



T.C.

**İSTANBUL RUMELİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ**

**UZAKTAN EĞİTİM ÖĞRENCİLERİNİN
BAŞARILARININ FPFS-kNN İLE TAHMİNİ**

Sema KILIÇ

İşletme Anabilim Dalı

Yönetim Bilişim Sistemleri Programı

İSTANBUL

2023

T.C.
İSTANBUL RUMELİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ

UZAKTAN EĞİTİM ÖĞRENCİLERİNİN
BAŞARILARININ FPFS-kNN İLE TAHMİNİ

Sema KILIÇ

İşletme Anabilim Dalı

Yönetim Bilişim Sistemleri Yüksek Lisans Programı

07/06/2023

Tez Danışmanı:

Dr. Öğr. Üyesi Samet MEMİŞ

İSTANBUL

2023

TEŐEKKÜR

Bu tezin gerekleŐtirilmesinde, alıŐmam boyunca benden bir an olsun desteęini ve yardımlarını esirgemeyen, gzel dilekleri ile beni motive eden, yol gstericilięi ile yeni bakıŐ aıları kazanmamı saęlayan ok deęerli hocam, saygı deęer danıŐmanım Dr. Öğr. Üyesi Samet MEMİŐ'e, hayatımın her evresinde bana destek olan, her zaman yanımda olduklarını hissettiren anneme, babama ve kardeŐlerime sonsuz teŐekkrlerimi sunarım.

Sema KILIÇ

İstanbul, Haziran 2023

SİMGELER VE KISALTMALAR

ÖBS	Öğrenci Bilgi Sistemi
Moodle	Modular Object Oriented Dynamic Learning Environment (Esnek Nesne Yönelimli Dinamik Öğrenme Ortamı)
k-NN	k-En Yakın Komşu (k-Nearest Neighbor)
<i>fpfs</i> -matris	Bulanık parametrelili bulanık esnek matris
FPFS-kNN	Bulanık Parametrelili Bulanık Esnek kNN
TP	Doğru pozitif (True Positive)
TN	Doğru negatif (True Negative)
FP	Yanlış pozitif (False Positive)
FN	Yanlış negatif (False Negative)
Acc	Doğruluk (Accuracy)
Pre	Kesinlik (Precision)
Rec	Duyarlık (Recall)
MacF	Makro F-skor (Macro F-score)
MicF	Mikro F-skor (Micro F-score)

ÖZET

UZAKTAN EĞİTİM ÖĞRENCİLERİNİN BAŞARILARININ FPFS-kNN İLE TAHMİNİ

Sema KILIÇ

İstanbul Rumeli Üniversitesi

Lisansüstü Eğitim Enstitüsü

İşletme Anabilim Dalı

Yönetim Bilişim Sistemleri Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Samet MEMİŞ

07/06/2023, XLVII

Uzaktan eğitim sistemleri gelişen eğitim teknolojileri ile daha yaygın hale gelmesiyle birlikte paralelinde öğrencilerin başarılarının tahmin edilmesi konusu da önem kazanmıştır. Öğrenci başarısını analiz etmek, öğrenciler, eğitimciler ve akademik kurumlar için de önemlidir.

Bu çalışma, İstanbul Arel Üniversitesi'nde uzaktan eğitim yolu ile verilen Türk Dili I, Atatürk İlkeleri ve İnkılap Tarihi I, İngilizce I ortak derslerini alan bazı öğrencilerin 14 hafta süresince yapılan eş zamanlı ve eş zamansız ders etkinliklerine katılımlarının bir veri setini oluşturmaya ve bu veri setini bulanık parametrelili bulanık esnek k-en yakın komşu (FPFS-kNN) algoritması ile kullanarak öğrencilerin başarılarının tahmin edilmesi üzerine odaklanmıştır. İlk olarak, eğitim öğretim faaliyetlerinin 14 haftaya yayıldığı bir dönem içindeki ders etkinliklerine katılım bilgileri anonimleştirilerek ham veriler elde edilmiştir. Daha sonra, bu veriler makine öğreniminde kullanılmak üzere işlenmiştir. Verilerden geçtikçe ve harf notları ile iki sınıflı ve çok sınıflı olmak üzere iki adet veri seti oluşturulmuştur. Ardından, her iki veri setine FPFS-kNN ile birlikte bilinen ve son teknoloji bazı makine öğrenimi yöntemleri uygulanmıştır. Sonuçlar, doğruluk, kesinlik, duyarlılık, macro F-skor ve micro F-skor performans metrikleri kullanılarak karşılaştırılmıştır. Son olarak, sonuçlar ve makine öğreniminin öğrenci başarı tahmini üzerine kullanımı hakkında bir tartışmaya yer verilmiştir.

Anahtar sözcükler: Uzaktan eğitim, Makine öğrenimi, Moodle, FPFS-kNN, Başarı tahmini

ABSTRACT

PREDICTION OF THE SUCCESS OF DISTANCE STUDENTS VIA FPFS-kNN

Sema KILIÇ

İstanbul Rumeli University

Graduate Education Institute

Department of Management Administration

Master of Science Thesis in Management Information Systems

Supervisor: Asst. Prof. Dr. Samet MEMİŞ

06/07/2023, XLVII

As distance education systems have become more familiar with virtual education technologies, the issue of estimating students' success has also gained importance. Analyzing student achievement is essential for students, educators, and academic institutions.

This study aims to create a dataset of the participation of some students who took Turkish Language I, Atatürk's Principles and History of Revolution I, and English I joint courses given via distance education at Istanbul Arel University to synchronous and asynchronous course activities for 14 weeks and to predict the students' success by employing fuzzy parameterized fuzzy soft k-nearest neighbor (FPFS-kNN) and the dataset. First, the raw data was obtained by anonymizing the participation information in the lectures in a period in which the education period was spread over 14 weeks. Later, these data were processed to be used in machine use. Two data sets were obtained from the raw data whose class labels consist of two-class (pass/fail) and multi-class (letter grades). Then, FPFS-kNN and well-known/state-of-the-art machine learning methods were applied to the datasets. Results were compared by utilizing accuracy, precision, macro F-score, and micro F-score performance metrics. Finally, a discussion of performance results and the use of machine learning in predicting student achievement is provided.

Keywords: Distance learning, Machine learning, Moodle, FPFS-kNN, Prediction of the Success

İÇİNDEKİLER

Sayfa No

TEŞEKKÜR.....	ii
SİMGELER VE KISALTMALAR	iii
ÖZET	iv
ABSTRACT.....	v
ŞEKİLLER DİZİNİ	ii
TABLolar DİZİNİ.....	ii
BÖLÜM 1	
GİRİŞ	1
BÖLÜM 2	
TEMEL KAVRAMLAR	6
2.1. Uzaktan Eğitim.....	6
2.2. Moodle Öğrenme Yönetim Sistemi	7
2.3. Öğrenci Bilgi Sistemi	10
2.4. Makine Öğrenimi	11
2.5. Bulanık Parametrelili Bulanık Esnek Matrisler (<i>fpfs</i> -matrisler).....	15
2.6. FPFS-kNN Algoritması.....	16
BÖLÜM 3	
ÖĞRENCİ VERİLERİNİN TOPLANMASI VE İŞLENMESİ	19
3.1. Verilerin Toplanması	19
3.2. Verilerin İşlenmesi	26
BÖLÜM 4	
FPFS-kNN İLE ÖĞRENCİ PERFORMANSI TAHMİNİ	27
4.1. Moodle Öğrenme Sistemi Veri Setlerinin Özellikleri.....	27
4.2. Sınıflandırma Problemi için Performans Metrikleri	28
4.3. FPFS-kNN'nin Moodle Öğrenme Sistemi Veri Setleri Üzerine Uygulanması	30
BÖLÜM 5	
SONUÇ VE ÖNERİLER.....	34
KAYNAKLAR	36

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 1. Moodle, Eğitimci, Derslerim Ana Sayfası.....	9
Şekil 2. Moodle Ders Sayfası Duyurular Bölümü	9
Şekil 3. Moodle Ders Etkinlikleri Sayfası	10
Şekil 4. Öğrenci Bilgi Sistemi Arayüzü.....	11
Şekil 5. Makine öğrenimi türleri (Anisimova, 2019, 27 Kasım; Memiş, 2021).....	13
Şekil 6. FPFS-kNN algoritma akış diagram (Memiş ve diğerleri, 2022)	18
Şekil 7. Moodle Öğrenme Yönetim Sistemi ATA ders sayfası	20
Şekil 8. Raporlar (Dijital ayak izleri) sayfası	21
Şekil 9. Etkinlik bazında rapor indirme sayfası	21
Şekil 10. Bir öğrenci verisi için özelliklerin dağılımı.....	27
Şekil 11. İkili sınıflı veri setlerindeki 50 çalıştırma için Acc değerlerinin kutu grafikleri..	33

TABLolar DİZİNİ

	Sayfa No
Tablo 1. Haftalık ders sunumu/ders notu 14 haftalık dijital ayak izleri raporu	22
Tablo 2. Haftalık dış kaynak (okuma metinleri/video) 14 haftalık dijital ayak izleri raporu	23
Tablo 3. Haftalık soru 14 haftalık dijital ayak izleri raporu	24
Tablo 4. Canlı ders anlatımı dijital ayak izleri raporu	25
Tablo 5. Başarı notları	25
Tablo 6. Verilerin işlenmiş versiyonundan bir örnek	26
Tablo 7. Tez çalışmasında oluşturulan veri setlerinin özellikleri	28
Tablo 8. İki sınıflı veri setleri için simülasyon sonuçları	31
Tablo 9. Çok sınıflı veri setleri için simülasyon sonuçları	32



BÖLÜM 1

GİRİŞ

Uzaktan eğitim sistemleri gelişen teknoloji ile her geçen gün daha yaygın hale geldiği için paralelinde öğrencilerin başarılarının tahmin edilmesi konusu da gün geçtikçe önem kazanmıştır. Not başarısı bir öğrencinin akademik gelişimini önemli oranda etkiler. Bu nedenle, öğrenci performansını ve notlarını analiz etmeye ve sınıflandırmaya ihtiyaç duyulmaktadır. Öğrenci başarısını analiz etmek, eğitimciler kadar akademik kurumlar için de önemlidir. Öğrencilerin öğrenimine fayda sağlamak ve eğitimin kalitesini arttırmak için önemlidir. Makine öğreniminin yeteneklerinin bu alanda kullanılması elzemdir.

Uzaktan eğitimde öğrencilerin başarılarına etki eden farklı ders etkinlikleri vardır. Moodle Öğrenme Yönetim Sistemi tüm öğrencilerin bu ders etkinliklerine katılım günlüklerini raporlayan önemli bir veri kaynağıdır. Toplanan bu veriler tek başına anlam ifade etmezler. Ancak bu ders etkinliklerine dair veriler analiz edilerek anlamlı bilgilere ulaşılabilir. Öğrenci Bilgi Sistemi (ÖBS) de başarı notlarına dair verilere ulaşım imkânı sağlar. Bu sistemlerdeki verilerin analizi ile elde edilen bilgiler dönem içi öğrenci katılımını arttırmak için kullanılarak başarıyı arttırabilir. Gelecek dönemlerde de başarı arttırıcı politikalar oluşturmak için kullanılabilir. Analiz sonucu elde edilen tüm bilgiler öğrencilere, öğretim elemanlarına ve akademik kurumlara fayda sağlayabilir, yükseköğretimde öğrenme sürecine olumlu katkı sağlayabilir.

Bu çalışma, uzaktan eğitim öğrencilerinin bir yarıyıl süresince Moodle Öğrenme Yönetim Sistemi ders sayfasındaki dijital ayak izleri kullanılarak makine öğreniminde kullanılacak veri seti oluşturmak ve bu veri seti ve bulanık parametrelili bulanık esnek k-en yakın komşu (FPFS-kNN) (Memiş, Enginoğlu ve Erkan, 2022c) algoritması ile öğrencilerin başarılarının tahmini üzerine odaklanmaktadır. Böylece öğretim programındaki eksikliklerin ortaya çıkmasında ve iyileştirilmesinde somut veriler ortaya koyacağı öngörülmektedir. Ayrıca, makine öğreniminin bu alanda kullanımını konusunda alanyazına katkı sağlayacaktır.

Alanyazında daha önce yapılan çalışmalar tarandığında öğrenci başarılarının makine öğrenmesi ile tahmini üzerine yapılan farklı çalışmalar görülmüştür.

Koyuncu, Kılıç ve Göksun (2022) Türkiye'deki bir devlet üniversitesinin öğrencilerinin, ortalama sayfa görüntüleme sayısı (günlük, haftalık, aylık ve toplam) verileri, sisteme giriş yapılan ortalama gün sayısına (haftalık ve aylık) dair veriler toplam hafta sayısı

ve sistemde geçirilen toplam süre (dk) gibi öğrenme yönetim sistemindeki ders etkinliklerini analiz etmiştir. Yapılan analizle başarı, başarısızlık durumları arasındaki ilişki incelenmiştir. Çalışmada bir dönem boyunca 14 haftalık zaman diliminde ders sunum videosu, iki eş zamanlı ders, her hafta paylaşılan pdf formatındaki ders içeriği ve haftalık tartışmalara ait dijital ayak izleri kullanılmıştır. Çalışma ile: Öğrencileri başarılı ve başarısız olarak sınıflandırmada hangi makine öğrenmesi tekniği en yüksek performansa sahip, en yüksek sınıflandırma performansına sahip makine öğreniminin sonuçları nelerdir, tüm bu değişkenlerin sınıflamadaki önem derecesi nedir sorularına cevap aranmıştır.

Çalışmanın sonucunda elde edilen bilgilere göre öğrencilerin başarılarının sınıflandırılmasında en etkili yöntem Fisher's Linear Discriminant Analysis (FLDA) (Li ve Wang, 2014) ve en etkili değişken öğrenme yönetim sistemine aylık ortalama giriş sayısıdır. Öğrencilerin tartışma ve canlı derslere katılımının da başarılarıyla doğrudan ilişkisi vardır. Başarıyı arttırmak için öğrenci hareketleri izlenerek ortalamadan az giriş yapan öğrenciler teşvik edilebilir (Koyuncu ve diğerleri, 2022).

Altınsoy (2019) HarvardX-MITX çevrimiçi derslerinin (Akademik Yıl 2013: Güz 2012, Bahar 2013 ve Yaz 2013) verilerini yapay zekâ algoritmalarıyla sınıflandırılarak yükseköğretim kurumlarında eğitsel metotların başarıya olan etkisi hakkında analizler yapmıştır. Buradaki her bir kayıt bir öğrencinin edX dersindeki bir etkinliğine karşılık gelir (Ho ve diğerleri, 2014). Yapılan çalışma ile hem üniversite yönetimine hem de öğrencilere eksikliklerini göstererek başarıyı arttıracak faydalı bilgiler sunmak hedeflenmiştir. Çalışma kapsamında uzaktan eğitim öğrencilerinin başarılarını etkileyen kriterler tespit edilerek veriler toplanmış ve veri setleri oluşturulmuştur. Başarı tahmininde Sade Bayes, Bayes Net, Destek Vektör Makineleri (SVM), Lojistik Regresyon, Rastgele Orman, Rastgele Ağaç ve Karar Ağaçları algoritmaları kullanılmıştır. Model oluşturularak öğrencilerin başarıları makine öğrenmesi ile tahmin edilmeye çalışılmıştır. Visual Studio 2017 platformu üzerinde C# dili kullanılarak Weka programı ve Microsoft SQL Server Management Studio (2017) yardımıyla öğrenci başarı durumlarını tahmin eden bir arayüz geliştirilmiştir.

Yıldız (2018) uzaktan eğitim öğrencilerinin Moodle Öğrenme Yönetim Sisteminde, 6 hafta boyunca etkinliklere erişimi ile oluşan dijital ayak izleri verileri kullanılarak yıl sonundaki başarı durumu makine öğrenimi ile tahmin etmeye çalışmıştır. 6 haftanın sonunda elde edilen verilerin kullanılarak analiz edilmesi şu açıdan önemlidir: Elde edilen bulgularla eğitimi veren kurum, başarı düzeyi düşük öğrenciler için farklı öğrenme yöntemleri geliştirebilir veya öğrenme amaçlarıyla uyumlu başarıyı arttırıcı farklı eğitsel yöntemler kullanabilir. Bu çalışmada ders sorumluları ve yöneticilere uyarı sistemi görevini üstlenecek

bilgi sonuçlarını sağlamak için bir öğrenci öğrenme yönetim sistemine hangi aralıklarla, ne zaman giriş yaptı, sistemde aktif kalma süresi nedir gibi sorularının cevaplarına yönelik veriler kullanılmıştır. Öğrenme yönetim sistemi içerisindeki öğrenci hareketleri belirsizlikler içermektedir. Bu nedenle problem çözümünde en iyi sonucu verecek bulanık mantık modeli ile matematiksel model kullanılmıştır. Problem çözümü için bulanık mantık yanında kümeleme yöntemleri (çıkarımlı kümeleme, k-ortalamlar, bulanık c-ortalamlar) de uygulanarak hibrit modelleme yapılmıştır. Eğitim verisi, test verisi ve doğrulama verisi olmak üzere 3 çeşit veri seti oluşturulmuştur. Ortalamada en yüksek doğruluk oranı bulanık c-ortalamlar kümeleme yöntemi ile bulunmuştur. Sayısal tahminle birlikte, kategorik olarak geçti-kaldı şeklinde de tahmin yapılmıştır.

Azimi, Popa ve Cucić, (2020) çevrimiçi öğrenme yönetim sisteminden toplanan verilerin öğrencilerin genel performansını tahmin etmek için kullanılabilirliğini ve bunun yanı sıra öğrencilerin performansını arttırmak üzere zamanında müdahale stratejileri önermek için de kullanılabilirliğini göstermeyi amaçlamaktadır. Çalışmanın sonuçlarına göre öğrencilerin performansını arttırmak için dönemin yarısı gibi erken bir zamanda etkili müdahale stratejilerinin önerilebileceği ortaya konulmuştur. Çalışmada, Finlandiya'daki bir üniversitenin Moodle çevrimiçi öğrenme yönetim sistemi üzerinde dokuz hafta süren tamamen çevrimiçi bir kursa kayıtlı 107 öğrenciden anonimleştirilmiş veriler toplanmıştır. Veriler, öğrencilerin notlarını, kurs günlüklerini ve öğrencilerin etkileşimlerini içermektedir. Veri analizi sonucunda, derste başarısız olan öğrencilerin, öğrenci başına ortalama 92 etkileşimle az sayıda etkileşime sahip olduğu, düşük başarılı öğrencilerin öğrenci başına ortalama 273 etkileşime sahip olduğu ve yüksek başarılı öğrencilerin ise öğrenci başına ortalama 450 etkileşime sahip olduğu belirlenmiştir. Bu çalışma, çevrimiçi öğrenme yönetim sistemleri üzerinden toplanan verilerin kullanılarak öğrencilerin performansını arttırmak için erken müdahale stratejileri önerilebileceğini ve makine öğrenimi gibi teknolojilerin bu alanda etkili bir şekilde kullanılabilirliğini ortaya koymaktadır.

Minaei-Bidgoli, Kashy, Kortemeyer ve Punch, öğrencilerin yıl sonu başarı notlarını tahmin etmek için web tabanlı bir eğitim sisteminde öğrencilerin etkileşimi ile oluşan verileri sınıflandırmaya yönelik bir yaklaşım sunmaktadır. Bu veri tabanı öğrencilerin her bir kaynağa ne zaman ne kadar süreyle ve kaç kez eriştikleri, verilen problemlere verdikleri doğru yanıtların sayısı, doğru ve yanlış yanıt verme şekilleri gibi çeşitli değişkenleri kaydetmektedir. Bir dizi örüntü sınıflandırıcı tasarlanmakta, uygulanmakta, değerlendirilmekte ve performansları çevrimiçi bir ders veri kümesi üzerinde karşılaştırılmaktadır. Birden fazla sınıflandırıcının kombinasyonu, sınıflandırma

performansında önemli bir iyileşmeye yol açmaktadır. Ayrıca genel bir algoritma aracılığıyla kullanılan özelliklerin uygun bir şekilde ağırlıklandırılmasını öğrenerek tahmin doğruluğunu daha da geliştirmektedir. Kullanılan yöntem özellikle çok büyük sınıflarda öğrencilerin başarı durumlarının erken tespit edilmesinde ve eğitmenin uygun tavsiyelerde bulunmasına olanak sağlamada dikkate değer bir fayda sağlayabilir.

Bognar, Fauszt (2020), Macaristan'daki Dunaujvaros Üniversitesi'nde Uygulamalı İstatistik dersine kayıtlı 57 öğrencinin başarısını tahmin etmek için 16 farklı Moodle makine öğrenimi modeli geliştirerek "iyilik" açısından test edilmiştir. Başarı çeşitli faktörlerden etkilenebilir, ancak burada yalnızca öğrencilerin bilişsel faaliyetleri incelenmiştir. Modellerde kullanılanlar: PDF ders notlarının görüntülenme sayısı, videolu derslerin görüntülenme sayısı, alıştırma kitaplarının görüntülenme sayısı, Minitab videolarının (istatistiksel bir yazılımla problem çözmeye yönelik videolar) görüntülenme sayısı, mini sınavların deneme sayısı ve öğrencilerin mini sınavlarda aldıkları en iyi notlar. Modeller, yordayıcıların sayısı ve türleri bakımından farklılık göstermiştir. Model eğitimi ve değerlendirmesi için İkili Lojistik Regresyon kullanılmıştır. Modellerin hedefi, bir öğrencinin dersi geçmek için gereken minimum notu alamama riski altında olup olmadığını göstermektedir. Farklı modellerin değerlendirildikten sonra, öğrencilerin başarısının tamamen bilişsel faaliyetlerden tahmin edilebileceği, ancak tahmin güçlerinin çok çeşitli olduğu gösterilmiştir. Sınavların tahmin edicileri başarı üzerinde en büyük etkiye sahiptir, ancak modeli daha az etkili diğer tahmin edicilerle destekleyerek çok daha iyi bir model oluşturulabilir.

Bu çalışmada, modelleme becerisi ile öne çıkan matematiksel araçlardan biri olan bulanık parametrelili bulanık esnek matris (*fpfs*-matris) kavramı tabanlı Bulanık Parametrelili Bulanık Esnek k-En Yakın Komşu (FPFS-kNN) (Memiş ve diğerleri, 2022c) algoritması öğrenci başarılarının tahmini üzerine uygulanmaktadır.

Çalışmanın ikinci bölümünde çalışmanın sonraki bölümlerinde ihtiyaç duyulan temel kavramlara yer verilmiştir. Üçüncü bölümde, Moodle öğrenme sistemi ve ÖBS yardımıyla Atatürk İlkeleri ve İnkılap Tarihi I, Türk Dili I ve İngilizce I ortak derslerinin verilerinin nasıl elde edildiği ve işlendiği üzerine odaklanılmıştır. Dördüncü bölümde, makine öğreniminde kullanıma hazır hale getirilen veri seti/setleri FPFS-kNN ve bilinen bazı makine öğrenimi yöntemleri kullanılarak sınıflandırılmış ve performans karşılaştırılması verilmiştir. Son olarak, uzaktan eğitimde başarı tahmini üzerine FPFS-kNN'nin uygulanması üzerine bir tartışmaya yer verilmiştir.

BÖLÜM 2

TEMEL KAVRAMLAR

Bu bölümde, uzaktan eğitim, Moodle öğrenme yönetim sistemi, öğrenci bilgi sistemi, makine öğrenimi, bulanık parametrelili bulanık esnek matrisler (*fpfs-matrisler*) ve FPFS-kNN algoritması kavramlarına yer verildi.

2.1. Uzaktan Eğitim

“Uzaktan eğitim, farklı ortamlarda bulunan öğrenci ve öğretmenlerin öğrenme-öğretme faaliyetlerini, iletişim teknolojileri ve posta hizmetleri ile gerçekleştirdikleri bir eğitim sistemi modelini ifade eder” (İşman, 2011, s. 23).

Uzaktan eğitim, geleneksel öğrenme-öğretme uygulanmasında karşılaşılan zorluklar, sınırlılıklar nedeniyle, sınıf içinde yüz yüze gerçekleştirilen etkinliklerin yürütülmesi olanağının bulunmadığı durumlarda öğretmenler ile öğrenciler arasında iletişim ve etkileşim kurabilmek için çeşitli teknolojik araçlarla desteklenmiş ve belirli bir merkezden yönetilen eğitim yöntemidir (Odabaş, 2003, s. 24).

“Uzaktan eğitim uygulamaları sayesinde birbirlerinden kilometrelerce uzaklıkta farklı ortamlarda olan öğretmen ve öğrenciler birbirleriyle görüntülü ve sesli olarak etkili iletişim kurabilmektedir. Var olan uzaktan eğitim sistemleri öğrenciler ve öğretmenlere küresel eğitim ve küresel iletişim imkânı sunmaktadır” (İşman, 2011, s. 3-4).

Uzaktan eğitim, bireylere kendi kendilerine öğrenme imkânının sağlandığı, geleneksel eğitime göre daha esnek ve birey koşullarına uygulanabilir bir eğitimidir. Uzaktan eğitimle, bireylere eğitim hizmeti götürmedeki sınırlılıkların kısmen ya da tümüyle ortadan kaldırılarak eğitim imkanlarının daha geniş kitlelere ulaştırılması amaçlanmaktadır. Çoklu ortam araçlarının ve sunum sistemlerinin işe koşulması, uzaktan eğitim tanımının yapılmasını güçleştirmektedir. Ancak, kısaca öğretmen ve öğrencinin zaman ve mekân bakımından birbirinden ayrıldığı ortamlar üzerine yapılandırılan eğitim uygulamalarının hepsi uzaktan eğitim olarak adlandırılmaktadır (Uluğ ve Kaya, 1997).

Uzaktan eğitim ilk olarak mektupla ve radyo yayınlarıyla başlamıştır. Ardından televizyon, telefon ve bilgisayardan yararlanılarak yapılmıştır. Günümüzde teknolojinin eğitime uyarlanması ile uzaktan eğitim daha da önemli rol oynamaktadır. Bilgisayarın ve internetin hayatımıza girişi ile öğretim teknolojisi ve öğretim modellerinde gelişmeler

yaşanmıştır. Gelişen bilişim teknolojisi ve yazılımlarla çevrimiçi derslerde etkileşim de artmakta, bilgi alışverişi yapılabilmektedir.

Uzaktan eğitim, geleneksel eğitimin belirli bir zaman ve belirli bir yerde ders yapılması zorunluluğunu ortadan kaldırırken, kalabalık sınıflarda göz ardı edilen öğrencilerin bireysel farklılıklarından kaynaklanan öğrenme hızını da dikkate alabilmekte, eğitimi bireyselleştirebilmektedir. Ders içeriklerinin, ödev ve projelerin düzenli bir şekilde internet ortamında bulunduğu, izleme ve değerlendirmenin kolaylıkla yapılabildiği, çeşitli iletişim araçlarının etkileşim sağlamada kullanıldığı, sürekli geliştirilebilir ve güncelleştirilebilir bir eğitim ortamı sağlayabilmektedir (Ersoy, 2014).

Uzaktan eğitim yaygın eğitime göre daha fazla fırsat sunmaktadır. Bilgiye ulaşımı hızlandırmakta, bireysel hızda öğrenme imkânı sağlamaktadır. Uzaktan eğitim, zengin görsel içeriklere sahip e-kitaplara erişim, kendi hızında öğrenme imkânı, eş zamanlı etkileşimli derslere zamandan bağımsız erişebilme, eş zamansız derslere zamandan ve mekândan bağımsız erişebilme, öğretim elemanları ile iletişim kurabilme, ölçme değerlendirme faaliyetleri ile başarının ölçülmesine imkân sunan öğrenci merkezli bir eğitim biçimidir.

Yaşam boyu, sürekli eğitim için önemli bir yer kaplamakta olan uzaktan eğitim kişilere, bulunduğu yerden ayrılmadan ekonomik açıdan daha uygun eğitim alma imkânı ve çalışma hayatı ile eğitim hayatını birlikte yürütme imkânı da sunar. Uzaktan eğitim eğitimde fırsat eşitliği sunarak hem çalışanlar için hem farklı coğrafyalarda yaşayanlar için hem de farklı yaş gruplarındaki kişiler için eğitim alma olanağı sağlamaktadır.

2.2. Moodle Öğrenme Yönetim Sistemi

Öğrenme yönetim sistemleri yüz yüze eğitimi desteklemek için veya örgün eğitimin alternatifi olarak uzaktan eğitim programlarının derslerini yönetmek amacıyla kullanılır. Bu sistemler eğitim içeriklerinin yönetimi, katılımcıların öğrenim günlüklerinin eğitimciler tarafından görüntülenmesi ve eğitimin ölçülmesine olanak tanınması gibi işlevleri yerine getirir. Öğretmenler tarafından çevrimiçi kurs ve kurs içerikleri oluşturmak için kullanılan öğrenme yönetim sistemleri zaman içinde gelişerek modern bir öğrenme aracına dönüşmüştür. Öğrenciler derslere erişmenin yanı sıra ödev göndermek, sınava girmek ve iletişim kurmak için cep telefonlarıyla bile sisteme erişim sağlayabilmektedir.

Moodle, tamamen ücretsiz, açık kaynak kodlu uzaktan eğitim öğrenme yönetim sistemidir (“Kliksoft”, t.y.). Açılımı, Modular Object Oriented Dynamic Learning

Environment (Esnek Nesne Yönelimli Dinamik Öğrenme Ortamı) kelimelerinin baş harflerinden oluşur (“Moodle”, t.y.).

Moodle yazılımı, PHP dilini destekleyen herhangi bir ortamda (Linux, Windows, Mac OS X vs.) MySQL ve PostgreSQL veritabanı sistemleri altında çalışabilen özgür, açık kaynak kodlu bir öğrenme yönetim sistemidir (Graf ve List, 2005). Open GL lisans yapısı ile tamamen ücretsiz lisanslama modeli sunmaktadır. Dünyada ve Türkiye’de kullanımı yaygın olan Moodle sürekli olarak geliştirilmektedir. Geliştirilen yeni özellikler ücretsiz olarak dağıtılmaktadır (“Moodle”, t.y.).

Moodle Öğrenme Yönetim Sistemi ilk olarak Martin Dougiamas tarafından öğrencilerin ihtiyaçlarına göre esnek, erişilebilir ve herkes için kaliteli bir eğitim sağlayacak bir çevrimiçi öğrenme çözümü yaratmak, eğitimcilerin çevrimiçi kurs içerikleri üretmesine imkân sağlamak amacıyla geliştirilmiştir. Moodle’ın 1.0 sürümü, 20 Mayıs 2002’de kullanıcıya yayınlanmıştır. Moodle modül eklentileri sayesinde sürekli geliştirilerek ihtiyaca göre aktif olarak güncellenmeye, yenilenmeye devam edilmektedir (“Moodle”, t.y.). 235 ülkede kullanılmaktadır ve 82 dilde desteği mevcuttur.

Moodle Öğrenme Yönetim Sistemi, bir uzaktan eğitim öğrenme yönetim sistemi üzerinde bulunması gereken etkinliklerin çoğunu fazlasıyla yerine getirebilecek özelliklere sahip modüller bir çevrimiçi kurs yönetim sistemidir. Moodle kullanıcı dostu ara yüzü ile bireyler tarafından (öğretmen, öğrenci, sistem yöneticileri) rahatlıkla kullanılabilir (Graf ve List, 2005).

Moodle Öğrenme Yönetim Sistemi, raporlanabilir öğrenme içerikleri paylaşma, başarı notlarının takibi, öğrenci kayıtlarının yönetimi, anket uygulama, raporlama eklentileri, kişisel takvim, kişisel dosyalar, blog, chat, ders yönetimi, sınav, forum, duyuru, mesajlaşma vb. internet üzerinden yapılabilecek çeşitli araçlardan oluşur. Literatür incelendiğinde, Moodle’ın zengin öğretici eğitim materyali ortamı sunması, yönetilebilir eklentiler sunması, dil paketi ile çok sayıda dil desteği sağlaması, ücretsiz olması ve toplu kurs ve öğrenci kaydı imkânı sunması, toplu sınav oluşturma gibi özelliklere sahip olması ile öne çıkan yaygın kullanılan bir öğrenme yönetim sistemi olduğu görülmektedir.

Moodle Öğrenme Yönetim Sistemi izleme ve raporlama özelliği ile kullanıcıların tüm hareketlerini izler, kayıt altına alarak büyük veriler oluşturur.

The screenshot shows the Moodle Teacher Dashboard. The main content area is titled "Derslere genel bakış" (General view of courses) and displays a list of courses under the filter "Devam eden" (Ongoing). The courses listed are:

- Atatürk İlkeleri ve İnkılap Tarihi-II_SB:10_Ortak Ders (CUMA 16:00-16:50)
- Atatürk İlkeleri ve İnkılap Tarihi-II_SB:11_Ortak Ders (Cumartesi 10:00-11:50)
- Atatürk İlkeleri ve İnkılap Tarihi-II_SB:12_Ortak Ders (Cumartesi 12:00-12:50)
- Atatürk İlkeleri ve İnkılap Tarihi-II_SB:22_Ortak Ders (Cumartesi 14:00-14:50)
- Atatürk İlkeleri ve İnkılap Tarihi-II_SB:25_Ortak Ders (Cumartesi 11:00-11:50)
- Atatürk İlkeleri ve İnkılap Tarihi-II_SB:3_Ortak Ders (Salı 11:00)

The right sidebar contains several sections:

- Son duyurular** (Recent announcements): A list of announcements with dates and times, including "2022-2023 Bahar Uzakta Eğitim Tezisi Yüksek Lisans Diploma Programları Ara Sınavları Hk.", "22-23 Bahar Dönemi Ara Sınav Duyurusu", and "2022-2023 Bahar Dönemi Uzakta Eğitim Sistemi Bilgilendirme".
- Yaklaşan etkinlikler** (Upcoming events): A section indicating "Yakın zamanda olay yok" (No events in the near future).
- Takvim** (Calendar): A section for the calendar.

Şekil 1. Moodle, Öğretmen, Derslerim Ana Sayfası

The screenshot shows the Moodle Course Page for "Total Quality Management_SB:1_İşletme (İngilizce)". The page displays a list of announcements for the course "BUSL374- TOTAL QUALITY MANAGEMENT - Assoc. Prof. Dr.":

- SYLLABUS
- ANNOUNCEMENT: About BUSL374- TOTAL QUALITY MANAGEMENT- HOMEWORK (MAKE-UP EXAM)
- ANNOUNCEMENT: About BUSL374- TOTAL QUALITY MANAGEMENT- HOMEWORK (FINAL EXAM)
- ANNOUNCEMENT: About BUSL374- TOTAL QUALITY MANAGEMENT- HOMEWORK (MID-TERM EXAM)
- About 11th WEEK'S BUSL374- TOTAL QUALITY MANAGEMENT COURSE
- Öğrenme Yönetim Sistemi Öğretmen Kılavuzu
- >>>KILAVUZ SUNUM<<<
- Öğrenme Yönetim Öğrenci Kılavuzu
- >>>ÖĞRENCİ SUNUM<<<

Şekil 2. Moodle Ders Sayfası Duyurular Bölümü

+ FEBRUARY 20 – FEBRUARY 26, 2023 (WEEK 1) ✎

+ You can download this week's study questions by clicking on the file below.

- WEEKLY STUDY QUESTIONS
- STUDY QUESTIONS 1.pdf

Klasörü indir

+ You can download this week's case study by clicking on the file below.

- WEEKLY CASE STUDY
- CASE STUDY 1.pdf

Klasörü indir

+ You can download this week's presentation output by clicking on file below.

- WEEKLY COURSE PRESENTATION OUTPUT
- TQM_WEEK1.pdf

Klasörü indir

+ You can download this week's additional course materials by clicking on the file below.

- WEEKLY ADDITIONAL COURSE MATERIALS (Reading Texts / Video)
- Case-Reading Text 1.pdf

Klasörü indir

+ BUSL374- TOTAL QUALITY MANAGEMENT-WEEK 1 (22.02.2023 - 09:00-12:00) ✎

[Click here for the online course \(Online derse girmek için tıklayınız\)](#)

[Click here to watch the 1st section record of the course \(Dersin 1. Oturumunu izlemek için tıklayınız\)](#)

[Click here to watch the 2nd section record of the course \(Dersin 2. Oturumunu izlemek için tıklayınız\)](#)

[Click here to watch the 3rd section record of the course \(Dersin 3. Oturumunu izlemek için tıklayınız\)](#)

Şekil 3. Moodle Ders Etkinlikleri Sayfası

2.3. Öğrenci Bilgi Sistemi

ÖBS Yükseköğretim kurumlarının yönetimini ve gelişimini kolaylaştıran, öğrenci verilerinin yönetilmesini sağlayan, öğrenci verilerini toplamak ve düzenlemek için kullanılan veri tabanı yazılımlarıdır (Gürkut ve Nat, 2018). Program, ders, hoca, müfredat gibi süreçlerin yönetilmesinde imkân sağlamaktadır. Öğrencilerin askerlik ve kayıt süreçlerinin yanı sıra akademik kayıtlarını, notlarını, devamsızlık durumlarını, burs durumlarını ve diğer önemli bilgilerini takip etmek için kullanılır. Akademisyenlerin ders bilgilerine, öğrenci bilgilerine erişmelerine imkân sağlayarak ders başarı notlarının oluşturulmasına olanak sağlamaktadır.

Akademik personelin yanı sıra özellikle öğrenci işleri idari birimi tarafından kullanılmaktadır. ÖBS, öğrencinin aldığı derslerin ve notların takip edilmesi gibi süreçlerde veri toplayarak düzenler. Eğitimle ilgili birçok kararda önemli rol oynayan istatistiksel raporlar da ÖBS tarafından sağlanmaktadır (Ergin ve Akseki, 2012). Akademik karar verme amaçları ve diğer akademik görevler için kullanımı çok önemlidir (Gürkut, ve Nat, 2018).



Şekil 4. Öğrenci Bilgi Sistemi Arayüzü

2.4. Makine Öğrenimi

Makine öğrenimi (machine learning), yapay zekâ (artificial intelligence) alanının bir alt dalı olarak ortaya çıkmıştır ve 1990'lerden itibaren kendi başına bir alan olarak çalışılmaya devam edilmiştir. Makine öğrenimi bir bilgisayar sisteminin, insan müdahalesi olmaksızın, verilerden öğrenmesini sağlayan bir teknoloji ve metodolojik yaklaşımdır (Mehryar, Rostamizadeh ve Talwalkar, 2018)

Makine öğrenimi, verilerde yeni ilişkiler keşfetmek için var olan verileri veya geçmiş deneyimleri kullanarak matematiksel ve istatistiksel işlemler ile veriler üzerinden çıkarımlar yaparak tahminlerde bulunan sistemlerin bilgisayarlar ile modellemesini yapan bir bilim

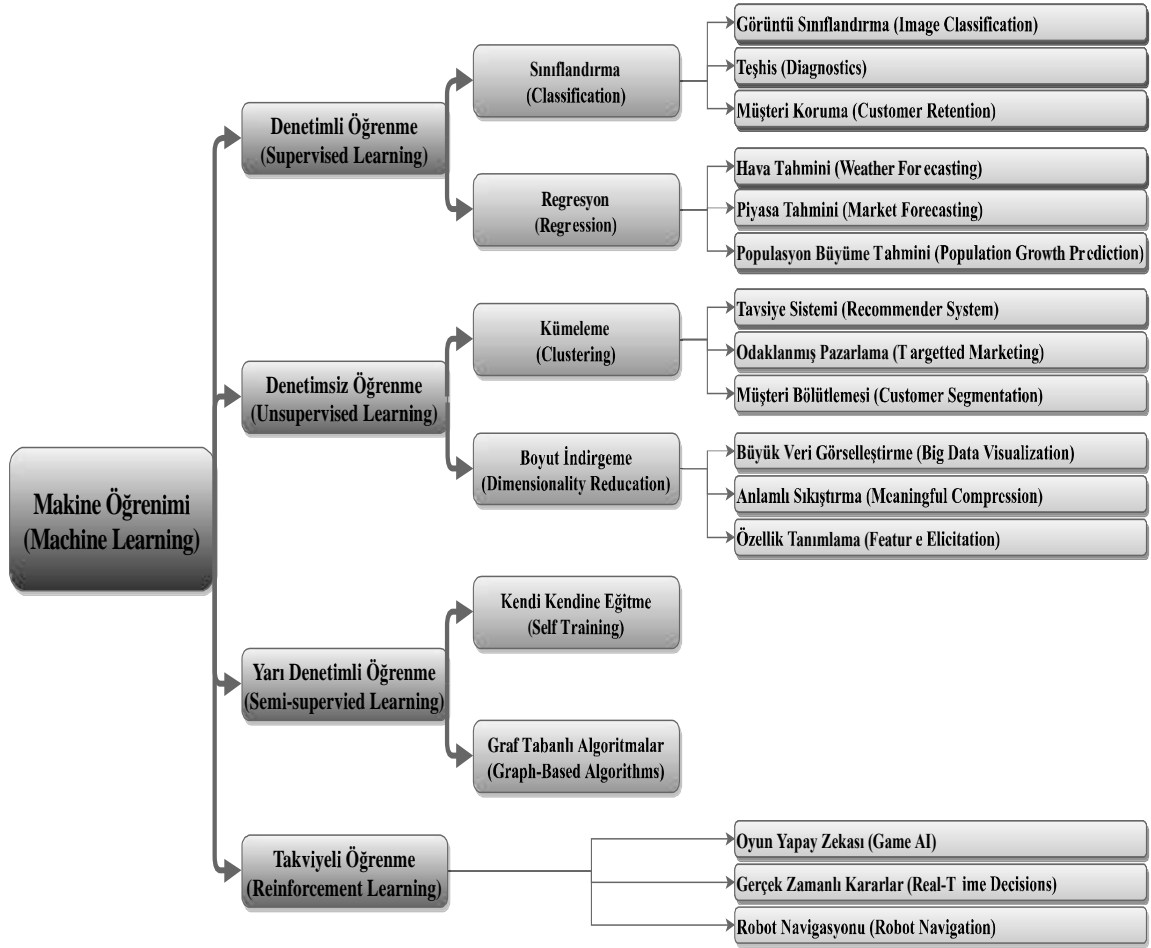
alanıdır. Bazı parametrelere kadar tanımlanmış bir modelimiz vardır ve öğrenme, eğitim verilerini veya geçmiş deneyimleri kullanarak modelin parametrelerini optimize etmek için bir bilgisayar programının yürütülmesidir. Model, gelecekte tahminler yapmak için öngörücü veya verilerden bilgi edinmek için açıklayıcı veya her ikisi de olabilir. Matematiksel modeller oluştururken istatistik teorisini kullanır çünkü temel görev bir örneklemden çıkarım yapmaktır (Moussawi, İbrahim, Said ve Mershad, 2020).

Makine öğrenimi, analitik modelleri teori, algoritmalar ve veriler aracılığıyla birden fazla yinelemeli döngü yoluyla optimize etmeyi ve nihayetinde bir soruna ve gerçek dünyadaki kararlara ilişkin içgörüler için en uygun modeli incelemeyi amaçlamaktadır. (McIntyre, 2022).

Makine öğrenimi, önceden tanımlanmış kurallar yerine veriye dayalı olarak öğrenme kabiliyeti ile bilgisayarların otomatik olarak kararlar vermesini ve problemleri çözmelerini sağlar. Bu, bir veri kümesindeki yapıları ve modelleri algılamak için kullanılan algoritmaların geliştirilmesini ve bu modellerin doğrulanmasını içerir.

Makine öğrenimi, büyük miktardaki karmaşık veriyi anlamlı bir şekilde analiz edebilir ve bu verilerden öğrenme yoluyla öngörülerde bulunabilir. Bu nedenle, Makine öğrenimi günümüzde birçok farklı uygulama alanında kullanılan önemli bir teknolojidir. Örneğin, doğal dil işleme, görüntü işleme, ses işleme, oyun oynama stratejileri, finansal analiz, tıbbi teşhis, hava tahmini, arama motoru optimizasyonu, satış tahmini ve daha birçok alanda makine öğrenimi teknikleri kullanılmaktadır. Birçok alanda hayatımızı etkileyen, günlük yaşantımızın takip edilmesinde ve yeni yapılacak hareketlerin tahmin edilmesinde kullanılan makine öğrenmesi kullanıcıların deneyimlerini depolayarak daha iyi bir hizmet sunmak amacıyla kullanıcı ihtiyaçlarına yönelik kolaylaştırıcı çözümler sunmaya çalışır (Şapçı ve Pektaş, 2021).

Veri türüne ve amaca göre farklı makine öğrenimi türleri kullanılmaktadır. Şekil 5'te makine türleri verilmektedir.



Şekil 5. Makine öğrenimi türleri (Anisimova, 2019, 27 Kasım; Memiş, 2021)

“Denetimli öğrenmede makineye hem girdi hem çıktı değer verilir” (Civalek, 2003). Denetimli Öğrenme, örnek girdi-çıktı çiftlerine dayalı olarak bir girdiyi bir çıktıya eşleyen bir fonksiyonu öğrenmeye yönelik makine öğrenimi türüdür (Russell ve Norvig, 2020). “Denetimli öğrenmede oluşturulan model ile bir grup girdi değerine karşılık onlara ait hedef değerleri verilerek aralarındaki ilişkiyi öğrenmesi ve hedef değerlere en yakın çıktıların üretilmesi amaçlanır. Elde edilen en iyi model, yeni girdi değerleri için en yakın çıktıyı da verebilecektir” (Atalay ve Çelik, 2017). Çıktılara etiket denir (Russell ve Norvig, 2020). Model, ona yeni bir görüntü verildiğinde uygun etiketi tahmin eden bir fonksiyon öğrenir (Russell ve Norvig, 2020). Burada model, eğitim verisi olarak bir dizi etiketli verileri alır ve etiketsiz tüm örnekler için tahminlerde bulunur. E-posta sistemlerindeki spam algılama problemi, denetimli öğrenmenin bir örneğidir (Mehryar ve diğerleri, 2018).

Denetimsiz öğrenmede makineye sadece girdi değer verilir (Civalek, 2003). Hedef değerleri olmadan sadece girdi değerleri arasındaki ilişki ortaya çıkarılmaya çalışılır. Bu

ilişkiler ile birbirine benzer değerler gruplandırılır. Buna kümeleme de denir. Yeni bir girdi bu kümelerden hangisiyle ilişkili ise o kümeye ait olacaktır (Atalay ve Çelik, 2017). Burada model tüm etiketsiz örnekler için tahminlerde bulunur. Genel olarak bu ortamda etiketli bir örnek bulunmadığından, bir modelin performansını nicel olarak değerlendirmek zor olabilir. Kümeleme ve boyut indirgeme, denetimsiz öğrenme problemlerine örnektir (Mehryar ve diğerleri, 2018).

Yarı Denetimli Öğrenme hem etiketli hem etiketsiz verileri kullanarak girdiye bir etiket atayan makine öğrenimi türüdür. Model, hem etiketli hem de etiketsiz verilerden oluşan bir eğitim dizisini alır ve tüm etiketsiz örnekler için tahminlerde bulunur. Yarı-denetimli öğrenme, etiketlenmemiş verilere kolayca erişilebilen ancak etiketlerin elde edilmesinin pahalı olduğu ortamlarda yaygındır. Sınıflandırma, regresyon veya sıralama problemleri de dâhil olmak üzere uygulamalarda ortaya çıkan çeşitli problem türleri, yarı-denetimli öğrenme örnekleri olarak verilebilir (Mehryar ve diğerleri, 2018).

Takviyeli öğrenme ise girdi değerlerine karşılık gelecek en uygun çıktı elde edilmesi sırasında katsayıların en uygun değerlerinin bulunması ile sağlanır (Civalek, 2003). “Pekiştirmeli (takviyeli) öğrenme yönteminde, hedef çıktıyı vermek için bir danışman yerine, elde edilen çıkışın verilen girişe karşılık iyi ya da kötü olarak değerlendiren bir kriter kullanılmaktadır” (Atalay ve Çelik, 2017). Takviyeli Öğrenme, içerisinde ödülle dayalı bir öğrenme barındıran makine öğrenimi türüdür. Burada model, bilgi toplamak için çevre ile aktif bir şekilde etkileşime girer, bazı durumlarda çevreyi etkiler ve her eylem için anında bir ödül alır. Modelin amacı, çevre ile etkileşiminde kazandığı ödülü en üst düzeye çıkarmaktır (Mehryar ve diğerleri, 2018).

Makine öğrenimi algoritmaları, birçok farklı yaklaşımla ve yöntemle geliştirilebilir. Denetimli öğrenme ve denetimsiz öğrenme yaygın olarak çalışılmaktadır. Makine öğrenimi algoritması seçimi genellikle verilerin yapısı ve hacmi ile ilgili faktörlere bağlıdır. Makine öğrenmesinde kullanılacak algoritmalar arasından veriyi işleyebilecek en uygun algoritmayı seçmek önemlidir. Bu algoritmaların bazıları k-En Yakın Komşu (k-Nearest Neighbor (kNN)) (Cover ve Hart, 1967; Fix ve Hodges, 1951), Karar Ağaçları (Decision Tree), Yapay Sinir Ağları (Artificial Neural Networks (ANN)), Destek Vektör Makineleri (Support Vector Machine (SVM)) (Cortes ve Vapnik, 1995), Doğrusal Regresyon (Linear Regression), Kümeleme, Derin Öğrenme (Deep Learning), Bulanık Parametrelili Bulanık Esnek kNN (FPFS-kNN) vb. şeklindedir.

2.5. Bulanık Parametrelili Bulanık Esnek Matrisler (*fpfs*-matrisler)

Bu alt bölümde, uygulama bölümündeki algoritmaların kullandığı *fpfs*-matris kavramını veriyoruz.

Tanım 2.1. (Çağman ve diğerleri, 2010) U evrensel küme, $\mu \in E$ ve α, μ' 'den $F(U)$ 'ya bir fonksiyon olsun. O halde, $\left\{ \left(\mu^{(x)} x, \alpha \left(\mu^{(x)} x \right) \right) : x \in E \right\}$ kümesine U üzerinde E ile parametrelendirilmiş (kısaca U üzerinde) bir bulanık parametrelili bulanık esnek küme (*fpfs*-küme) denir.

Bu tez çalışması boyunca, U üzerindeki tüm *fpfs*-kümelerin kümesi $FPFS_E(U)$ ile gösterilsin.

Örnek 2.2. $E = \{x_1, x_2, x_3\}$ ve $U = \{u_1, u_2, u_3\}$ olsun. O halde,

$$\alpha = \left\{ \left({}^{0.1}x_1, \alpha \left({}^{0.2}u_1, {}^{0.3}u_2, {}^{0.4}u_3 \right) \right), \left({}^0x_2, \alpha \left({}^{0.5}u_1, {}^{0.6}u_3 \right) \right), \left({}^{0.9}x_3, \alpha \left({}^{0.7}u_2, {}^{0.8}u_3 \right) \right) \right\}$$

U üzerinde bir *fpfs*-kümedir.

Tanım 2.3. (Enginoğlu ve Çağman, 2020) $\alpha \in FPFS_E(U)$ olsun. O halde, $i \in \{0, 1, 2, \dots\}$ ve $j \in \{1, 2, \dots\}$ için,

$$a_{ij} := \begin{cases} \mu(x_j), & i = 0 \\ \alpha \left(\mu^{(x_j)} x_j \right) (u_i), & i \neq 0 \end{cases}$$

ile tanımlı

$$[a_{ij}] = \begin{bmatrix} a_{01} & a_{02} & a_{03} & \dots & a_{0n} & \dots \\ a_{11} & a_{12} & a_{13} & \dots & a_{1n} & \dots \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ a_{m1} & a_{m2} & a_{m3} & \dots & a_{mn} & \dots \\ \vdots & \vdots & \vdots & \ddots & \vdots & \ddots \end{bmatrix}$$

biçiminde yazılan $[a_{ij}]$ matrisine α 'nın *fpfs*-matrisi denir. Burada, eğer $|U| = m - 1$ ve $|E| = n$ ise $[a_{ij}]$ $m \times n$ tipindedir.

Çalışma boyunca, $FPFS_E[U]$, U üzerinde E ile parametrelendirilmiş tüm *fpfs*-matrislerin kümesini gösterebiliriz.

Örnek 2.4. Örnek 2.2'de verilen α 'nın *fpfs*-matrisi aşağıdaki gibidir:

$$[a_{ij}] = \begin{bmatrix} 0.1 & 0 & 0.9 \\ 0.2 & 0.5 & 0 \\ 0.3 & 0 & 0.7 \\ 0.4 & 0.6 & 0.8 \end{bmatrix}$$

2.6. FPFS-kNN Algoritması

kNN algoritması verileri sınıflandırma için kullanılır. Verimliliğini ve performansını belirleyen en önemli faktör komşu sayısının belirlendiği k değeridir. kNN, sınıflandırılmamış verilerin en yakın komşularına bakılıp, benzerliği yüksek sınıflara göre tahminler yapan bir sınıflandırma yöntemidir. kNN algoritmasında, oluşturulan veri setindeki sınıfları belli olan kümelerden faydalanılarak, tahminde bulunulacak veri setindeki yeni verilerin, mevcut verilere göre uzaklık değerleri hesaplanır (örneğin Öklid uzaklığı) ve k sayıdaki komşuluklarına bakılır. Eğitilmiş veri setinde yer alan k adet en yakın komşuların sınıf etiketleri alınır ortaya çıkan sınıf etiketlerinden hangisi çoğunluktaysa işleme alınan veri o kümeyle dahil edilir (Güvenç ve diğerleri, 2022).

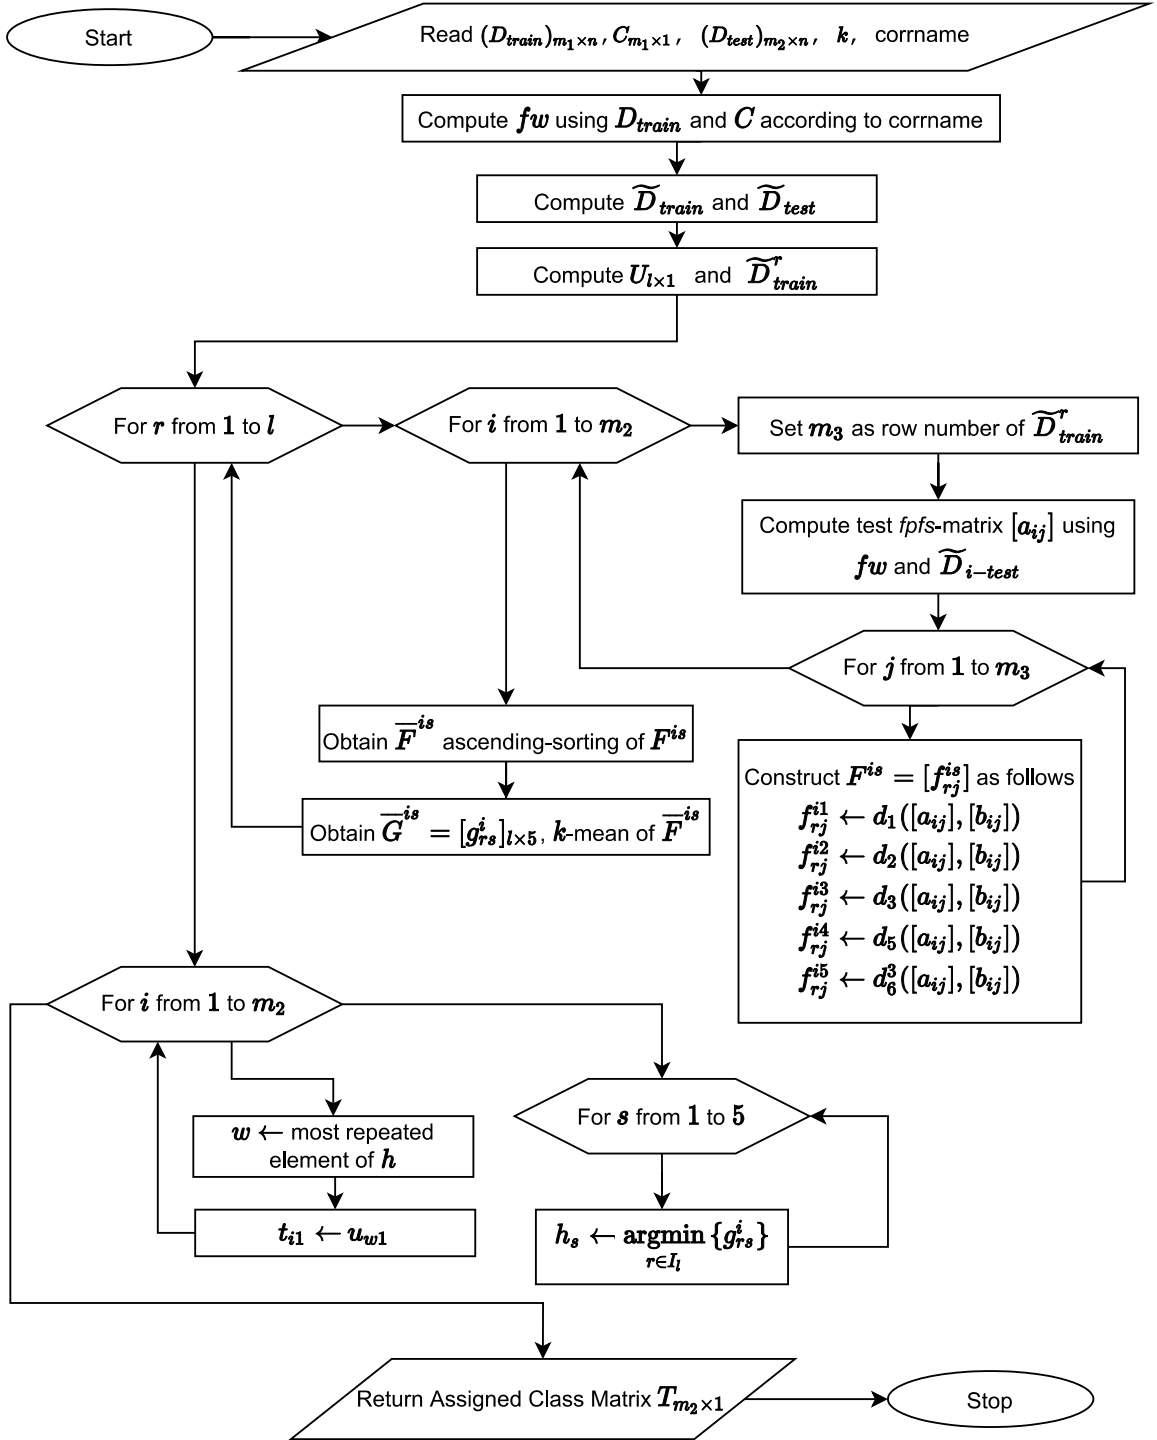
Makine öğrenimi türlerindeki problemler de dâhil olmak üzere günlük yaşamda karşılaştığımız çoğu problem belirsizlik içeren pek çok veri içermektedir. Son zamanlarda önem kazanan, belirsizliklere karşı uygun çerçeve olan bulanık kümeler (Zadeh, 1965) ve esnek kümeler (Molodtsov, 1999) karşılaşılan bu problemleri modelleyebilmek ve üstesinden gelebilmek için geliştirilen matematiksel araçlar arasındadır. Bulanık kümeler belirsizlikle başarılı bir şekilde başa çıkabilmek için Zadeh tarafından geliştirilmiştir. Bulanık küme teorisinin ortaya atılması ve yaygınlaşması sayesinde var olan yöntemlerin Fuzzy kNN (Keller, Gray ve Givens, 1985) ve Fuzzy SVM (Lin ve Wang, 2002) gibi hibrit ve yeni versiyonları geliştirilmiştir (Memiş, 2021).

kNN algoritmasının başarısı k değerine ve k -komşulukları hesaplamak için kullandığı mesafe fonksiyonuna göre değişiklik göstermektedir. Fuzzy kNN (Keller ve diğerleri, 1985), k -komşuluktaki her bir k -komşunun sorgu noktasına olan uzaklığına göre bir bulanık üyelik derecesi kullanarak her bir k -komşuyu ağırlıklandırır ve sınıflandırma işlemini gerçekleştirir.

Molodtsov (1999) tarafından belirsizliği modellemek için bir matematiksel araç olarak ortaya atılan esnek kümeler, belirsizliği modellemede başarılı bir matematiksel araç olsa da parametrelerin veya alternatiflerin bulanık olduğu problemleri modellemede yetersiz kalmaktadır. Bu nedenle, bulanık esnek kümeler (Çağman, Enginoğlu ve Çıtak, 2011b; Maji, Biswas ve Roy, 2001), bulanık parametrelili esnek kümeler (Çağman, Çıtak ve Enginoğlu, 2011a) ve bulanık parametrelili bulanık esnek kümeler (*fpfs*-kümeler) (Çağman, Çıtak ve Enginoğlu, 2010) gibi esnek kümelerin genel biçimleri genişletilerek tanımlanmıştır. *fpfs*-kümeler hem parametrelerin hem de alternatiflerin bulanık olduğu durumları modelleyebildiğinden diğerleri üzerinde doğal bir avantaja sahiptir. Ayrıca, bu avantajın yüksek veri ve belirsizlik içeren problemlerin bilgisayar üzerinde çözülebilmesi konusunda

da kullanılabilmesi için bulanık parametrelili bulanık esnek matrisler (*fpfs*-matrisler) (Enginođlu ve ađman, 2020) kavramı ortaya atılmıřtır.

Son teknoloji makine đrenimi algoritmalarından biri olan FPFS-kNN (Memiř ve diđerleri, 2022c), *fpfs*-matrislerin mesafe fonksiyonlarına dayanan yeni nesil bir kNN algoritmasıdır. Her ne kadar kNN ve kNN tabanlı ok eřitli algoritmalar nerilmiř olsa da bu algoritmalar verileri hem tek bir benzerlik fonksiyonu aracılıđıyla hem de bir veri kumesinin parametrelerini ađrılıklandırmadan sınıflandırır. Parametrelerin gruplamadaki belirleyici rolü nedeniyle daha etkin bir sınıflandırma iin ok kriterli ve parametre ađrılıklandırma yntemine ihtiya duyulmaktadır. Bu anlamda, esnek kumeler/matrisler ve bulanık esnek kumeler/matrislerden daha genel bir matematiksel ara olan *fpfs*-matrisler kavramı, sınıflandırma problemlerinin özümünde ne ıkmaktadır. Parametrelerin sınıflandırma srecindeki etkilerini de gz nne alan FPFS-kNN algoritmasının akıř diyagramı Őekil 6'da verilmiřtir. FPFS-kNN'nin en nemli katkısı, parametrelerin sınıflandırma srecine etkisini de mesafe hesabına ve dolayısı ile sınıflandırma srecine dâhil etmesidir. Bu yaklařım sınıflandırma bařarısını nemli lde arttırmaktadır. Bu nedenle, bu alıřmada đrencilerin ders etkinliklerine katılım verileri kullanılarak bařarı tahmini yapılmasında kullanılmıřtır.



Şekil 6. FPFS-kNN algoritma akış diagram (Memiş ve diğerleri, 2022)

BÖLÜM 3

ÖĞRENCİ VERİLERİNİN TOPLANMASI VE İŞLENMESİ

Bu bölümde Moodle öğrenme yönetim sistemi günlükler sayfalarındaki 14 haftalık öğrenci etkileşim verilerinin toplanması ve işlenmesi sürecindeki aşamalara yer verildi.

3.1. Verilerin Toplanması

Uzaktan eğitim sistemi üzerinden yapılan etkinliklere katılım sağlayan öğrenci hareketlerinin kayıt altına alınmasıyla oluşan büyük boyutlu verilerin analiz edilmesi ile kaliteli bir eğitim için erken önlemler alınması sağlanabilir, öğrencinin bireysel öğrenme biçimine uygun içerikler önerilmesine olanak sağlayabilir. Öğrenenin başarı tahmin sonuçlarına göre eksik kaldığı konuları belirleme gibi alanlarda kullanılabilir (Tosunoğlu, Yılmaz, Özeren ve Sağlam, 2021).

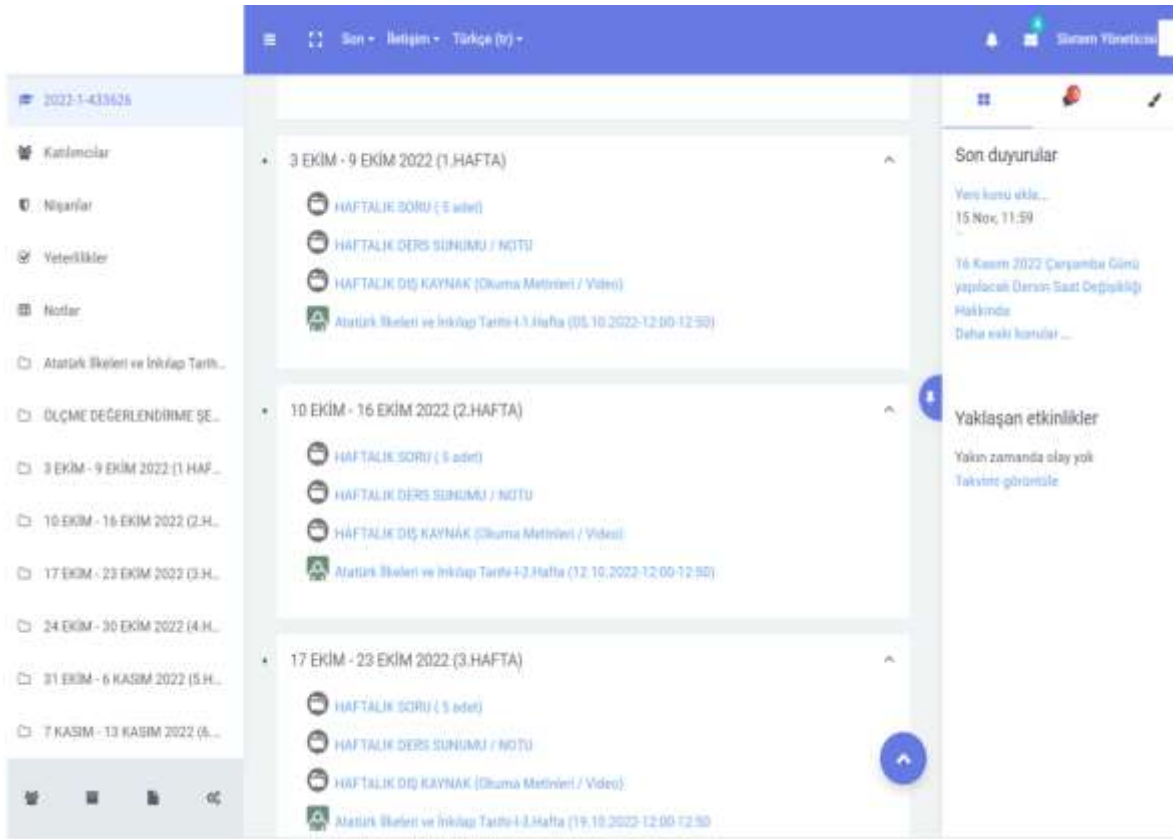
Uzaktan eğitim öğrencilerinin başarılarını etkileyen dönem içi etkinliklerine katılımlarını analiz edip öğrenci başarılarını tahmin etmek için öncelikle verilerin toplanması gerekir. Çevrimiçi öğrenme ortamı olan Moodle Öğrenme Yönetim Sistemi tüm öğrencilerin öğrenme hareketlerini toplayan önemli bir veri kaynağıdır. Öğrencilerin ders içi hareketlerine dair büyük veriler oluşturur. ÖBS'nde başarı notlarına dair verilere ulaşım imkânı sağlar. Bu verilerin analizi, değerli bilgilerle sonuçlanabilir ve öğrencilere, eğitmenlere ve yöneticilere yükseköğretimde öğrenme sürecini yükseltme konusunda yardımcı olabilir.

Bu çalışmada öğrencilerin ödevlerini tamamlama durumu, sınav notları, canlı derslere katılım süreleri, eşzamansız etkinliklere katılım oranları, başarı notları gibi veriler toplanıp makine öğreniminde kullanılmak üzere işlenecektir. Daha sonra bu veriler FPFS-kNN ile sınıflandırılarak öğrencilerin başarı tahminleri elde edilecektir. Ayrıca, sınıflandırma performansı için doğruluk, kesinlik, duyarlık ve F1-skor metrikleri kullanılacaktır.

Bu çalışma kapsamında, 2022-2023 güz yarıyılında, 231 öğrencinin kayıtlı olduğu Atatürk İlkeleri ve İnkılap Tarihi I, 215 öğrencinin kayıtlı olduğu İngilizce I, 197 öğrencinin kayıtlı olduğu Türk Dili I derslerine ait veriler kullanılarak analiz edilecektir. Moodle Öğrenme Yönetim Sistemi izleme ve raporlama özelliği ile kullanıcıların tüm hareketlerini izleyerek günlüklere kaydeder. Günlükler sayfasından elde edilen veriler analiz edilerek öğrencilerin başarıları tahmin edilebilir ve elde edilen bilgiler başarı arttırmak için kullanılabilir. Moodle Öğrenme Yönetim Sistemi üzerindeki dersin sayfasından erişilen

günlükler sayfasından, tüm etkinliklere erişim loglarına ulaşma imkânı tanıyan dijital ayak izleri, etkinlik bazında, .xlsx formatında indirilmiştir.

Uzaktan Eğitim ile verilen derste eğitim, 14 haftada süresince haftalık olarak yapılan eş zamanlı ve eş zamansız etkinlikler üzerinden tamamlanmıştır. Eğitimin her haftası, Canlı (çevrimiçi) ders, Haftanın konusuna dair ders sunumu dosyası, Dış kaynak paylaşımları ve Haftalık çalışma soruları etkinliklerinden oluşmaktadır (“İstanbul Arel Üniversitesi”, 2022).



The screenshot displays the Moodle LMS interface for the ATA course. The top navigation bar includes the course name 'ATA', the language 'Türkçe (tr)', and the user's name 'Sistem Yöneticisi'. The left sidebar shows a list of course sections, with the current section being '3 EKİM - 9 EKİM 2022 (1 HAFTA)'. The main content area is divided into three weekly sections: '3 EKİM - 9 EKİM 2022 (1 HAFTA)', '10 EKİM - 16 EKİM 2022 (2. HAFTA)', and '17 EKİM - 23 EKİM 2022 (3. HAFTA)'. Each weekly section contains a list of activities: 'HAFTALIK SORU (5 adet)', 'HAFTALIK DERS SUNUMU / NOTU', 'HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)', and 'Atatürk Şieleri ve İnkılap Tarihi-1.3.Hafta'. The right sidebar features a 'Son duyurular' (Recent Announcements) section with a notification about a course update on 15 Nov, 11:59, and a 'Yaklaşan etkinlikler' (Upcoming Activities) section with a notification about a course update on 15 Nov, 11:59.

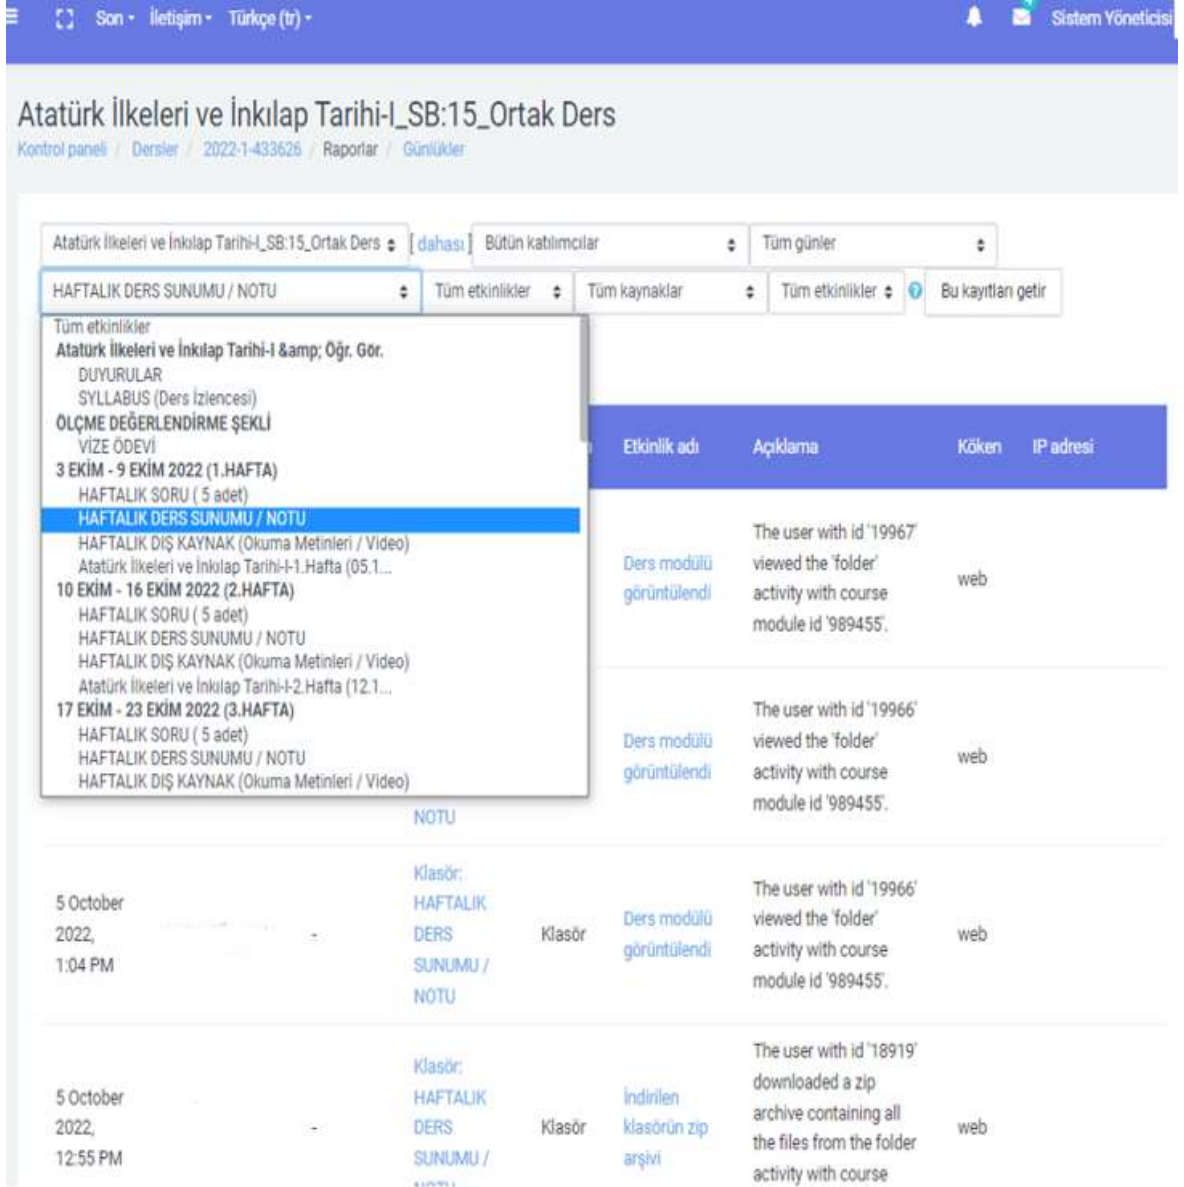
Şekil 7. Moodle Öğrenme Yönetim Sistemi ATA ders sayfası

Öğrencilerin haftalık olarak paylaşılan ders sunumlarına erişimlerine dair dijital ayak izleri raporu Moodle ÖYS üzerindeki Günlükler (log) sayfasından, her hafta için ayrı ayrı çekilmiştir.



Şekil 8. Raporlar (Dijital ayak izleri) sayfası

Raporlar/Günlükler sayfasındaki “Tüm Etkinlikler” alanından ilgili etkinlik seçilerek, her hafta için ayrı ayrı .xlsx formatında indirilmiştir.



Şekil 9. Etkinlik bazında rapor indirme sayfası

Haftalık Ders Sunumları/ Ders Notu: Haftanın konusuna dair öğretici bilgiler içeren, eşzamanlı derslerde de paylaşılan sunum dosyalarıdır. Öğrenme-öğretme yöntemleriyle uyumlu ana materyallerdendir. Eşzamansız (asenkron) etkinliğe öğrenciler ihtiyaç duyduğu her zaman erişim sağlamaktadır (“İstanbul Arel Üniversitesi”, 2022).

Raporlar/Günlükler sayfasındaki “Tüm Etkinlikler” alanından ilgili etkinlik seçilerek, her hafta için ayrı ayrı .xlsx formatında indirilmiştir.

Tablo 1. Haftalık ders sunumu/ders notu 14 haftalık dijital ayak izleri raporu

Zaman	Kullanıcı	Etkinlik başlığı	Bleşen Etkinlik adı	Açıklama	Köşen IP adresi
28/01/22, 21:34	STU01	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP01
11/01/22, 15:09	STU02	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP02
11/01/22, 12:07	STU03	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP03
10/01/22, 18:28	STU04	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP04
10/01/22, 13:19	STU05	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP05
7/01/22, 22:22	STU06	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18945' viewed the 'folder' activity with course module id '9 web	IP06
27/12/22, 21:01	STU07	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP07
11/12/22, 01:55	STU08	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP08
10/12/22, 23:50	STU09	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP09
9/12/22, 21:17	STU10	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP10
9/12/22, 20:06	STU11	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP11
9/12/22, 13:06	STU12	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '17835' viewed the 'folder' activity with course module id '9 web	IP12
7/12/22, 20:29	STU13	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP13
7/12/22, 19:10	STU14	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '1659' viewed the 'folder' activity with course module id '9 web	IP14
27/11/22, 19:06	STU15	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP15
27/11/22, 18:32	STU16	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP16
27/11/22, 16:34	STU17	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP17
26/11/22, 00:16	STU18	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP18
25/11/22, 01:54	STU19	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '16940' viewed the 'folder' activity with course module id '9 web	IP19
21/11/22, 02:05	STU20	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP20
20/11/22, 11:06	STU21	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18945' viewed the 'folder' activity with course module id '9 web	IP21
19/11/22, 20:11	STU22	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '13045' viewed the 'folder' activity with course module id '9 web	IP22
18/11/22, 10:08	STU23	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP23
17/11/22, 13:22	STU24	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18931' viewed the 'folder' activity with course module id '9 web	IP24
17/11/22, 14:58	STU25	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18944' viewed the 'folder' activity with course module id '9 web	IP25
16/11/22, 21:50	STU26	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP26
16/11/22, 20:39	STU27	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP27
16/11/22, 17:59	STU28	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP28
16/11/22, 17:26	STU29	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP29
16/11/22, 13:22	STU30	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP30
15/11/22, 14:10	STU31	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP31
10/11/22, 08:49	STU32	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP32
9/11/22, 12:46	STU33	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18920' viewed the 'folder' activity with course module id '9 web	IP33
9/11/22, 12:43	STU34	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	Ders modülü görüntüendi The user with id '18927' viewed the 'folder' activity with course module id '9 web	IP34
8/11/22, 17:58	STU35	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	İndirilen klasörün zip arşivi The user with id '18927' downloaded a zip archive containing all the files fr: web	IP35
5/11/22, 15:14	STU36	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	İndirilen klasörün zip arşivi The user with id '18927' downloaded a zip archive containing all the files fr: web	IP36
5/11/22, 00:35	STU37	- Klasör: HAFTALIK DERS SUNUMU / NOTU	Klasör	İndirilen klasörün zip arşivi The user with id '18947' downloaded a zip archive containing all the files fr: web	IP37

Haftalık Dış Kaynak Paylaşımları: Eş zamanlı derslerde kullanılan ders notlarına ek olarak paylaşılan, eğitsel içerikleri artırarak öğrenmeyi de arttıracak makale, okuma parçası, vaka çalışması, video vb. dış kaynak paylaşımlarıdır. Eşzamansız etkinliğe öğrenciler istediği zaman erişim sağlamaktadır (“İstanbul Arel Üniversitesi”, 2022).

Raporlar/Günlükler sayfasındaki “Tüm Etkinlikler” alanından ilgili etkinlik seçilerek, her hafta için ayrı ayrı .xlsx formatında indirilmiştir.

Tablo 2. Haftalık dış kaynak (okuma metinleri/video) 14 haftalık dijital ayak izleri raporu

Zaman	Kullanıcı #	Etkinlik başlığı	Bilgi	Bölüm adı	Açıklama	Köken IP adresi
12/01/23, 08:02	STU01	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18944' viewed the 'folder' activity with course module id '98' web	IP01
7/01/23, 22:21	STU02	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18946' viewed the 'folder' activity with course module id '98' web	IP02
9/12/22, 14:59	STU03	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18965' viewed the 'folder' activity with course module id '98' web	IP03
7/12/22, 19:10	STU04	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18659' viewed the 'folder' activity with course module id '98' web	IP04
27/11/22, 19:06	STU05	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20857' viewed the 'folder' activity with course module id '98' web	IP05
26/11/22, 00:16	STU06	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '19956' viewed the 'folder' activity with course module id '98' web	IP06
23/11/22, 13:58	STU07	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	İndirilen klasörün zip arşivi	The user with id '18924' downloaded a zip archive containing all the files from web	IP07
20/11/22, 11:05	STU08	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18946' viewed the 'folder' activity with course module id '98' web	IP08
17/11/22, 14:59	STU09	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '19944' viewed the 'folder' activity with course module id '98' web	IP09
17/11/22, 13:48	STU10	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20866' viewed the 'folder' activity with course module id '98' web	IP10
16/11/22, 23:50	STU11	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20852' viewed the 'folder' activity with course module id '98' web	IP11
16/11/22, 12:23	STU12	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20870' viewed the 'folder' activity with course module id '98' web	IP12
13/11/22, 14:30	STU13	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20857' viewed the 'folder' activity with course module id '98' web	IP13
5/11/22, 15:15	STU14	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20872' viewed the 'folder' activity with course module id '98' web	IP14
25/10/22, 06:46	STU15	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18923' viewed the 'folder' activity with course module id '98' web	IP15
21/10/22, 15:52	STU16	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20872' viewed the 'folder' activity with course module id '98' web	IP16
20/10/22, 15:36	STU17	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20852' viewed the 'folder' activity with course module id '98' web	IP17
19/10/22, 18:22	STU18	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20857' viewed the 'folder' activity with course module id '98' web	IP18
19/10/22, 18:09	STU19	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20880' viewed the 'folder' activity with course module id '98' web	IP19
19/10/22, 16:10	STU20	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20880' viewed the 'folder' activity with course module id '98' web	IP20
16/10/22, 22:29	STU21	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18940' viewed the 'folder' activity with course module id '98' web	IP21
13/10/22, 15:57	STU22	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	İndirilen klasörün zip arşivi	The user with id '20878' downloaded a zip archive containing all the files from web	IP22
13/10/22, 15:14	STU23	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20870' viewed the 'folder' activity with course module id '98' web	IP23
12/10/22, 18:05	STU24	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '19973' viewed the 'folder' activity with course module id '98' web	IP24
12/10/22, 12:51	STU25	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '19950' viewed the 'folder' activity with course module id '98' web	IP25
12/10/22, 12:50	STU26	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20875' viewed the 'folder' activity with course module id '98' web	IP26
12/10/22, 12:16	STU27	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18927' viewed the 'folder' activity with course module id '98' web	IP27
12/10/22, 00:57	STU28	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	İndirilen klasörün zip arşivi	The user with id '20857' downloaded a zip archive containing all the files from web	IP28
8/10/22, 12:47	STU29	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '19963' viewed the 'folder' activity with course module id '98' web	IP29
8/10/22, 11:51	STU30	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20877' viewed the 'folder' activity with course module id '98' web	IP30
8/10/22, 10:19	STU31	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '19953' viewed the 'folder' activity with course module id '98' web	IP31
6/10/22, 14:38	STU32	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	İndirilen klasörün zip arşivi	The user with id '19975' downloaded a zip archive containing all the files from web	IP32
6/10/22, 09:50	STU33	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '20858' viewed the 'folder' activity with course module id '98' web	IP33
6/10/22, 08:54	STU34	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	Ders modülü görüntülendi	The user with id '18944' viewed the 'folder' activity with course module id '98' web	IP34
5/10/22, 23:23	STU35	- Klasör: HAFTALIK DIŞ KAYNAK (Okuma Metinleri / Video)	Klasör	İndirilen klasörün zip arşivi	The user with id '19953' downloaded a zip archive containing all the files from web	IP35

Haftalık Çalışma Soruları: Çalışma soruları 14 hafta süresince ilgili haftanın öğrenme hedeflerine uygun olarak konuyu pekiştirmeye yönelik paylaşımlardır. Eşzamansız etkinliğe öğrenciler istediği zaman erişim sağlamaktadır (“İstanbul Arel Üniversitesi”, 2022).

Raporlar/Günlükler sayfasındaki “Tüm Etkinlikler” alanından ilgili etkinlik seçilerek, her hafta için ayrı ayrı .xlsx formatında indirilmiştir.

Tablo 3. Haftalık soru 14 haftalık dijital ayak izleri raporu

Zaman	Kullanıcı	Etkinlik bağlamı	Bileşen	Etkinlik adı	Açıklama	Köken	IP adresi
11/01/23, 19:37	STU01	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19948' viewed the 'folder' activity with course module id '98 web		IP01
11/01/23, 19:26	STU02	- Klasör: HAFTALIK SORU (5 adet)	Klasör	İndirilen klasörün zip arşivi	The user with id '19948' downloaded a zip archive containing all the files from web		IP02
11/01/23, 18:39	STU03	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '18916' viewed the 'folder' activity with course module id '98 web		IP03
11/01/23, 15:13	STU04	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20876' viewed the 'folder' activity with course module id '98 web		IP04
10/01/23, 19:02	STU05	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '3659' viewed the 'folder' activity with course module id '98 web		IP05
7/01/23, 22:22	STU06	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '18946' viewed the 'folder' activity with course module id '98 web		IP06
7/01/23, 03:00	STU07	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20857' viewed the 'folder' activity with course module id '98 web		IP07
1/01/23, 01:15	STU08	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20856' viewed the 'folder' activity with course module id '98 web		IP08
27/12/22, 21:02	STU09	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20856' viewed the 'folder' activity with course module id '98 web		IP09
11/12/22, 23:45	STU10	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '18935' viewed the 'folder' activity with course module id '98 web		IP10
11/12/22, 22:22	STU11	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19963' viewed the 'folder' activity with course module id '98 web		IP11
11/12/22, 15:01	STU12	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20864' viewed the 'folder' activity with course module id '98 web		IP12
11/12/22, 12:15	STU13	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '10104' viewed the 'folder' activity with course module id '98 web		IP13
10/12/22, 22:42	STU14	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '18940' viewed the 'folder' activity with course module id '98 web		IP14
9/12/22, 10:46	STU15	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '17835' viewed the 'folder' activity with course module id '98 web		IP15
30/11/22, 07:21	STU16	- Klasör: HAFTALIK SORU (5 adet)	Klasör	İndirilen klasörün zip arşivi	The user with id '20859' downloaded a zip archive containing all the files from web		IP16
25/11/22, 20:02	STU17	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19956' viewed the 'folder' activity with course module id '98 web		IP17
25/11/22, 12:04	STU18	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19956' viewed the 'folder' activity with course module id '98 web		IP18
25/11/22, 08:31	STU19	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19956' viewed the 'folder' activity with course module id '98 web		IP19
23/11/22, 17:40	STU20	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19960' viewed the 'folder' activity with course module id '98 web		IP20
21/11/22, 02:01	STU21	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20857' viewed the 'folder' activity with course module id '98 web		IP21
18/11/22, 10:38	STU22	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19956' viewed the 'folder' activity with course module id '98 web		IP22
17/11/22, 15:13	STU23	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19944' viewed the 'folder' activity with course module id '98 web		IP23
17/11/22, 14:57	STU24	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19944' viewed the 'folder' activity with course module id '98 web		IP24
16/11/22, 23:50	STU25	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20852' viewed the 'folder' activity with course module id '98 web		IP25
16/11/22, 12:23	STU26	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20870' viewed the 'folder' activity with course module id '98 web		IP26
14/11/22, 20:41	STU27	- Klasör: HAFTALIK SORU (5 adet)	Klasör	İndirilen klasörün zip arşivi	The user with id '19967' downloaded a zip archive containing all the files from web		IP27
13/11/22, 14:10	STU28	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '20857' viewed the 'folder' activity with course module id '98 web		IP28
9/11/22, 12:31	STU29	- Klasör: HAFTALIK SORU (5 adet)	Klasör	Ders modülü görüntülendi	The user with id '19958' viewed the 'folder' activity with course module id '98 web		IP29
9/11/22, 12:18	STU30	- Klasör: HAFTALIK SORU (5 adet)	Klasör	İndirilen klasörün zip arşivi	The user with id '19968' downloaded a zip archive containing all the files from web		IP30

Canlı (Çevrimiçi) Ders Anlatımı Etkinlikleri: Canlı yapılan dersler, ÖBS üzerinde ilan edilen programa uygun olarak sanal sınıf platformu üzerinden 14 hafta süresince eşzamanlı (senkron) gerçekleştirilen etkinliklerdir. Canlı derse katılım yoklamalarına dair veriler Moodle ÖYS içinde entegre çalışan Adobe Connect sanal sınıf platformu üzerinden indirilerek kullanılmıştır (“İstanbul Arel Üniversitesi”, 2022).

Bahsedilen haftalık etkinliklere öğrencilerin erişimlerini gösteren raporlar hafta bazında .xlsx formatında indirilmiştir.

Tablo 4. Canlı ders anlatımı dijital ayak izleri raporu

Varlık	Scor	Kullanıcı	Oturum	Oturum Adı	Öğretici	Süre Başlangıcı	Süre Sonu	Ad	Anket	Oturum	Alınan Süre	Süre	Satır Etiketleri	Toplam Süre
6,7E+09	7E+09	7E+09	2,2E+08	STU1	Ataturk-il	2022-10-05 12:52:24	2022-10-05 12:54:42	STU1	1	2,2E+08	00:02:18	00:02:18	STU1	00:41:53
6,7E+09	7E+09	7E+09	2,2E+08	STU1	Ataturk-il	2022-10-05 11:56:05	2022-10-05 12:52:15	STU1	1	2,2E+08	00:56:09	00:56:09	STU1	00:56:37
6,7E+09	7E+09	7E+09	2,2E+08	STU2	Ataturk-il	2022-10-05 12:43:34	2022-10-05 12:54:32	STU2	1	2,2E+08	00:10:58	00:10:58	STU2	01:02:41
6,7E+09	7E+09	7E+09	2,2E+08	STU2	Ataturk-il	2022-10-05 12:29:46	2022-10-05 12:43:18	STU2	1	2,2E+08	00:13:31	00:13:31	STU2	01:01:31
6,7E+09	7E+09	7E+09	2,2E+08	STU2	Ataturk-il	2022-10-05 12:13:15	2022-10-05 12:29:23	STU2	1	2,2E+08	00:16:07	00:16:07	STU2	01:02:17
6,7E+09	7E+09	7E+09	2,2E+08	STU2	Ataturk-il	2022-10-05 12:08:28	2022-10-05 12:13:39	STU2	1	2,2E+08	00:05:10	00:05:10	STU2	00:53:13
6,7E+09	7E+09	7E+09	2,2E+08	STU3	Ataturk-il	2022-10-05 11:58:55	2022-10-05 12:54:38	STU3	1	2,2E+08	00:55:42	00:55:42	STU3	00:57:37
6,7E+09	7E+09	7E+09	2,2E+08	STU3	Ataturk-il	2022-10-05 11:54:56	2022-10-05 11:58:43	STU3	1	2,2E+08	00:03:46	00:03:46	STU3	00:58:27
6,7E+09	7E+09	7E+09	2,2E+08	STU4	Ataturk-il	2022-10-05 11:48:45	2022-10-05 12:54:45	STU4	1	2,2E+08	01:05:59	01:05:59	STU4	01:04:03
6,7E+09	7E+09	7E+09	2,2E+08	STU5	Ataturk-il	2022-10-05 12:02:09	2022-10-05 12:54:35	STU5	1	2,2E+08	00:52:25	00:52:25	STU5	00:59:37
6,7E+09	7E+09	7E+09	2,2E+08	STU6	Ataturk-il	2022-10-05 11:46:41	2022-10-05 12:54:29	STU6	1	2,2E+08	01:07:48	01:07:48	STU6	01:18:47
6,7E+09	7E+09	7E+09	2,2E+08	STU7	Ataturk-il	2022-10-05 11:40:53	2022-10-05 11:45:58	STU7	1	2,2E+08	00:05:04	00:05:04	STU7	01:08:59
6,7E+09	7E+09	7E+09	2,2E+08	STU8	Ataturk-il	2022-10-05 12:20:53	2022-10-05 12:54:35	STU8	1	2,2E+08	00:33:42	00:33:42	STU8	01:05:59
6,7E+09	7E+09	7E+09	2,2E+08	STU8	Ataturk-il	2022-10-05 12:04:01	2022-10-05 12:09:49	STU8	0	2,2E+08	00:05:47	00:05:47	STU8	01:06:51
6,7E+09	7E+09	7E+09	2,2E+08	STU9	Ataturk-il	2022-10-05 11:48:47	2022-10-05 12:54:50	STU9	1	2,2E+08	01:06:02	01:06:02	STU9	00:56:27
6,7E+09	7E+09	7E+09	2,2E+08	STU9	Ataturk-il	2022-10-05 12:04:49	2022-10-05 12:54:50	STU9	1	2,2E+08	00:50:01	00:50:01	STU9	00:47:55
6,7E+09	7E+09	7E+09	2,2E+08	STU10	Ataturk-il	2022-10-05 12:17:30	2022-10-05 12:54:41	STU10	1	2,2E+08	00:37:11	00:37:11	STU10	01:08:09
6,7E+09	7E+09	7E+09	2,2E+08	STU10	Ataturk-il	2022-10-05 12:16:35	2022-10-05 12:57:25	STU10	1	2,2E+08	00:40:50	00:40:50	STU10	01:03:01
6,7E+09	7E+09	7E+09	2,2E+08	STU11	Ataturk-il	2022-10-05 11:56:49	2022-10-05 12:54:48	STU11	1	2,2E+08	00:57:58	00:57:58	STU11	01:00:15

Ölçme Değerlendirme Etkinlikleri: Yarıyıl içinde ders öğrenme çıktılarına ölçecek sınav, ödev gibi ders ölçme değerlendirme etkinlikleri yapılmakta, yarıyıl sonunda da final ve bütünleme sınavları yapılmaktadır. Yıl içi etkinliklerinin %40'ı, yarıyıl sonu etkinliklerinin %60'ı alınarak başarı notları hesaplanmaktadır. Başarı notları ÖBS üzerinden .xlsx formatında indirilmiştir. Başarı notlarının yer aldığı tabloda, Öğrenci numarası, Adı Soyadı bilgileri ve Ödev notu, Final notu, Bütünleme notu ve ağırlıkları, Harf notu, Geçme durumu bilgileri yer almaktadır.

Tablo 5. Başarı notları

No	Öğrenci No	Adı_21	Soyadı_21	Sınıf	Ödev(%40)	Final(%60)	But(%60)	HBN	Harf
125	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	10	40		28	FF
32	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	0	50		30	FF
59	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	60	45		51	DC
70	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	85	35		55	CC
54	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	85	95		91	AA
37	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	100	70		82	BA
61	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	32	90		67	CB
85	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	90	55		69	CB
44	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	90	20		48	DC
110	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	95	45		65	CB
124	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	80	65		71	CB
94	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	70	90		82	BA
55	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	100	100		100	AA
111	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	0			0	FF
28	XXXXXXXXXX	XXXXXXXXXX	XXXXXXXXXX	1	100	45		67	CB

3.2. Verilerin İşlenmesi

Moodle Öğrenme Yönetim Sisteminden elde edilen veriler ve ÖBS üzerinden elde edilen veriler “Rapor, Verilerin İşlenmesi” adlı .xlsx dokümanında formüllerle birleştirilmiştir. Bu tez çalışmasındaki öğrenci kişisel bilgilerine dair veriler gizli tutularak kullanılmıştır.

Haftalık Ders Sunumu paylaşımları, Haftalık Dış Kaynak eşzamansız etkinlikleri Haftalık Soru etkinliklerine (“areluzem.arel.edu.tr”) dair öğrenci etkinlik katılım sayıları ilgili haftalara ait .xlsx dosyalarından “=EĞERSAY” formülü ile “Rapor, Verilerin Toplanması” adlı dosyaya işlenmiştir. İlgili haftadaki etkinliği kaç defa görüntülediğine dair her bir hafta için tek tek yazılmıştır.

Canlı ders katılımlarına dair veriler öğrencilerin her hafta yapılan eş zamanlı etkinliğe toplam katılım süresi üzerinden her hafta için ayrı ayrı yazılmıştır. Saat formatında yazılı olan katılım süreleri “=SAYIYAÇEVİR” formülü ile çevrilmiştir ve “=DÜŞEYARA(B2;'1. Hafta ATA.xlsx'!\$E\$1:\$P\$120;12;0)” formülü ile “Rapor, Verilerin Toplanması” adlı dosyaya işlenmiştir.

Tablo 6. Verilerin işlenmiş versiyonundan bir örnek

ID	QW1	QW2	QW3	QW4	QW5	LNW8	LNW9	ESW1	ESW2	ESW3	ESW4	ESW13	ESW14	OCW1	OCW2	OCW3	OCW7	OCW8	OCW9	OCW10	OCW11	OCW14	Harf Notu	Geçti/Kaldı	
STU1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	302	0	0	0	0	0	0	0	0	0	
STU2	1	0	0	0	0	0	0	2	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1218	0	0	0	0	2172	0	0	0	
STU4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	1	
STU9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6648	0	0	0	0	0	0	3	1	
STU10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
STU12	2	2	2	2	2	0	0	1	1	0	0	0	0	0	3306	3557	3412	3719	3762	3805	3167	5163	3444	6	1
STU13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2721	3539	2744	3114	2829	3091	0	2290	0	6	1
STU14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2529	1233	7571	3172	3674	4742	3019	2306	0	6	1
STU15	2	3	2	2	2	7	3	7	7	4	4	0	0	0	2944	3253	2836	3402	2148	3357	0	2610	3282	7	1
STU16	0	0	0	0	0	1	0	0	0	0	0	0	0	0	2629	6830	6832	3503	3550	7068	1198	0	0	5	1
STU17	0	0	0	0	0	0	0	2	2	0	0	0	0	0	0	0	0	0	3518	0	0	0	0	4	1
STU18	1	0	0	0	0	1	1	0	0	1	0	0	0	0	0	3606	0	3799	0	3620	3502	3724	3884	6	1
STU19	1	0	0	0	0	0	0	0	0	0	0	0	0	0	3290	3894	2703	3608	3463	3747	2626	2399	0	6	1
STU20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2204	0	0	0	0	0	0	0	0
STU21	0	0	0	0	0	0	0	4	4	1	0	1	1	0	2855	3801	2960	3146	3086	2873	3044	2607	0	5	1
STU22	3	4	2	1	1	0	0	1	1	0	0	0	0	0	0	3312	3426	4388	3011	4797	5172	4524	3137	6	1
STU23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	770	0	0	0	7183	0	0	0	0	5	1
STU24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2838	3146	1152	3321	3775	1995	4113	2489	3221	0	0
STU25	1	0	1	0	0	0	0	5	5	1	0	0	0	0	2872	4151	2831	3833	3330	6115	0	3198	3393	5	1
STU26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2849	3358	2900	3294	3544	3326	5151	2467	0	7	1
STU27	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	3946	0	0	3067	0	0	0	0	6	1
STU28	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4712	5440	0	0	0	0	0	4	1
STU29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5563	829	4193	7125	3899	0	0	0	5	1
STU30	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
STU31	1	0	0	0	0	0	0	0	0	0	0	0	0	0	2729	3654	3567	3379	2869	2995	2998	2619	3020	5	1
STU32	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3354	1349	3437	0	2079	3616	5	1
STU33	2	1	1	1	1	0	0	1	1	0	0	0	0	0	3024	4192	3346	3856	3596	4075	3731	3209	3457	6	1
STU34	2	0	0	0	0	0	0	0	0	0	0	0	0	0	1292	631	0	0	0	0	0	0	0	2	1
STU35	0	0	0	0	0	2	2	0	0	0	0	0	0	0	0	3545	0	0	132	3580	2749	1460	0	6	1
STU36	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3280	3023	2607	3396	3074	1683	1367	1984	1890	6	1

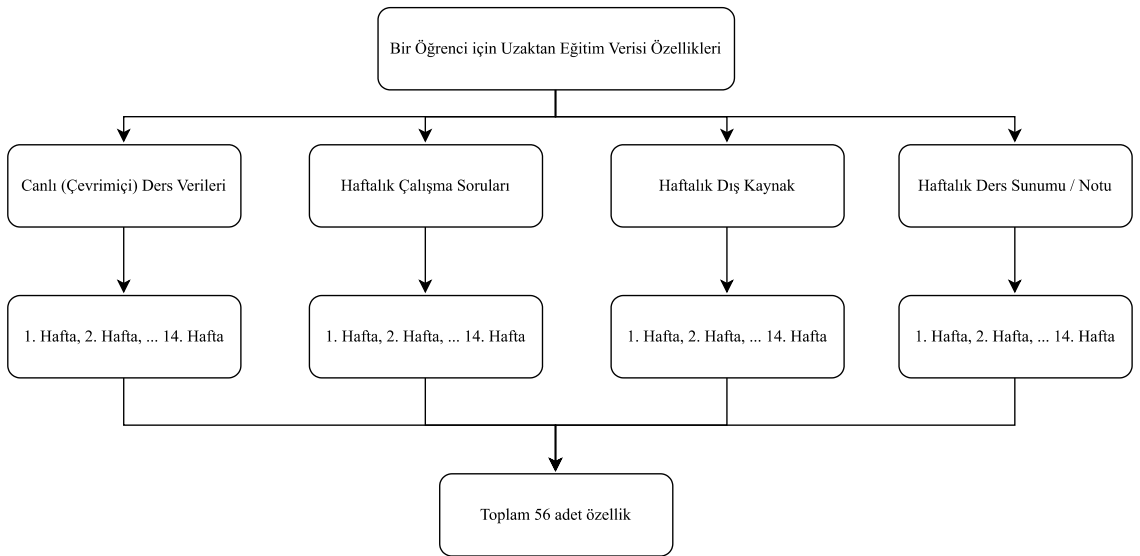
BÖLÜM 4

FPFS-kNN İLE ÖĞRENCİ PERFORMANSI TAHMİNİ

Bu bölümde Moodle öğrenme yönetim sistemi üzerinden toplanan verilerle oluşturulan veri setlerinin özellikleri verildi. Daha sonra, sınıflandırma problemi için performans metriklerinin matematiksel notasyonları ifade edildi. FPFS-kNN ve bilinen/son teknoloji makine öğrenimi yönetimlerinden bazıları veri setleri üzerine uygulandı ve performans sonuçları karşılaştırıldı.

4.1. Moodle Öğrenme Sistemi Veri Setlerinin Özellikleri

Bu alt bölümde, Moodle Öğrenme Yönetim Sistemi verileri ve ÖBS verileri Bölüm 3'te detaylı olarak anlatıldığı şekilde işlenerek makine öğreniminde kullanılmak üzere altı adet veri seti oluşturulmuştur. Uzaktan eğitim ile verilen derslerde eğitim, 14 hafta süresince haftalık olarak yapılan eş zamanlı ve eş zamansız etkinlikler üzerinden tamamlanmıştır. Eğitimin her haftası, Canlı (çevrimiçi) ders, haftanın konusuna dair ders sunumu dosyası, dış kaynak paylaşımları ve haftalık çalışma soruları etkinliklerinden oluşmaktadır. Türk Dili I, Atatürk İlkeleri ve İnkılap Tarihi I ve İngilizce I dersleri için geçti-kaldı ve harf başarı notları olmak üzere ikişer veri seti oluşturulmuştur. Her bir veri seti bahsi geçen etkinliklerin verilerinden oluşmaktadır (Şekil 10). Eksik sütunlardan dolayı sadece İngilizce I dersi verilerinde 4 özellik sütunu veri setinde 0 olarak değerlendirilmiştir.



Şekil 10. Bir öğrenci verisi için özelliklerin dağılımı

Tablo 7. Tez çalışmasında oluşturulan veri setlerinin özellikleri

Veri seti	Örnek Sayısı	Özellik Sayısı	Sınıf Sayısı
ATAFALL1	231	56	2
ATAFALL2	231	56	9
TDEFALL1	197	56	2
TDEFALL2	197	56	9
INGFALL1	215	56	2
INGFALL2	215	56	9

4.2. Sınıflandırma Problemi için Performans Metrikleri

Bu alt bölümde, algoritmaların performanslarını karşılaştırabilmek için yaygın olarak kullanılan doğruluk (Acc) (Denklem 4.5 ve 4.14), kesinlik (Pre) (Denklem 4.6 ve 4.15), duyarlık (Rec) (Denklem 4.7 ve 4.16), makro F-skor (MacF) (Denklem 4.8 ve 4.17) ve mikro F-skor (MicF) (Denklem 4.9 ve 4.18) performans metrikleri sunuldu. Bu performans metriklerinin matematiksel notasyonları aşağıdaki gibidir.

Sınıflandırılmak istenen n tane örnek $X = \{x_1, x_2, \dots, x_n\}$ şeklinde gösterilsin. $\mathbb{Y} = \{\mathbb{Y}_1, \mathbb{Y}_2, \dots, \mathbb{Y}_n\}$ bu örneklerin doğru sınıflarını, $\hat{\mathbb{Y}} = \{\hat{\mathbb{Y}}_1, \hat{\mathbb{Y}}_2, \dots, \hat{\mathbb{Y}}_n\}$ bu örneklerin tahmin edilen sınıflarını ve l toplam sınıf sayısını gösterebilir.

İkili sınıf içeren veri setleri göz önüne alındığında, doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerleri:

$$TP = |\{x_t \mid 1 \in \mathbb{Y}_t \wedge 1 \in \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.1)$$

$$TN = |\{x_t \mid 0 \notin \mathbb{Y}_t \wedge 0 \notin \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.2)$$

$$FP = |\{x_t \mid 0 \notin \mathbb{Y}_t \wedge 1 \in \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.3)$$

$$FN = |\{x_t \mid 1 \in \mathbb{Y}_t \wedge 0 \notin \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.4)$$

olmak üzere,

$$\text{Acc}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{TP + TN}{TP + TN + FP + FN} \quad (4.5)$$

$$\text{Pre}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{TP}{TP + FP} \quad (4.6)$$

$$\text{Rec}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{TP}{TP + FN} \quad (4.7)$$

$$\text{MacF}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{2TP}{2TP + FP + FN} \quad (4.8)$$

$$\text{MicF}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{2TP}{2TP + FP + FN} \quad (4.9)$$

biçimindedir.

Çoklu sınıf içeren veri setleri göz önüne alındığında, i . sınıf için doğru pozitif (TP_i), doğru negatif (TN_i), yanlış pozitif (FP_i) ve yanlış negatif (FN_i) değerleri:

$$TP_i := |\{x_t \mid i \in \mathbb{Y}_t \wedge i \in \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.10)$$

$$TN_i := |\{x_t \mid i \notin \mathbb{Y}_t \wedge i \notin \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.11)$$

$$FP_i := |\{x_t \mid i \notin \mathbb{Y}_t \wedge i \in \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.12)$$

$$FN_i := |\{x_t \mid i \in \mathbb{Y}_t \wedge i \notin \hat{\mathbb{Y}}_t, 1 \leq t \leq n\}| \quad (4.13)$$

olmak üzere,

$$\text{Acc}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{1}{l} \sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \quad (4.14)$$

$$\text{Pre}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{1}{l} \sum_{i=1}^l \frac{TP_i}{TP_i + FP_i} \quad (4.15)$$

$$\text{Rec}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{1}{l} \sum_{i=1}^l \frac{TP_i}{TP_i + FN_i} \quad (4.16)$$

$$\text{MacF}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{1}{l} \sum_{i=1}^l \frac{2TP_i}{2TP_i + FP_i + FN_i} \quad (4.17)$$

$$\text{MicF}(\mathbb{Y}, \hat{\mathbb{Y}}) := \frac{2 \sum_{i=1}^l TP_i}{2 \sum_{i=1}^l TP_i + \sum_{i=1}^l FP_i + \sum_{i=1}^l FN_i} \quad (4.18)$$

biçimindedir.

4.3. FPFS-kNN'nin Moodle Öğrenme Sistemi Veri Setleri Üzerine Uygulanması

Bu alt bölümde, elde edilen Moodle öğrenme sistemi veri setine kNN (Fix ve Hodges 1951; Cover ve Hart 1967), SVM (Cortes ve Vapnik 1995), Fuzzy kNN (Keller ve ark. 1985), Boosted Tree (Friedman, 2001), FPFS-EC (Memiş, Enginoğlu ve Erkan, 2021), FPFS-CMC (Memiş, Enginoğlu ve Erkan, 2022a), FPFS-AC (Memiş, Enginoğlu ve Erkan, 2022b), IFPIFSHC (Memiş, Arslan, Aydın, Enginoğlu, Camcı, 2021), IFPIFSC (Memiş, Arslan, Aydın, Enginoğlu, Camcı, 2023) ve FPFS-kNN (Memiş ve diğerleri, 2022c) makine öğrenimi algoritmaları uygulanmıştır. Sonuçların karşılaştırılması için Bölüm 4.2'de matematiksel notasyonları verilen Acc, Pre, Rec, MacF ve MicF performans metrikleri kullanılmıştır.

FPFS-kNN ve makine öğrenimi sınıflandırma performansı için beş performans ölçütü (doğruluk, kesinlik, duyarlık ve F1-skor metrikleri kullanılarak simülasyon gerçekleştirilmiştir. Simülasyon sonuçlarını elde etmek için MATLAB R2021b yazılımı ve I(R) Core(TM) CPU i5-4200H @ 2.8 GHz işlemci ve 8 GB RAM donanımına sahip bir dizüstü bilgisayar kullanıldı.

Her bir sınıflandırma algoritması, k-fold çapraz doğrulama (Stone, 1974) yoluyla eğitildi ve test edildi. k-fold çapraz doğrulamada, veri setleri eşit boyutlu k parçaya ayrılır. Bu süreç rastgele gerçekleşmektedir. Bir parça doğrulama verisi (test verisi) olarak kullanılırken, kalan k-1 parça algoritmayı eğitmek için eğitim verisi olarak kullanılmaktadır. Çapraz doğrulama işlemi k kez tekrarlandığından dolayı, her parça test verisi olarak yalnızca bir kez kullanılır. Bu nedenle, veri setindeki tüm örnekler hem eğitim hem de test verileri olarak kullanılmış olur.

Bu tez çalışmasında, simülasyonlarda 5-fold çapraz doğrulama kullanıldı ve bu 5 iterasyon için elde edilen ortalama performans sonuçları ve çalışma süreleri kaydedildi. Daha sonra, bu işlem 10 kez tekrarlandı. Son olarak, 10 tekrardan elde edilen Acc, Pre, Rec, MacF, MicF ve çalışma süresi sonuçları elde edildi. 5-fold çapraz doğrulama ve 10 tekrar (Yani toplam 50 çalıştırma) ile elde edilen performans sonuçları Tablo 8 ve 9'da sunulmaktadır.

Tablo 8, ATAFALL1, TDEFALL1 ve INGFAIL1 (geçti-kaldı olarak iki sınıflı) veri setleri için FPFS-kNN ve göz önüne alınan sınıflandırıcılar için Acc, Pre, Rec, MacF, MicF, çalışma süresi sonuçlarını göstermektedir. Üç veri seti için FPFS-kNN'nin Acc ve Pre sonuçları diğer sınıflandırıcılardan öndedir. ATAFALL1 ve INGFAIL1 veri setlerinde Rec sonuçları hariç diğer bütün sonuçlarda FPFS-kNN en yüksek sonuçlara sahiptir.

Tablo 8. İki sınıflı veri setleri için simülasyon sonuçları

Veri seti	Sınıflandırıcı	Acc	Pre	Rec	MacF	MicF	Çalışma Süresi
ATA1	kNN	81.0777	53.5947	68.9333	59.6253	59.6253	0.1034
	SVM	68.0157	26.3205	43.8889	49.4532	49.4532	1.9394
	Fuzzy kNN	80.4339	52.6061	67.5333	58.0531	58.0531	0.0030
	Decision Tree	79.7475	51.3257	66.7556	57.2288	57.2288	0.0148
	Boosted Tree	80.1369	51.6884	62.5333	55.9371	55.9371	0.7714
	FPFS-EC	77.0241	46.4512	68.6000	56.5098	56.5098	0.0295
	FPFS-CMC	75.8973	44.4208	68.8222	55.2284	55.2284	0.6006
	FPFS-AC	77.9343	47.2103	60.8667	54.2972	54.2972	1.3149
	FPFS-kNN	82.6013	57.1437	68.3111	61.3597	61.3597	0.5549
	IFPIFS-HC(5,5)	74.6383	42.8972	67.5333	51.5623	51.5623	0.1045
IFPIFSC(5,5)	77.4052	47.3251	66.8889	54.2924	54.2924	0.6891	
TDE1	kNN	78.8167	53.8404	71.5556	60.7308	60.7308	0.0736
	SVM	66.7385	29.3013	43.1111	51.7504	51.7504	1.5103
	Fuzzy kNN	78.9718	54.1310	71.7778	61.0598	61.0598	0.0023
	Decision Tree	80.3321	56.9217	70.8889	62.2114	62.2114	0.0125
	Boosted Tree	79.8410	56.0210	59.7778	57.1737	57.1737	0.5686
	FPFS-EC	76.9962	50.6218	75.7778	60.1643	60.1643	0.0211
	FPFS-CMC	75.5769	48.4870	76.2222	58.8425	58.8425	0.3561
	FPFS-AC	79.1218	54.6762	66.8889	59.4644	59.4644	0.7308
	FPFS-kNN	81.4205	58.6826	70.2222	63.1881	63.1881	0.3095
	IFPIFS-HC(5,5)	78.5641	52.6351	82.8889	64.0123	64.0123	0.0667
IFPIFSC(5,5)	80.3372	55.6731	82.6667	65.9478	65.9478	0.3947	
ING1	kNN	79.9884	41.9123	51.6071	45.3359	45.3359	0.1622
	SVM	45.0116	5.5566	13.7857	45.8291	45.8291	2.1190
	Fuzzy kNN	81.0095	44.9123	50.5714	46.3072	46.3072	0.0069
	Decision Tree	78.8436	39.7839	48.0000	43.9456	43.9456	0.0196
	Boosted Tree	80.9725	43.0200	38.9286	41.3142	41.3142	0.9012
	FPFS-EC	78.7474	39.8742	52.9286	44.6247	44.6247	0.0375
	FPFS-CMC	78.2326	40.0256	53.9286	44.6893	44.6893	0.7033
	FPFS-AC	78.2696	37.2014	41.9286	40.4308	40.4308	1.3145
	FPFS-kNN	83.2357	50.8535	47.5714	47.5589	47.5589	0.5839
	IFPIFS-HC(5,5)	77.5835	37.9055	51.3929	42.8171	42.8171	0.1115
IFPIFSC(5,5)	76.7104	37.6583	53.3929	43.0671	43.0671	0.7349	

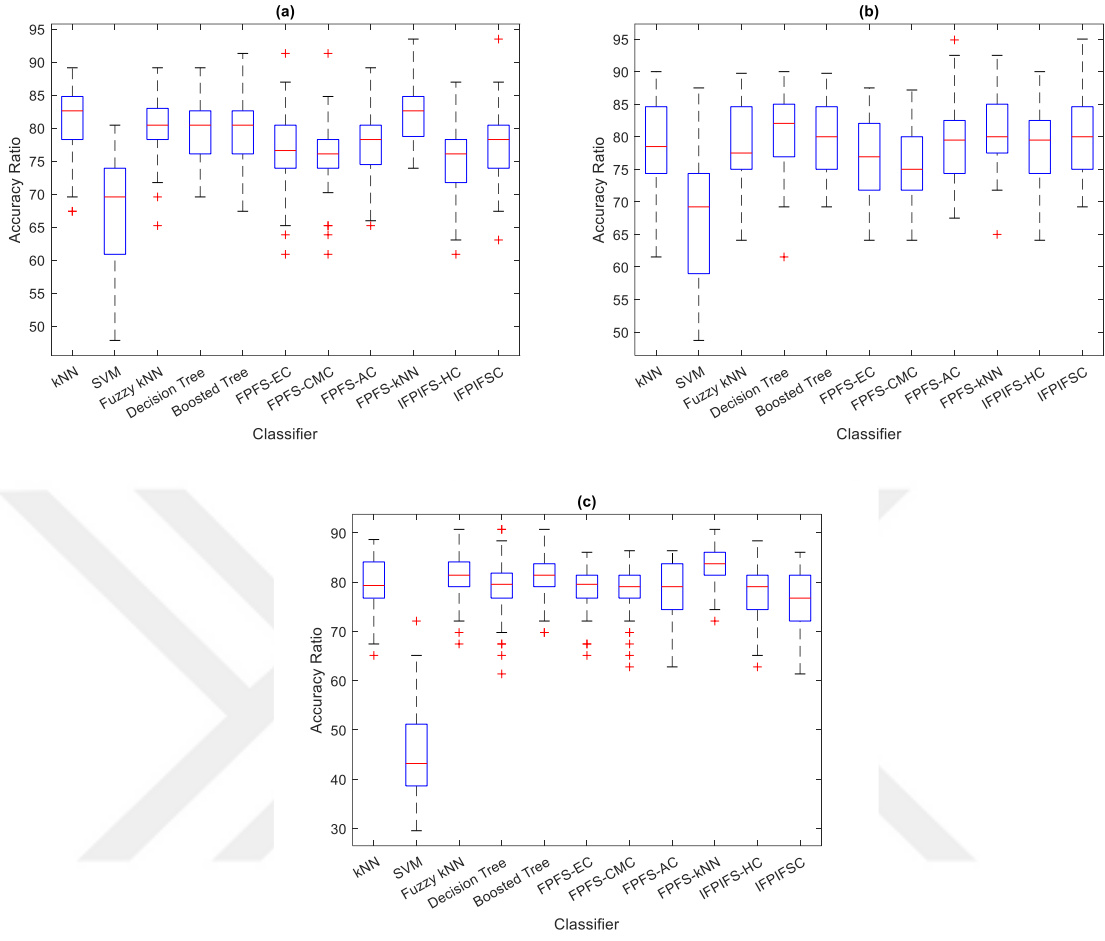
Tablo 9, ATAFALL2, TDEFALL2 ve ING FALL2 (harf notları olarak 9 sınıflı) veri setleri için FPFS-kNN ve göz önüne alınan sınıflandırıcılar için Acc, Pre, Rec, MacF, MicF, çalışma süresi sonuçlarını göstermektedir. Üç veri seti için FPFS-kNN en iyi sonuçları üretmese de en yüksek sonuçlara yakın performans değerlerine sahiptir.

Her iki türdeki veri setleri için performans sonuçları değerlendirildiğinde, FPFS-kNN'nin geçti-kaldı şeklindeki ikili sınıflı veri setlerinde harf notlarına bağlı 9 sınıflı veri setlerine göre daha başarılı sonuçlar ürettiği görülmektedir. Bu nedenle, öğrencilerin bir dersteki katılım ve etkinlik verilerine dayalı olarak dersten geçip geçmediğini tahmin etmede başarı bir şekilde kullanılabilir.

Tablo 9. Çok sınıflı veri setleri için simülasyon sonuçları

Veri seti	Sınıflandırıcı	Acc	Pre	Rec	MacF	MicF	Çalışma Süresi
ATA2	kNN	82.8980	24.0503	21.0333	35.9574	31.5920	0.0887
	SVM	80.2405	13.8440	14.5238	29.3823	20.9621	19.5002
	Fuzzy kNN	82.8122	20.4654	19.9346	35.4595	25.0666	0.0027
	Decision Tree	81.9362	19.1728	19.3499	36.1695	27.7447	0.0166
	Boosted Tree	83.0615	22.5487	20.0937	39.0738	32.2461	0.6734
	FPFS-EC	81.4470	16.9573	17.9023	34.2206	25.7882	0.0242
	FPFS-CMC	81.6968	16.7524	17.6731	35.2556	26.7872	0.4930
	FPFS-AC	81.5548	17.6024	17.9004	34.9339	26.2192	1.0060
	FPFS-kNN	82.9429	23.1020	20.5203	38.6972	31.7715	0.4390
	IFPIFS-HC(5,5)	80.7986	13.9615	14.7151	32.3193	23.1943	0.0828
IFPIFSC(5,5)	80.7983	14.7030	15.4460	32.4933	23.1933	0.5558	
TDE2	kNN	81.4390	21.9543	21.8154	41.9412	33.7667	0.0915
	SVM	80.5478	19.7287	21.0890	33.1890	26.4692	15.4596
	Fuzzy kNN	83.1636	23.7802	22.8734	42.8055	33.9679	0.0026
	Decision Tree	82.4617	25.9851	22.5037	44.3635	36.8821	0.0226
	Boosted Tree	84.3112	35.6418	26.2860	49.5079	45.0179	0.7219
	FPFS-EC	82.2533	20.5031	20.2021	41.3690	34.0179	0.0222
	FPFS-CMC	82.0228	19.8777	19.7323	40.0434	33.4038	0.4111
	FPFS-AC	81.6127	22.5790	20.7401	38.8224	33.8513	0.8358
	FPFS-kNN	84.2082	27.5963	22.4094	48.9299	41.2179	0.3596
	IFPIFS-HC(5,5)	81.2333	17.1012	18.3787	45.5590	32.1487	0.0737
IFPIFSC(5,5)	82.3559	23.8076	22.5194	41.8603	36.7205	0.4528	
ING2	kNN	81.5196	21.4146	18.0817	32.9291	26.0782	0.1105
	SVM	79.8628	15.1309	16.2029	27.9604	19.4514	23.9562
	Fuzzy kNN	83.8951	24.8124	22.0992	36.2730	28.2896	0.0032
	Decision Tree	81.1808	19.9673	15.9662	32.2186	24.7230	0.0322
	Boosted Tree	82.1313	18.5780	16.8143	36.9665	28.5254	0.8882
	FPFS-EC	81.7693	21.5852	21.7313	33.7637	27.0772	0.0284
	FPFS-CMC	81.7011	21.2850	20.9645	33.6352	26.8044	0.5674
	FPFS-AC	81.3417	21.6273	21.7178	32.5494	25.3668	1.1133
	FPFS-kNN	82.1298	25.5743	18.0141	33.2043	28.5190	0.5009
	IFPIFS-HC(5,5)	82.3044	25.9646	25.9366	34.4038	29.2178	0.1028
IFPIFSC(5,5)	82.2119	24.1787	24.2833	34.7969	28.8478	0.6029	

Şekil 11 karşılaştırılan algoritmaların ikili sınıfla veri setleri üzerinde 50 çalıştırılma sonucunda elde edilen Acc performans değerlerinin kutu grafiklerini sunmaktadır. Şekil 11a'daki görsel sonuçlara göre FPFS-kNN en yüksek performans değerini üretmenin yanı sıra normal dağılıma yakın bir başarı performans değerlerine sahiptir. Şekil 11b'deki görsel sonuçlara göre FPFS-kNN her ne kadar en yüksek skoru elde etse de, 50 performans sonucu normal dağılımdan biraz uzaklaşmıştır. Şekil 11b'deki görsel sonuçlara göre FPFS-kNN hem en yüksek skoru üretmektedir hem de 50 performans sonuçları neredeyse normal dağılım sergilerken aynı zamanda da çeyrekler arası mesafe oldukça düşüktür.



Şekil 11. İkili sınıflı Modde veri setlerindeki 50 çalıştırma için Acc değerlerinin kutu grafikleri (a) ATAFALL1 (b) TDEFALL1 (c) ING FALL1

BÖLÜM 5

SONUÇ VE ÖNERİLER

Öğrencilerin ders başarı notlarının makine öğrenimi kullanılarak tahmin edilmesi ile eğitimcilerin erken geri bildirim almaları ve öğrenci başarısını iyileştirmek için önleyici stratejiler geliştirmeleri öğrencilerin akademik hayatı için büyük öneme sahiptir. Özellikle uzaktan eğitim sistemi üzerinden ders alan öğrencilerin eş zamanlı/eş zamansız ders katılımları ve ders etkinlik tamamlama oranları gibi birçok verisi sistem veri tabanlarına kaydedilmektedir. Bu tez çalışması, bu tip verilerden bir örneklem belirlemeye, bu verileri kullanarak FPFS-kNN ile öğrenci başarı tahmini yapmaya ve bilinen algoritmalar ile FPFS-kNN'nin performans sonuçlarını karşılaştırmaya odaklanmıştır.

İlk olarak, uzaktan eğitim ile verilen Türk Dili I, Atatürk İlkeleri ve İnkılap Tarihi I ve İngilizce I dersleri için 14 hafta süresince haftalık olarak yapılan eş zamanlı ve eş zamansız etkinlik verileri incelenmiştir. Her bir hafta için, canlı (çevrimiçi) ders, haftanın konusuna dair ders sunumu dosyası, dış kaynak paylaşımları ve haftalık çalışma soruları etkinlikleri verileri işlenerek her bir ders için biri geçti-kaldı diğeri harf notları olacak şekilde iki adet veri seti makine öğreniminde kullanılmak üzere oluşturulmuştur. Daha sonra, FPFS-kNN ile bilinen (kNN, SVM, Fuzzy kNN, Decision Tree ve Boosted Tree) ve son teknoloji makine öğrenimi algoritmaları (FPFS-EC, FPFS-CMC, FPFS-AC, IFPIFS-HC ve IFPIFSC) beş performans metriği (Acc, Pre, Rec, MacF ve MicF) kullanılarak çalışmada elde edilen ATAFALL1, TDEFALL1, ING FALL1, ATAFALL2, TDEFALL2 ve ING FALL2 veri setleri üzerine uygulanmıştır. Sonuçlar, FPFS-kNN'nin öğrencilerin derslerden geçti-kaldı şeklinde ikili sınıflandırılmasında diğer yöntemlerden daha başarılı olduğunu göstermektedir. Harf notları tabanlı veri setleri için sonuçlar incelendiğinde, FPFS-kNN en yüksek skorları üretmese de en yüksek skorlara yakın değerler üretmektedir.

Genel olarak, veri setlerindeki performans sonuçları çok yüksek değildir. Bunun nedenlerinin,

- i.* Bazı öğrencilerin derslere ve etkinliklere gerçekten katılmayıp sistem üzerinde katılmış görünmesi.
- ii.* Etkinliklerin yapılan sınavlarla örtüşme oranı
- iii.* Yüksek tahmin için daha fazla parametreye ihtiyaç olması şeklinde olabileceği düşünülmektedir.

Uzaktan eğitim sistemlerine FPFS-kNN kullanılarak bir ara yazılım eklenerek, öğrenciler 14 haftanın belli dönemlerinde dersten geçme-kalma tahminlerine göre sistem üzerinden otomatik olarak uyarılabilir. Benzer şekilde, ilgili dersin kazanımlarının öğrenci tarafından ne kazanıldığına dair veri setleri elde edilerek FPFS-kNN ders kazanım tahmininde de kullanılabilir. Son olarak, FPFS-kNN daha yüksek başarı için özelleştirilebilir veya FPFS-kNN'den daha genel matematiksel araçlar kullanılarak geliştirilmiş IFPIFS-HC ve IFPIFSC algoritmaları da yine yüksek başarı için ders başarı tahmini odaklı olarak özelleştirilebilir.



KAYNAKLAR

- Anisimova, A. (2019, 27 Kasım). Types of machine learning out there [Online]. Erişim adresi: (27 Nisan 2023) <https://idapgroup.com/blog/types-of-machine-learning-out-there>
- Altınsoy, F. (2019). Uzaktan eğitim öğrencilerinin başarılarının yapay zekâ teknikleri ile tahmini (Yüksek lisans tezi) Süleyman Demirel Üniversitesi. Erişim adresi: <https://search.ebscohost.com/login.aspx?direct=true&db=ir01942a&AN=hmn.suleyman-demirel..61ad4d2f7a0676e74ccea3f798c97308&lang=tr&site=eds-live>
- Atalay, M., ve Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları, Artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 155-172. <https://doi.org/10.20875/makusobed.309727>
- Azimi, S., Popa, C.-G., ve Cucić, T. (2020). Improving Students Performance in Small-Scale Online Courses—A Machine Learning-Based Intervention. *International Journal of Learning Analytics and Artificial Intelligence for Education (IJAI)*, 2 (2), 80. <https://doi.org/10.3991/ijai.v2i2.19371>
- Bognar, L., ve Fauszt, T. (2020, September). Different learning predictors and their effects for Moodle Machine Learning models. In 2020 11th IEEE International Conference on Cognitive Infocommunications (CogInfoCom) (pp. 000405-000410). IEEE.
- Cortes C., Vapnik V. (1995) Support Vector Machines. *Machine Learning*, 20(3):273–297
- Cover, T. M. ve Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13, 21-27. Erişim adresi: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=1053964&tag=1>
- Çağman N, Çıtak F ve Enginoğlu S (2010) Fuzzy parameterized fuzzy soft set theory and its applications. *Turkish Journal of Fuzzy Systems*, 1(1):21–35
- Çağman N, Çıtak F ve Enginoğlu S (2011a) FP-soft set theory and its applications. *Annals of Fuzzy Mathematics and Informatics*, 2(2):219–226
- Çağman N, Enginoğlu S ve Çıtak F (2011b) Fuzzy soft set theory and its applications. *Iranian Journal of Fuzzy Systems* 8(3):137–147
- Ersoy, M. (2014). Uzaktan eğitim uygulamalarında tam öğrenme modelinin öğrencilerin başarı ve tutumlarına etkisi (Doktora tezi). İnönü Üniversitesi Eğitim Bilimleri Enstitüsü. Erişim adresi: <http://abakus.inonu.edu.tr/xmlui/handle/11616/6069>

- Fix E, Hodges J. L. (1951) *Discriminatory analysis, nonparametric discrimination: Consistency properties*. USAF School of Aviation Medicine, Randolph Field. Eriřim adresi: <https://books.google.com.tr/books?hl=tr&lr=&id=Br33IRC3PkQC&oi=fnd&pg=PR3&ots=2ywRIubcJt&sig=>
- Friedman, J. H. (2001) Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29, 1189–1232.
- Graf, S. ve List, B. (2005) An Evaluation of Open Source E-Learning Platforms Stressing Adaptation Issues - *An Evaluation of 9 Open Source E-Learning Platforms*.
- Gürkut, C. ve Nat, M. (2018). Öğrenci Bilgi Sistemi Kalitesini ve Memnuniyetini Etkileyen Önemli Faktörler. *Avrasya Matematik, Fen ve Teknoloji Eğitimi Dergisi*, 14 (3), 923-932. <https://doi.org/10.12973/ejmste/81147>
- Güvenç, E., Sakal, M., Çetin, G., ve Özkaraca, O. (2022) Öğrencilerin Dersteki Niteliklerinin Makine Öğrenmesi Teknikleri Kullanılarak Sınıflandırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(3), 1359-1371. Eriřim adresi: <https://doi.org/10.29130/dubited.1017202>
- Ho, A., Reich, J., Nesterko, S., Seaton, D., Mullaney, T., Waldo, J., Chuang, I., 2014. Person-Course De-identification Process, HarvardX and MITx: The first year of open online courses (HarvardX and MITx Working Paper No. 1).
- İstanbul Arel Üniversitesi (2022). Uzaktan eğitim el kitabı. Eriřim adresi: (02 Mayıs 2023) <https://areluzem.arel.edu.tr/wp-content/uploads/2022/09/Uzaktan-Egitim-El-Kitabi.pdf>
- İřman, A. (2011). Uzaktan Eğitim, Ankara, Pegem Akademi, 4. bs.
- Keller, J. M., Gray, M. R. ve Givens, J. A. (1985). A fuzzy k-nearest neighbor algorithm. *IEEE Transactions on Systems, Man, and Cybernetics*, 15, 580-585. Eriřim adresi: <https://doi.org/10.1109/TSMC.1985.6313426>
- Kliksoft. Moodle öğrenim yönetim sistemi. Eriřim adresi: (4 Nisan 2023) <https://www.kliksoft.net/moodle-lms/>
- Koyuncu, İ., Kılıç, A. F., ve Gökşun, D. O. (2022). Classification of students achievement via machine learning by using system logs in learning management system. *Turkish Online Journal of Distance Education*, 23 (3), Article 3. <https://doi.org/10.17718/tojde.1137114>
- Li, C. ve Wang, B. (2014). Fisher linear discriminant analysis. CCIS Northeastern University. https://www.ccis.northeastern.edu/home/vip/teach/MLcourse/5_features_dimensions/lecture_notes/LDA/LDA.pdf

- Lin, C. F. ve Wang, S. D. (2002). Fuzzy support vector machines. *IEEE Transactions on Neural Networks*, 13(2), 464-471. Eriřim adresi: <https://doi.org/10.1109/72.991432>
- Maji, P. K., Biswas, R. ve Roy, A. R. (2001). Fuzzy soft sets. *The Journal of Fuzzy Mathematics*, 9(3), 589-602.
- Mehryar, M., Rostamizadeh, A. ve Talwalkar, A. (2018). Foundations of machine learning (2. bs.). London: The MIT Press.
- Memiř, S. (2021). Bulanık parametrelili bulanık esnek matrislerin makine öğrenimine uygulamaları (Yayımlanmamıř doktora tezi). Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, Türkiye.
- Memiř, S., Arslan, B., Aydın, T., Enginođlu, S. ve Camcı, Ç. (2021) A classification method based on Hamming pseudo-similarity of intuitionistic fuzzy parameterized intuitionistic fuzzy soft matrices, *Journal of New Results in Science*, 10(2), 59–76
- Memiř, S., Arslan, B., Aydın, T., Enginođlu, S. ve Camcı, Ç. (2023) Distance and Similarity Measures of Intuitionistic Fuzzy Parameterized Intuitionistic Fuzzy Soft Matrices and Their Applications to Data Classification in Supervised Learning, *Axioms*, 12, 463. <https://doi.org/10.3390/axioms12050463>
- Memiř S., Enginođlu, S. ve Erkan, U. (2021) Numerical data classification via distance-based similarity measures of fuzzy parameterized fuzzy soft matrices. *IEEE Access*, 9, 88583–88601.
- Memiř, S., Enginođlu, S., ve Erkan, U. (2022a). A classification method in machine learning based on soft decision-making via fuzzy parameterized fuzzy soft matrices. *Soft Computing*, 26(3), 1165-1180. <https://doi.org/10.1007/s00500-021-06553-z>
- Memiř S., Enginođlu, S. ve Erkan, U. (2022b) A new classification method using soft decision-making based on an aggregation operator of fuzzy parameterized fuzzy soft matrices. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(3), 871–890.
- Memiř S., Enginođlu, S. ve Erkan, U. (2022c) Fuzzy parameterized fuzzy soft k-nearest neighbor classifier. *Neurocomputing*, 500, 351–378. Eriřim adresi: <https://doi.org/10.1016/j.neucom.2022.05.041>
- Minaei-Bidgoli, B., Kashy, D. A., Kortemeyer, G., ve Punch, W. F. (2003). Predicting student performance: An application of data mining methods with an educational Web-based system. *33rd Annual Frontiers in Education*, 2003. FIE 2003., 1, T2A-13. <https://doi.org/10.1109/FIE.2003.1263284>

- Molodtsov, D. (1999). Soft set theory-first results. *Computers and Mathematics with Applications*, 37(4-5), 19-31. Eriřim adresi: [https://doi.org/10.1016/S0898-1221\(99\)00056-5](https://doi.org/10.1016/S0898-1221(99)00056-5)
- Moussawi, A., Ibrahim, P., Said, B., ve Mershad, K. (2020). Using Machine Learning to Enhance “Students’ Assessment” Moodle Application.
- Moodle. (t.y.). The Moodle Story-Moodle-Online Education For Everyone. Eriřim adresi: (24 Nisan 2023) <https://moodle.com/about/the-moodle-story/>
- Odabař, H. (2003). İnternet tabanlı uzaktan eęitim ve bilgi ve belge ynetimi. *Trk Ktphanecilięi*, 17 (1), s 24. Eriřim adresi: (27 Nisan 2023) <http://tk.org.tr/index.php/TK/article/view/167/162>
- Russell, S. ve Norvig, P. (2020). Artificial intelligence: A modern approach (4. bs.). Hoboken: Pearson.
- řapcı, B., Pektař, ř. T. (2021). Makine ęrenmesi Aracılıęı ile Kullanıcı Deneyimi Bilgilerinin Erken Mimari Tasarım Sreçleriyle Btnleřtirilmesi. *Journal of Computational Design*, 2(1), 67-94.
- Tosunoęlu, E., Yılmaz, R., zeren, E., ve Saęlam, Z. (2021). Eęitimde makine ęrenmesi: Arařtırmalardaki gncel eęilimler zerine inceleme. *Ahmet Keleřoęlu Eęitim Fakltesi Dergisi*, 3(2), 178-199.
- Uluę, F. Ve Kaya, Z. (1997) Uzaktan Eęitim Yaklařımıyla İlkęretim. Ankara. Uzaktan Eęitim Vakfı. 3r5.
- Yıldız, O. (2018). Makine ęrenmesi ile uzaktan eęitim ęrencilerinin performanslarının deęerlendirilmesi (Doktora tezi). İstanbl niversitesi Fen Bilimleri Enstits. Eriřim adresi: <https://acikbilim.yok.gov.tr/handle/20.500.12812/149715>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8, 338-353. Eriřim adresi: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)