay zekâ teknolojilerini, problemleri çözmek, veri analizi yapmak ve simülasyonlar gerçekleştirmek için kullanabileceklerdir. / Use at least one programming language and computer and artificial intelligence technologies widely employed in statistics for problem-solving, data analysis, and simulations.	<u>5</u>	<u>5</u>	<u>5</u>	<u>5</u>	<u>5</u>
<u>PC-7</u> İstatistik ve ilgili alanlardaki bilimsel ve teknolojik gelişmeleri izleyebilecek, kariyer fırsatlarını değerlendirerek kişisel ve mesleki gelişim hedeflerini belirleyebilecek ve bu hedeflere					



ulaşmak için hayat boyu öğrenme stratejilerini kullanabileceklerdir. / Follow scientific and technological developments in statistics and related fields, assess career opportunities, identify personal and professional development goals, and adopt lifelong learning strategies to achieve these goals.					
PC-8 Bilimsel araştırmalarını ve mesleki faaliyetlerini yürütürken doğabilecek hukuksal sonuçları ve toplumsal etkileri dikkate alarak mesleki etik ilkeler, kalite standartları ile evrensel değerler doğrultusunda ve sosyal sorumluluk bilinci ve adalet duygusuyla hareket edebileceklerdir. / Act with a sense of social responsibility and justice and in accordance with professional ethical principles, quality standards, and universal values by taking into account potential legal and societal consequences of their scientific research and professional activities.					
PC-9 Bireysel olarak ya da takımlarda etkin biçimde çalışabileceklerdir. / Work effectively both independently and as part of a team.					
PC-10 İstatistik alanında güvenilir bilgi kaynaklarına ulaşarak literatür taraması yapabilecek ve akademik araştırma tasarlayıp yürütebileceklerdir. / Access reliable sources of information, conduct literature reviews, and design and carry out academic research in the field of statistics.					
PC-11 İstatistiksel konuları, teorileri, ispatları, araştırmaları ve problem çözümlerini, istatistiksel terminoloji kullanarak tüm paydaşlara Türkçe ve İngilizcede sözlü ve yazılı olarak etkili biçimde aktarabileceklerdir. / Effectively communicate statistical topics, theories, proofs, research, and problem solutions to all relevant stakeholders using appropriate mathematical terminology, both orally and in writing, in Turkish and in English.					