

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**ÖĞRENCİLERİN ÇEVİRİMİÇİ EĞİTİM
PLATFORMUNDAKİ ETKİLEŞİMLERİNDEN
PROFİLLERİNİN OLUŞTURULMASI**

Yüksek Lisans Tezi

Tezi Hazırlayan

Şafak SİLİK

İstanbul, 2023

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**ÖĞRENCİLERİN ÇEVİRİMİÇİ EĞİTİM
PLATFORMUNDAKİ ETKİLEŞİMLERİNDEN
PROFİLLERİNİN OLUŞTURULMASI**

Yüksek Lisans Tezi

Tezi Hazırlayan

Şafak SİLİK

Öğrenci No.

2020003039

Orcid: 0009-0002-9833-6065

Danışman:

Dr. Öğr. Üyesi Zeynep ALTAN

İstanbul, 2023

YEMİN METNİ

Yüksek Lisans Tezi olarak hazırladığım “**Öğrencilerin Çevrimiçi Eğitim Platformundaki Etkileşimlerinden Profillerinin Oluşturulması**” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullandıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. 15.09.2023

Şafak SİLİK

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ
TEZLİ YÜKSEK LİSANS SINAV TUTANAĞI

15.09/2023

Enstitümüz *Bilgisayar Mühendisliği* Anabilim Dalı *Bilgisayar Mühendisliği* Programı yüksek lisans öğrencilerinden 2020003039 numaralı *Şafak SİLİK*'in "İstanbul Beykent Üniversitesi Lisansüstü Eğitim – Öğretim Yönetmeliği"nin ilgili maddesine göre hazırlayarak, Enstitümüze teslim ettiği "*Öğrencilerin Çevrimiçi Eğitim Platformundaki Etkileşimlerinden Profillerinin Oluşturulması*" konulu tezini, Yönetim Kurulumuzun 06/06/2023 tarih ve 2023/23 sayılı toplantısında seçilen On-Line toplanan biz jüri üyeleri huzurunda, İstanbul Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 29. maddesinin 3. fıkrası gereğince 45 dakika süre ile Zoom programı aracılığıyla on-line olarak aday tarafından savunulmuş ve sonuçta adayın tezi hakkında "*OYBİRLİĞİ*" ile "*KABUL*" kararı verilmiştir.

İşbu tutanak, 2 nüsha olarak hazırlanmış ve Enstitü Müdürlüğü'ne sunulmak üzere tarafımızdan düzenlenmiştir.

DANIŞMAN
Dr. Öğr. Üyesi Ze*** AL***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ta*** Fİ***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ke*** ŞA***
(İstanbul Medipol Üniversitesi)

Adı ve Soyadı : Şafak SİLİK
Danışmanı : Dr. Öğr. Üyesi Zeynep ALTAN
Türü ve Tarihi : Yüksek Lisans Tezi, 2023
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Makine Öğrenimi, Kümeleme, K-Means, Python, Elbow

ÖZ

ÖĞRENCİLERİN ÇEVİRİMİÇİ EĞİTİM PLATFORMUNDAKİ ETKİLEŞİMLERİNDEN PROFİLLERİNİN OLUŞTURULMASI

Çevrimiçi eğitim platformlarında sistemi kullanma şekillerine göre farklı profillerde öğrenciler bulunmaktadır; bazı profiller öğrencilerin yönelimlerine katkı sunmaktadır. Bu tezin amacı, bu profilleri doğru bir şekilde erkenden tahmin edip, öğrencilere kişileştirilmiş destek vermek ve yönlendirme yapmaktır. Bu konu çocukların gelişiminde çok önemli olduğu için öğrencilerinin kullanmış oldukları eğitim platformlarında, çocukların sistem etkileşimlerinden makine öğrenmesi yardımı ile kümeler oluşturulmuştur.

Özel çevrimiçi eğitim platformu üzerinden alınan 82.189 adet öğrenci hareketlerinden her sınıf için farklı kümeler oluşturulmuştur. Çıkan kümeler incelendiğinde 10 farklı profil çıkarımı yapılmıştır. Yazılım dili olarak Python kullanılmıştır.

Name and Surname : Şafak SİLİK
Supervisor : Asst. Prof. Zeynep ALTAN
Degree and Date : Master's Thesis, 2023
Major : Computer Engineering
Key Words : Machine Learning, Clustering, K-Means, Python,
Elbow

ABSTRACT

CREATING PROFILES OF STUDENTS FROM THEIR INTERACTIONS ON THE ONLINE EDUCATION PLATFORM

Online education platforms have different profiles of students according to the way they use the system; some profiles contribute to the orientation of students. The aim of this thesis is to accurately predict these profiles early on and provide personalized support and guidance to students. Since this issue is very important in the development of children, clusters were created with the help of machine learning from the system interactions of children on the educational platforms used by their students.

Different clusters were created for each class from 82,189 student movements taken from a special online education platform. When the clusters were analyzed, 10 different profiles were extracted. Python was used as the software language.

İÇİNDEKİLER

Sayfa No.

ÖZ	
ABSTRACT	
TABLolar LİSTESİ	iii
ŞEKİLLER LİSTESİ	iv
KISALTMALAR	v
SÖZLÜK	vi
GİRİŞ	1

BİRİNCİ BÖLÜM

LİTARATÜR TARAMASI

1. LİTARATÜR TARAMASI	3
------------------------------------	----------

İKİNCİ BÖLÜM

ÇALIŞMAYLA İLGİLİ TEMEL BİLGİLER

1. VERİ KAVRAMI	7
2. ZEKA	8
2.1. Yapay Zeka	9
2.2. Eğitimde Yapay Zeka	9
3. MAKİNE ÖĞRENMESİ	10
3.1. Denetimli Öğrenme	11
3.2. Pekiştirmeli Öğrenme	12
3.3. Denetimsiz Öğrenme	12
4. DENETİMSİZ ÖĞRENME TEKNİKLERİ	13
4.1 Kümeleme.....	13
4.2. K-means	13
4.3. Elbow ve Doğrulama Metodları	14
4.3.1. Silhoute Score	15
4.3.2. Davies-Bouldin İndeksi.....	15
4.3.3. Calinski-Harabasz İndeksi	16
4.4. Veri Düzenleme	16
4.4.1. Ki-Kare Testi.....	16
4.4.2. Aritmatik Ortalama	17

ÜÇÜNCÜ BÖLÜM SİSTEM TASARIMI

1. EĞİTİM PLATFORMU	18
2. PLATFORMDA KULLANILAN MAKİNE ÖĞRENME TEKNOLOJİLERİ	20
2.1. Pandas	20
2.2. Numpy	20
2.3. Anaconda	21
3. SİSTEMİN MİMARİSİ	21
4. UYGULAMADA KULLANILAN VERİLER	22

DÖRDÜNCÜ BÖLÜM

UYGULAMA VE SONUÇLARIN DEĞERLENDİRMESİ

1. VERİ TEMİZLEME	25
2. VERİ İŞLEME.....	25
3. ÇIKTILARIN DEĞERLENDİRİLMESİ.....	26
3.1. Profillerin Etiketleri	27
3.1.1. Döngüsel Geleneksel Öğrenenler.....	28
3.1.2. Doğrusal Teoriden Uygulamaya Öğrenenler	29
3.1.3. Yinelemeli Ustalık Sınavına Girenler	30
3.1.4. Sistem Ustası.....	30
3.1.5. Usta Oyuncular	31
3.1.6. Pratik Odaklı Sınav Katılımcıları.....	31
3.1.7. Teoriden Pratiğe Geçen Gözden Geçirenler (Teoriden Pratiğe Yorumcular)(Pratik Gözden Geçirenler).....	31
3.1.8. Oyun Odaklı Sınav Katılımcıları	32
3.1.9. Doğrusal Oyuna Öncelik Veren Öğrenciler (Oyunu İlk Gözden Geçirenler).....	32
3.1.10. Doğrusal Uygulama Öncelikli Sınava Girenler (Pratik Öncelikli Sınava Girenler)	33
SONUÇ VE ÖNERİLER.....	34
KAYNAKÇA.....	36

TABLolar LİSTESİ

Sayfa No.

Tablo 1: Veri Seti Özellikleri Tablosu.....	24
Tablo 2: Küme Doğruluk Sonuçları Tablosu.....	27
Tablo 3: Sınıf Dağılım Tablosu	28



ŞEKİLLER LİSTESİ

Sayfa No.

Şekil 1: Veri ve Beyin	8
Şekil 2 : Pekiştirmeli Öğrenme Akış	12
Şekil 3 : Elbow Grafiği Örnek.....	14
Şekil 4 : Ders İçe Örnek Resimler.....	19
Şekil 5: Sistem İçindeki Materyal Ekranı.....	19
Şekil 6: Sistem İçindeki Rapor Ekranı	20
Şekil 7: Sistem Akış Şeması.....	22
Şekil 8: Hafta İçi Ve Hafta Sonu Öğrenci Devamlığı Grafiği	23
Şekil 9: Elbow Çıktı Grafikleri	26
Şekil 10: Profillerin Etiketlenmesi	27

KISALTMALAR

DÖ	:	Derin Öğrenme
K-Means	:	K-ortalamalar
Mlib	:	Makine Öğrenimi Kütüphanesi
MÖ	:	Makine Öğrenimi
YSA	:	Yapay Sinir Ağları
YZ	:	Yapay Zeka



SÖZLÜK

Algoritma: Bir problemin çözümünü veya belirli bir hedefe ulaşmayı sağlayan yönergelerin sıralı bir listesi olarak tanımlanır. Bu matematik ve bilgisayar bilimlerinde kullanılan bir kavramdır. Başlangıçtan sona belirli adımları takip ederek, tanımlanmış bir sonuca ulaşmayı amaçlar

Elbow Yöntemi: Elbow yöntemi, K-means gibi kümeleme algoritmalarında doğru küme sayısını belirlemek için kullanılan bir tekniktir. Farklı küme sayıları için modelin hatasını (inertia) grafikte gösterir ve dirseğin olduğu noktada optimal küme sayısını belirlemeye çalışır.

K-Means: K-Means, bir veri kümesini belirli sayıda küme veya grup halinde kümelemek için kullanılan bir makine öğrenme algoritmasıdır.

Makine Öğrenimi: Makine öğrenimi, yazılım programlarının veri analizi ve öğrenme yoluyla sonuçları tahmin etmesine olanak tanıyan bir algoritma türüdür. Bu, belirli bir problemi çözmek için önceden açıkça programlanmak yerine, verilere dayalı örüntüleri tanımak ve öğrenmek için kullanılır.

Sistem Mimarisi: Sistem mimarisi, bir bilgisayar veya yazılım sisteminin bileşenlerinin, yapılarının ve ilişkilerinin tasarımını ve organizasyonunu tanımlayan bir kavramdır. Bu, bir sistemi nasıl işlediğini, bileşenlerin nasıl etkileşimde bulunduğunu ve sistem gereksinimlerini anlamak için kullanılır.

Tekrarlama (İterasyon): İterasyon, bir işlemi sürekli olarak tekrar etme anlamına gelir. Programlama bağlamında, döngüler kullanarak belirli bir işlemi yineleyen bir işlem dizisini ifade eder. Bu, belirli koşullar sağlandığında veya belirli bir süre boyunca işlemi tekrarlamak için kullanılır.

Yapay Zeka: Yapay zeka, bir dizi yazılım ve donanım sistemini içeren bir kavramdır. Bu sistemler, insan davranışını taklit etme yeteneği, sayıları anlama, hareket etme yeteneği, dil işleme ve ses algısı gibi birçok özelliklerle karakterize edilir. Yapay zeka, karmaşık görevleri gerçekleştirmek, özerk kararlar almak ve büyük veri kümelerini analiz etmek gibi birçok uygulama alanında kullanılır.

GİRİŞ

Makinelere belirli bir deneyim kazandırmak için verilere ihtiyaç duyulur. Deneyim ve bilgi, veri kümeleri aracılığıyla makinelerin anlayabileceği bir formata dönüştürülür. Veri olmadan, yapay zeka (YZ) ve makine öğrenimi adım atamaz. YZ, insan benzeri mantıklı davranışları modellemeyi hedefler ve karmaşıklığıyla tanınan insan zekasını makinelere aktarmaya çalışır. Makine Öğrenmesi(MÖ)'nin, çeşitli sektörlerde ve uygulamalarda büyük bir rol oynayabilir.

Herhangi bir makinenin belirli bir yetiğe sahip olabilmesi için, çeşitli verilere ihtiyaç vardır. Bu veriler, deneyimleri ve bilgiyi içeren veri kümeleri şeklinde toplanır ve ardından makineye aktarılır. Veriler olmadan, YZ ve MÖ yöntemleri düşünülemez bir hâle gelir. YZ, her türlü mantıklı davranışı doğadan öğrenmeyi amaçlar. Aynı zamanda, insan zekasının problem çözme yeteneklerini taklit etmeye ve insan beyninin karmaşık yapısını makinelerle uyumlu hâle getirmeye çalışır. Makine öğrenimi ise birçok sektörde ve endüstride kullanım alanı bulabilir.

Baysal ve ark. göre 21. yüzyılda, toplumların eğitim ihtiyaçları, hızlı gelişmelere paralel olarak artmış ve ülkeler daha fazla okul açma, öğretmen yetiştirme, eğitim kurumlarını verimli kullanma ve öğrenim süresini uzatma gibi çeşitli önlemler almıştır. Ekonomik zorluklar, nüfus artışı ve teknolojik ilerlemeler, geleneksel eğitim yöntemlerinin eğitim ihtiyaçlarını karşılama konusunda zorluklar yaşamasına neden olmuştur. Bu nedenle, ülkeler nitelikli, ekonomik ve yaygın eğitim sağlama yollarını aramış, bu bağlamda uzaktan eğitim yaklaşımını geliştirmişlerdir. Özellikle COVID-19 salgını, acil uzaktan eğitim anlayışının hızla benimsenmesine yol açmıştır, bu da salgın sırasında eğitimdeki aksamaları hızlı bir şekilde ele almaları gerektirir.

Azcona ve ark. göre çevrimiçi öğrenme ortamlarının kullanımı pandeminin etkisi ile artmaktadır. Bu artış ile sistemlerde öğrencilerin yapmış oldukları hareket kayıtları da artmıştır. Bu verilerden öğrencilerin yapmış oldukları alışkanlık ve öğrenim çeşitleri görülmektedir. Çevrimiçi öğrenme ortamlarında öğrencilerin gerçekleştirdiği her türlü etkileşim ve hareket, dijital iz olarak kaydedilir ve bu izler, öğrenme sürecine dair önemli veriyi oluşturur.

Çalışmanın bu bölümünde çalışma hakkında genel bilgiler verilmektedir. Bölüm 1'de bu konuda literatürdeki benzer çalışmalardan bahsedilmektedir. Bölüm 2'de çalışmayla ilgili temel bilgiler içermektedir. Bölüm 3, sistem tasarımı hakkında bilgiler içermektedir. Bölüm 4'de uygulama ve sonuçların değerlendirilmesi yapılmıştır.



BİRİNCİ BÖLÜM

LİTARATÜR TARAMASI

1. LİTARATÜR TARAMASI

Bu tez için literatür gözden geçirildiğinde, online eğitim platformu üzerindeki öğrencilerin sistem hareket/işlemleri üzerinden profil oluşturulması ve yeni öğrenci profillerinin tahmin edilmesi alanında araştırmaların çeşitli metotlar ve türlü uygulamalar kullanılarak yürütüldüğü tespit edilmiştir. Bu tezde makine öğrenmesi ile öğrencilerin sistem hareketlerinden profillerinin tespit edilmesi öğrencilerin etiketlerinin oluşturulup, derslerinde daha başarılı ve zaman kullanımını daha iyi hale getirilmeye çalışılmıştır. Makine öğrenmesinin öğrenci profillemesinde kullanıldığı görülmüştür. K-Means kümeleme algoritması kümeleri başarılı bir kümeleme işlemine tutmuştur.

Talib ve arkadaşlarının yürütmüş oldukları Malezya'daki Yükseköğretim kurumlarında HEI (Higher Education Institutions) öğrencileri izlemek ve başarılarını takip etmenin akademideki kaliteyi arttırmak için önemli olduğunu belirtmişlerdir. Bu amaçla Malezya Ulusal Üniversitesi Teknoloji ve Bilişim Fakültesi'nden (Faculty of Technology and Information Science, The National University of Malaysia) aldıkları verileri inceleyerek Elbow metodu ile 3 kümenin ideal küme olduğu belirlenmiştir. K-Means ile kümeler oluşturulmuştur. Kümeleri Düşük, ortalama ve yüksek performans olarak etiketlemişlerdir (Talib, Majid, Sahran 2023).

Alawi, Shahrane ve Jamil'in yürütmüş oldukları çalışmada Umman Eğitim Portalı üzerindeki öğrencilerin performanslarını incelemişlerdir. İncelemelerde 49588 öğrenci bulunmaktadır. 4 farklı profil tespit edilmiştir. Bunlar "mükemmel", "iyi", "ortalama", "başarısız" olmaktadır. Çalışma sonuçlarının da umman eğitim bakanlığının düşük performans eğilimi gösteren öğrencileri bulup onları yönlendirme ve müfredat düzenlemelerine yardımcı olabileceği söylenmektedir (Alawi ve ark. 2023).

Kim ve arkadaşlarını Kore Cumhuriyetinde Kyung Hee Üniversitesinde 2021 döneminde çevrimiçi kursa kaydolmuş öğrenciler üzerinde yaptıkları çalışmada K-Means algoritması kullanılıp, K değerini silhouette skoru ile ölçerek 2 sonucunu

bulmuşlardır. Öğrencilerin 2 profili tespit edilmiştir. Yüksek ve düşük bağıllık olarak isimlendirmişlerdir. Verilerin çok olmaması araştırma için yeterli kanıt olmadığı görülmüştür. 2 profilin incelendiğinde düşük katılım oranı olan öğrencilerin çeşitli ders sevdirci stratejiler yürütmesi gerek olduğunu tavsiye edilmiştir (Sohee Kim ve ark. 2023).

Andreswari ve arkadaşlarının yürütmüş oldukları çalışmada "Öğrenmeye Özgürlük" programındaki öğrencilerin demografik verileri kullanılmıştır. Öğrenmeye Özgürlük programının amacı öğrencilerin tutkuları ve yeteneklerinin peşinden gitmelerine yardımcı olmaktır. Kayıtlı öğrencilerin demografik bilgileri alınıp hazırlama, ön işleme, veri temizliği ve veri analizi yapmıştır. Kümeleme işleminde K-Means kullanılmıştır. Küme sayısının belirlenmesi için Elbow metodu kullanılmış ve 3 tane küme olduğu tespit edilmiştir. K-Means ile 3 kümeye bölünmüştür. Kümeler incelendiğinde de öğrencilerin üniversite sonrası kariyer yönelimini değerli bir yardımcı olduğu görülmektedir (Andreswari ve ark. 2022).

Liu ve arkadaşlarının yapmış oldukları öğrencilerin anksiyete bozukluklarını profillemeyi denemişler ve Kmeans algoritması ile 3 farklı profil belirlemişlerdir. Belirlenen öğrencilere farklı kategorize edilerek farklı stratejilerde destek olunması sağlanmasını önermişlerdir (Liu ve ark. 2022).

Covid-19 pandemisi ile değişen eğitim sisteminde çevrimiçi eğitim sisteminin çevrimdışı eğitim sistemine göre daha az tercih edildiğini savunan Sari ve ark. öğrencileri puan sistemine göre profillemişlerdir. Kümeleme için K-Means ve C-Ortalamalardan yararlanmışlardır. Araştırma sonucunda 3 farklı küme bulmuşlardır. Sınıfların performansları kıyaslamışlardır. Sınıfların başarı durumlarını bulmuşlardır (Sari ve ark. 2021).

Moubayed, Injadat, Shami ve Lutfiyya yapmış oldukları çalışmada çevrimiçi öğrenme sistemlerindeki öğrencilerin karşılaştıkları zorlukları (motivasyon ve katılım) engellemek bu çalışmayı yapmışlardır. Çalışmada kmeans algoritması kullanılmış ve siluet skorundan destek alınmıştır. 3 farklı küme tespit edilmiştir. Kümeleri incelendiğinde platform içeriğini değiştirmek veya çevrimiçi öğrencilerin tercihlerine göre ekstra materyal sağlamak onları daha fazla meşgul etmek için kullanılabilir olduğunu vurgulamışlardır (Moubayed ve ark. 2020).

Çinde 4 farklı üniversiteden Dijital kampüs verileri ile yapılan çalışmada K-Means kümeleme algoritmasını kullanılmıştır. Kümeleme analizi sonucunda yaşam alışkanlık ile öğrenme performanslarının farklı olduğu belirtilmiştir. Bu araştırma ile üniversitelerin, öğrencilerin davranışları ile hakkında bilgi edinip sistem kişiselleştirme hizmeti sağlanabileceği sonucuna varmıştır (Chang ve ark. 2020).

Öğrencileri çevrimiçi öğrenme davranışlarına göre kümeleme fikrinin öğretmenlere ve öğrencilere daha uyarlanabilir bir sistem potansiyeline sahiptir. ACware Tutor'da öğrenci gruplarını belirlemek amacıyla 8 farklı değişken belirleyerek öğrencileri kümeleme yapmaya çalışmıştır. Elbow ile yapılan çalışmada $k=4$ olduğu belirlenmiştir. Kmeans ile veriyi 4 kümeye bölümlenmiştir. 4 farklı profilin olduğu tespit edilmiştir. Kümelerin daha anlaşılır olması için karar ağacı kullanılmıştır (Grubisic ve ark. 2020).

Eryılmaz'ın yapmış olduğu çalışmada, Atılım Üniversitesinin kullanmış olduğu sanal öğrenme ortamı olan Moodle üzerinde 131 öğrencinin ortam kullanma bilgileri alınarak kümeleme analizi yapılmıştır. Kümeleme analizinde kmeans kullanılmıştır. Yapılan analiz sonucunda memnuniyet, kaygı ve akademik başarı puanları olarak 3 profil elde edilmiştir. Profillerde tespit edilen sistem kullanımlara dikkat edilerek öğrencilerin akademik başarısında ve memnuniyetinde etkili olacağını belirtilmiştir. Çeşitli bağımlı değişkenlerle yapılan yeni deneyler, farklı sonuçlar elde etmeyi mümkün kılacağını önermiştir (Eryılmaz 2019).

Üniversitenin başarısı öğrencilerin performansının yüksekliği ve düşüklüğü yansıtabilir. Başarısız öğrenciler okulu bırakma eğilimine girebilmektedir. Bu araştırma da K-Means ile problemi çözmeye çalışılmıştır. Yapılan çalışmada 3 tane küme bulunmuştur. Okulu bırakma potansiyeli olan, okulu bırakma ihtimali olan ve okulu bırakma ihtimali olmayan öğrencilerdir (Purba ve ark. 2018).

Çevrimiçi öğrenme ortamındaki öğrencilerin profillerinin kümelenmesi çalışmasında Türkiye'de bir devlet üniversitesinin verileri incelenmiştir. Kümeleme için K-means algoritması kullanılmıştır. Öğrenciler, aktivite düzeylerine göre (Çok aktif, Aktif, Aktif olmayan) ve akademik performanslarına göre (Yüksek öğrenenler, Orta öğrenenler, Düşük öğrenenler) farklı kümelere sınıflandırılmıştır (Akçapınar ve ark. 2016).

Yükseköğretim kurumlarının doğru kararlar alması ve eğitim kalitesini artırması için veri madenciliği yöntemlerinin kullanılması incelenmiştir. Fırat Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü öğrencilerinin mezuniyet notlarının tahmin edilmesi amacıyla Yapay Sinir Ağları (YSA) ve Karar Ağaçları kullanılmıştır. 127 öğrencinin dört yıl süresince aldığı ders notları kullanılarak mezuniyet notu tahminleri yapılmıştır. İki farklı senaryoda, öğrencilerin sadece ilk iki sınıf notları veya ilk üç sınıf notları ile mezuniyet notları tahmin edilmiştir. Yapılan benzetim çalışmalarında YSA'nın daha iyi tahmin başarısı gösterdiği ve ikinci senaryonun daha iyi tahminler sağladığı tespit edilmiştir (Şengür 2013).

Kurt ve Erdem'e göre mezuniyet sonrası bölümle ilgili bir işte çalışıp çalışmama ihtimalinin başarıyı ciddi şekilde etkilediği görülmüştür. Araştırmacı kişiliğin başarı üzerine büyük bir etkisi olduğu gözlenmiştir. Bu nedenle uygun konu, faaliyet, proje ve etkinliklerle öğrencilerin araştırmacı niteliklerinin geliştirilmesine çalışılabilir. Başarısızlığa etki eden faktörlerin başında istemediği bölümde okumak gelmektedir; bu bağlamda liselerde üniversite, bölüm, dal tercihleri yapılırken rehberlik ve yönlendirme faaliyetleri gözden geçirilebilir. Öğrencilerin lise mezuniyet ortalamaları ile lisans ortalamaları arasında ilişki bulunmuştur. Bu da üniversitelerde başarının artırılabilmesi için lisedeki verimin artırılması gerektiğini göstermektedir. Cinsiyetin başarı üzerinde etkin olarak belirleyici bir etkisi saptanmamıştır (Kurt ve Erdem 2012).

İKİNCİ BÖLÜM

ÇALIŞMAYLA İLGİLİ TEMEL BİLGİLER

1. VERİ KAVRAMI

Veri, “tek başına anlam ifade etmeyen veya kullanılmayan, bununla birlikte enformasyona ve bilgiye temel oluşturan ilişkilendirilmeye, gruplandırılmaya, yorumlanmaya, anlamlandırılmaya ve analiz edilmeye gereksinim duyulan ham bilgi” (Yılmaz 1998) olarak tanımlamıştır.

1997 yılında düzenlenen 8. IEEE Görüntüleme Konferansı'nda Michael Cox ve David Ellsworth tarafından "Application-Controlled Demand Paging for Out-of-core Visualization" adlı makalede, veri setlerinin büyüklüğü ve bilgisayar sistemlerinin bellek, disk ve harici depolama birimlerinin dolduğu sorunlarından bahsedilerek "Büyük Veri Problemi" adı verilen bir kavram ortaya konulmuştur. Francis X. Diebold daha sonraki çalışmalarında, fizik, biyoloji ve sosyal bilimler gibi birçok alanda karşılaşılan büyük veri fenomeninin önemine vurgu yaparak, veriye "çağımızın ham maddesi" denildiğini ifade etmiştir. Bu gerçek, büyük bilişim şirketlerinin de kuruluş felsefelerinde temel bir rol oynamaktadır. Büyük veri kavramı, farklı hacimlerdeki heterojen veriyi tanımlayan ve geleneksel veri tabanı teknikleriyle işlenemeyen yeni bir kavramdır. Bu kavram, çeşitli dijital içeriklerden oluşmaktadır (Aktan 2018).

2.1. Yapay Zeka

Yapay zeka bağımsız makineler -bu makineler insan olmaksızın kompleks işler yapabilir- inşa etmek için araştırma yapan bilişsel bilim dalıdır. Bu hedef makinelerin düşünmesini ve anlamasını gerektirir (Pirim, 2006: 81-93).

Edward Fredkin, MIT Bilgisayar Bilimleri laboratuvar yöneticisi olarak, yaptığı bir BBC söyleşisinde "Tarihin üç büyük olayı vardır: kainatın oluşumu, yaşamın başlangıcı ve yapay zeka." ifadesini kullanmıştır. Bu ifade, Fredkin'in yapay zekanın insanlık için ne kadar önemli bir keşif olduğuna inandığını ve insanlık tarihindeki önemli dönüm noktalarından biri olduğunu düşündüğünü yansıtmaktadır (Pirim 2006).

Yapay zeka (YZ), bilgisayarların ve makinelerin insan düşünce ve davranışlarını taklit etmesi anlamına gelir. YZ, insan zekasıyla ilişkilendirilen problem çözme ve örüntü tanıma gibi bilişsel görevleri yerine getirerek, sonrasında da bu görevleri uyarlamayı amaçlamaktadır. MÖ gibi gelişmiş analitik yöntemlerini kullanarak, yapay zeka olayları anlama, kararları destekleme, otomatikleştirme ve harekete geçirme gibi işlevleri gerçekleştirmektedir. YZ, bilgisayar görüşü, doğal dil işleme, robotik ve bilgi temsili gibi farklı disiplinleri içeren bir alan olarak tanımlanabilir (Öztürk 2022).

2.2. Eğitimde Yapay Zeka

Sidney L. Pressey'in 1920'lerde yapmış olduğu çalışma, çoktan seçmeli testlerin öğrencilerin başarısını değerlendirmenin yanı sıra öğrenmelerini pekiştirmek için de kullanılabileceğini ortaya koymuştur. Edward Thorndike'nin etki kanununa dayanarak, test sonuçlarının öğrencilere derhal geribildirim olarak sunulması ve doğru cevap konusunda yönlendirme yapılması gerektiği savunulmuştur. Pressey, bu geri bildirim işlevini yapacak "makinelerden" bahsetmiştir ve bu fikirleri yapay zekanın ilk uygulama örnekleri arasında sayılmıştır. Bunun yanı sıra, Pressey yapay zekanın eğitimde kullanım alanlarından biri olan eğitimin yönetimi konusuna da değinerek, böyle bir makinanın sadece öğrencilerin öğrenmelerine destek sağlamayacağını ayrıca öğretmenlerin yüklerini de azaltacağını belirtmiştir. Testlerin değerlendirmesine daha az zaman ayıran öğretmen, öğrencileriyle de daha fazla

zaman geirme ansı bulacaktır. Bununla birlikte, B.F. Skinner'ın programlı retim ve retme makineleri gibi nc alıřmaları da yapay zekanın eđitimdeki kullanımına nclk etmiřtir. Skinner, 1958 yılında basit bir algoritmaya sahip retme makinelerini geliřtirmiř ve kiřiselleřtirilmiř renmenin temellerini atarak gnmzdeki "akıllı retim sistemlerinin yolunu amıřtır (Arslan 2020).

3. MAKİNE RENMESİ

Makine renimi, bilgisayar algoritmalarıyla bir problemin veriye dayalı olarak modellenmesi iřlemidir. Veri seti ve kullanılan algoritma ile oluřturulan model, en yksek performansı sađlamak zere tasarlanır. Bu nedenle, birok farklı makine renimi yntemi geliřtirilmiřtir. Bunlar arasında k-en yakın komřu, basit Bayes sınıflandırıcı, karar ađaları, lojistik regresyon analizi, k-ortalamlar algoritması, destek vektr makinaları ve yapay sinir ađları bulunur. Bu yaklařımların bir kısmı tahmin ve kestirim, bir kısmı kmeleme ve bir kısmı da sınıflandırma yapabilme yeteneđine sahiptir. Makine reniminde kullanılan renme stratejileri, denetimli, denetimsiz ve pekiřtirmeli olarak sınıflandırılır. Denetimli renmede, modelin bir girdi deđer iin hedef deđerler verilerek aralarındaki iliřki renilir ve en yakın ıktılar retilir. Denetimsiz renmede ise hedef deđerleri olmadan sadece girdi deđerleri arasındaki iliřki ortaya ıkarılmaya alıřılır. Pekiřtirmeli renmede ise, elde edilen ıkıřın verilen giriře karřılık iyi ya da kt olarak deđerlendirilmesi esas alınır (Atalay, elik 2022).

M, bilgisayar sistemlerinin verilerdeki kalıpları belirlemek iin kullandıđı bir sretir ve YZ elde etmek iin nemli bir aratır. M algoritmaları, veri alt kmeleri zerinde eđitilir ve bu verilerin analizi sonucu oluřan kalıplar, bir veri modeli oluřturulmasına yardımcı olur. Modelin dođru bir řekilde eđitilmesi, makine renmesi modelinin grevini hızlı ve dođru bir řekilde yerine getirmesi iin nemlidir. Dar YZ, iyi eđitilmiř bir makine renmesi modeliyle elde edilebilir ve faydalı ve gvenilir sonular sađlar (Microsoft 2023).

M, bilgisayarlara veri setleri zerinden renme ve ıkarım yapabilme yeteneđi kazandıran bir yapay zeka dalıdır. Bu yntem, programcıların bilgisayarın

her adımını önceden belirlemek yerine, bir problemi çözmek için veri setlerini analiz etmesine izin verir. Bu veriler, algoritmaların öğrenmesi için kullanılır ve böylece gelecekte benzer sorunlarla karşılaştığında çözümler üretebilirler (Gürsakal 2017). MÖ, finans, sağlık, ticaret, ulaşım ve daha birçok alanda kullanılmaktadır. Veri kaynakları arasında sensörler, kameralar, kullanıcı etkileşimleri ve daha fazlası yer alabilir.

MÖ, bilgisayarların bir dizi veri üzerinden öğrenme yaparak, gelecekteki benzer durumlarda tahminlerde bulunmalarını sağlayan bir alandır. Bu süreç, veri analizi, model oluşturma ve modeli kullanarak tahmin adımlarının tekrarlanması yoluyla gerçekleştirilir. Örneğin, bir fotoğraf tanıma yazılımı, binlerce fotoğrafı analiz ederek öğrenebilir ve gelecekteki fotoğrafları tanımlamak için bu öğrenmeyi kullanabilir. Makine öğrenmesi, otomatik öğrenme ve keşif yapabilen bir sistem oluşturmak için kullanılır (Arslan 2020).

MÖ üç başlıkta incelenmektedir. Bunlar Denetimsiz öğrenme, Denetimli Öğrenme ve Pekiştirmeli Öğrenmedir.

3.1. Denetimli Öğrenme

Denetimli öğrenme, girdi verilerine ek olarak etiketli çıktı verilerinin de yer aldığı bir eğitim veri kümesi kullanarak ML modelini eğitmek için kullanılan bir yöntemdir. Bu etiketli veriler, örneğin kullanıcı sayısı gibi sayısal bir değer olabileceği gibi, olumlu kullanıcı yorumları gibi kategorik bir sınıflandırma da olabilir. Eğitim veri setindeki bu veri çiftleri daha sonra modelin parametrelerini kalibre etmek için kullanılır ve model başarıyla eğitildikten sonra, yeni veya görünmeyen girdi verileri kullanılarak çıktı tahmin edilebilir. Denetimli öğrenme, regresyon problemleri ve sınıflandırma problemleri arasında ayırım yapılabilir (Janiesch 2020).

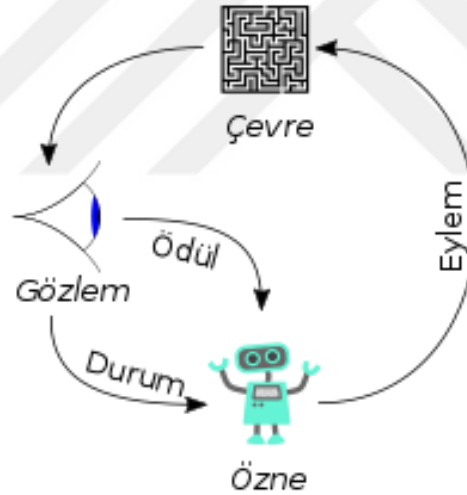
Denetimli öğrenme, eğitim verileri kullanılarak bir model oluşturma sürecidir. Bu süreçte, veriler önceden etiketlenir ve bir algoritma, bu etiketlerden yararlanarak öğrenir ve test verileri üzerinde denetlenir. Tahmin ve sınıflandırma problemleri denetimli öğrenmenin odak noktasıdır. Regresyon, nicel değişkenlerin

tahmin edilmesi için kullanılırken, sınıflandırma, nitel deęişkenlerin sınıflandırılması için kullanılır (Akay 2018).

3.2. Pekiřtirmeli Öğrenme

Takviyeli öğrenme, makine öğrenimi modelinin, belirli bir görev için girdi ve çıktı çiftleri vermek yerine, sistem için bir hedef belirleyerek ve erişebileceęi eylemler listesini ve çevresel kısıtlamaları tanımlayarak ödülü maksimize etmek için deneme-yanılma yöntemini kullanmasına izin verir. Bu yaklaşım, oyunlar gibi kapalı sistemlerde olduęu kadar, elektronik pazarlar gibi açık sistemlerde de kullanılabilir. Bu sayede, güçlendirilmiş öğrenme modelleri birçok alanda başarılı bir şekilde uygulanabilir (Janiesch ve ark. 2020).

Şekil 2’de pekiřtirmeli öğrenme akış sistemi gösterilmektedir.



Şekil 2 : Pekiřtirmeli Öğrenme Akış

3.3. Denetimsiz Öğrenme

Denetimsiz öğrenme, verilerin etiketlenmemiş olması durumunda kullanılan bir öğrenme yöntemidir. Bu yöntemde, verilerin yapısını anlamak için benzer özelliklere sahip veri noktaları gruplandırılır veya veriler yüksek boyutlu bir alandan daha düşük boyutlu bir alana yansıtılır. Bu şekilde, öğrenme sistemi verilerdeki kalıpları keşfedebilir ve daha fazla bilgi edinebilir. Örneğin, elektronik pazarlarda,

müşterileri veya pazarları segmentlere ayırmak için kümeleme teknikleri kullanılarak denetimsiz öğrenme uygulanabilir. Bu yöntem, hedef kitleye özel iletişim stratejileri geliştirmek için kullanılabilir (Janiesch1 ve ark. 2020).

Denetimsiz öğrenme, veri analizi yapmak için kullanılan bir yöntemdir. Bu yöntem, verilerdeki yapıyı ve ilişkileri keşfetmek için kullanılır. Denetimsiz öğrenme teknikleri sayesinde, verilerdeki benzer örnekler arasında gruplamalar yapılabilir ve verilerin içerdiği temel yapı ve dağılım hakkında daha fazla bilgi elde edilebilir (Akay 2018).

4. DENETİMSİZ ÖĞRENME TEKNİKLERİ

4.1 Kümeleme

Birbirine benzeyen verilerin kümeler adı altında bir araya getirilip gruplanmasına verilen tekniğin adıdır. Amaç, bir küme içerisindeki verilerin birbirine benzemesi ve diğer küme içindeki verilere benzeyecek şekilde ayırmaktır (Müller, Guido 2016:162).

Veri analizi için oldukça yaygın bir teknik olan kümeleme, birçok alanda kullanılır. Bu teknik, benzer özelliklere sahip verileri gruplara ayırarak veri kümesini alt kümeler halinde düzenler. Alt kümelerin belirlenmesi, veriler arasındaki belirli bir mesafe ölçüsüne göre yapılır. Kümeleme, özellikle makine öğrenimi, veri madenciliği, örüntü tanıma, görüntü analizi ve biyoinformatik gibi alanlarda verilerin analiz edilmesine yardımcı olur (Madhulatha 2020).

4.2. K-means


Kümeleme uygulamalarında K-means algoritması, büyük veri kümeleri için en iyi performansı sağlaması nedeniyle sıklıkla kullanılan bir algoritmadır. Algoritma, başlangıçta belirlenen K noktası üzerinden çalışır ve her bir nokta bir kümeyi temsil eder. Veri kümesindeki tüm nesnelere, minimum mesafelerine göre merkezlere atanır ve tüm nesnelere tahsis edildikten sonra, merkezlerin kümeleri yeniden hesaplanır. Genellikle, mesafe hesaplamaları için Öklid mesafesi kullanılır,

ancak bu, iterasyonlar sırasında uzun sürebilir. Bu nedenle, mesafe hesaplamalarını hızlandırmak için birçok matematiksel ölçüm önerilmiştir (Ghazal ve ark. 2020).

K-means algoritması, hızlı yinelemeli bir kümeleme yöntemidir ve kümeleme hatasını minimize etmek için kullanılır. Başlangıçta rasgele konumlara yerleştirilen küme merkezleri, her adımda hareket ettirilerek çözüm aranır. Ancak, başlangıç konumlarına bağlı olduğu için, farklı başlangıç noktalarında çalıştırmalar yaparak daha iyi sonuçlar elde edilebilir. K-ortalamlar algoritması, kümeleme problemlerini çözmek için sıklıkla kullanılmaktadır ve verilerin gruplanması, örüntü tanıma, görüntü işleme gibi birçok uygulama alanında kullanılmaktadır (Likasa ve ark. 2020).

4.3. Elbow ve Doğrulama Metodları

Elbow, örneğin K-means ve yığınsal hiyerarşik kümeleme gibi yöntemler için, hangi sayıda kümenin seçilmesi gerektiğini belirlemek için yaygın olarak kullanılan bir yöntemdir. Bu kriter, yeni bir küme eklemenin veri setine yeterli bilgi eklemeyeceği bir noktada durmanızı önerir. Başka bir deyişle, kümelerin açıkladığı varyans yüzdesi ile küme sayısını grafik üzerinde gösterdiğinizde, başlangıçta küme sayısındaki artışın fazla bilgi sağlayacağını ancak bir noktadan sonra bu artışın azalacağını görebilirsiniz. Bu noktada, grafikte bir dirsek noktası belirginleşir ve bu noktadan sonraki küme sayısı, yeterli bilgi sağlamak için uygun olan sayı olarak kabul edilir (Madhulatha 2012). Şekil 3'te örnek bir Elbow grafiği gösterilmiştir.



Şekil 3 : Elbow Grafiği Örnek

Bir veri kümesindeki gerçek küme sayısını belirlemek için en eski yöntemlerden biri "dirsek yöntemi" olarak adlandırılan bir görsel yöntemdir. Bu yöntemde, K=2 ile başlanır ve her adımda kümeler ve eğitimle birlikte gelen maliyet hesaplanarak K değeri 1 artırılır. K için bir değerde, maliyet önemli ölçüde düşer ve daha fazla artırıldığında bir düzlük gözlemlenir. Bu düzlük, istenen K değeridir (Trupti 2020).

4.3.1. Silhouette Score

Silhouette indeksi, kümeleme sonuçlarının uygunluğunu değerlendirmek için kullanılan bir ölçüdür. Bu indeks, her veri noktasının kendi kümesi içindeki benzerliğini ve diğer kümelerle olan farkını değerlendirir ve aşağıdaki eşitlikle hesaplanır:

$$s = \frac{b - a}{\max(a, b)}$$

a: bir örnek ile aynı kümedeki diğer tüm noktalar arasındaki ortalama mesafe

b: bir örnek ile en yakın kümedeki diğer tüm noktalar arasındaki ortalama mesafe

S değeri, -1 ile 1 arasında bir sayıdır ve 1'e daha yakın değerler, başarılı bir kümeleme işaretidir (Rousseeuw, 1987).

4.3.2. Davies-Bouldin İndeksi

Bu yöntem, verilerin aynı kümedeki merkeze olan uzaklığını en aza indirmeyi ve farklı kümeler arasındaki uzaklığı en fazla seviyeye çıkarmayı amaçlar. Kümeleme geçerliliğini ölçmek için aşağıdaki eşitlik kullanılır:

$$db = \frac{1}{k} \sum_{i=1}^k R_i$$

Her bir küme için, küme indeksi R_{ij} ile gösterilen, i ve diğer kümeler arasındaki maksimum karşılaştırma oranını hesaplamak için aşağıdaki eşitlik kullanılır; burada i ve j sırasıyla 1'den k 'ye kadar olan indislerdir.

$$R_{ij} = \frac{S_i + S_j}{d_{ij}}$$

d_{ij} : kümelerde bulunan merkezler arasındaki mesafe

S_i & S_j : küme gözlemlerinin bulunduğu kümenin merkezlerine olan ortalama mesafe

Küçük db (formül değişkeni) değerleri iyi kümelemeyi ifade eder (Davies ve Bouldin, 1979).

4.3.3. Calinski-Harabasz İndeksi

Bir veri kümesi k adet kümeye ayrıldığında, kümeleme geçerliliğini ölçmek için aşağıdaki eşitlik kullanılır:

$$ch = \frac{\text{tr}(B_k) \times (n_E - k)}{\text{tr}(W_k) \times (k - 1)}$$

$\text{tr}(B_k)$: kümeler içi kareler toplamı

$\text{tr}(W_k)$: kümeler arası kareler toplamı

Ch indeksinin en yüksek değeri, en iyi kümenin olduğunu gösterir (Caliński ve Harabasz, 1974).

4.4. Veri Düzenleme

4.4.1. Ki-Kare Testi

Ki-kare testi, gözlenen frekanslar ile beklenen frekanslar arasındaki farkın istatistiksel olarak anlamlı olup olmadığını belirlemek için kullanılan bir testtir. Niteliksel veriler kullanılarak yapılan test aynı zamanda sürekli değişkenlerin nitelendirilmesiyle de uygulanabilir. Ancak, oranlar veya yüzdeler şeklinde ifade edilen veriler için test uygulanamaz. Ki-kare testi, serbestlik derecesi ile tanımlanır ve küçük serbestlik derecelerinde basık bir dağılıma sahip olmasına rağmen, serbestlik derecesi arttıkça normal bir dağılıma yaklaşır. Genellikle, iki bağımsız niteliksel kriteri test etmek için kullanılır ve sıfır hipotez, iki kriterin bağımsız

olduđunu ifade ederken araştırma hipotezi, iki kriter arasında bir ilişki olduđunu belirtir (Güngör ve Bulut 2020).

4.4.2. Aritmetik Ortalama

İstatistiksel bir ölçüm olarak, bir veri kümesinin merkezi eğilimini belirlemek için kullanılan en yaygın ve anlaşılır yöntemdir. Veri kümesindeki gözlemlerin sayısal değerleri toplamının, gözlem sayısına bölünmesi ile hesaplanır ve bu değer ortalama olarak adlandırılır. İstatistikte ortalama terimi, merkezi eğilim ölçülerinden biridir ve veri kümesindeki gözlemlerin sayısal değerlerinin dağılımını özetler. Aritmetik ortalama formülü aşağıdaki gibidir:

$$A = \frac{1}{n} \sum_{i=1}^n a_i = \frac{a_1 + a_2 + \dots + a_n}{n}$$

ÜÇÜNCÜ BÖLÜM

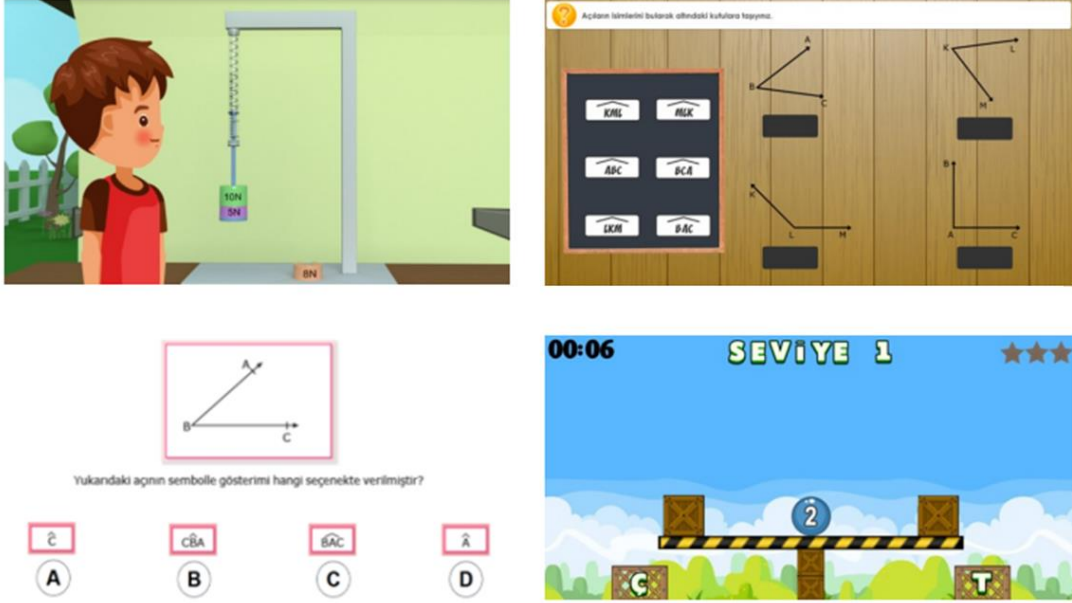
SİSTEM TASARIMI

1. EĞİTİM PLATFORMU

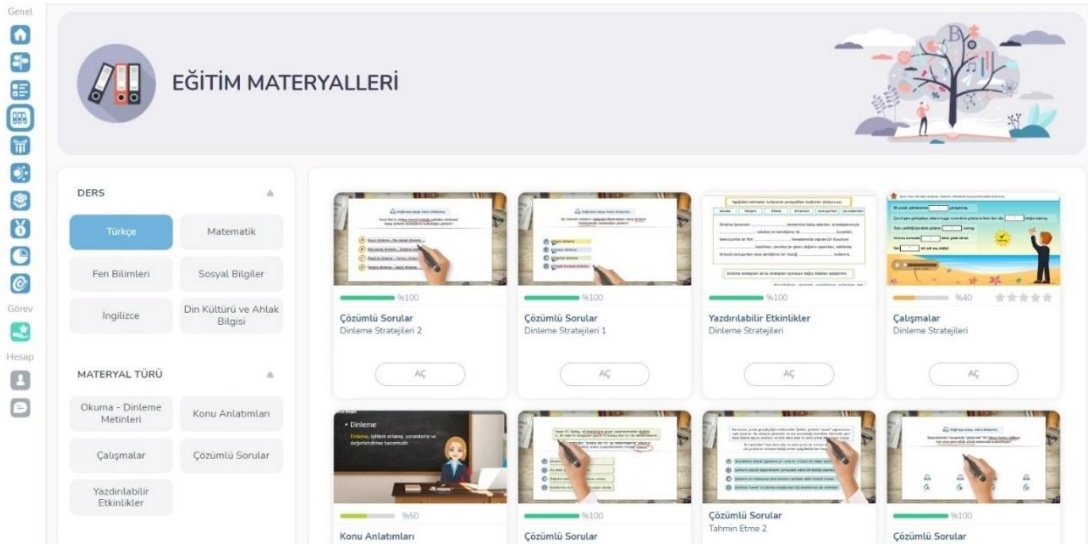
Bu uygulamada kullanılan platform bir e-öğrenme platformudur. Birçok yapılandırılmış öğrenme kaynağı ve etkinliği içeren kapsamlı bir çevrimiçi sistem olan e-öğrenme platformu, 1. sınıftan 8. sınıfa kadar öğrencilerin okumaya ve yazmaya hazırlık, Türkçe, Hayat Bilgisi, Matematik, İngilizce, Bilim (fizik, kimya ve biyoloji) ve Sosyal Bilgiler gibi birçok alanda eğitimini desteklemektedir. Bu platform, Türkiye Milli Eğitim Bakanlığı'nın ulusal müfredatına uygun içerikler sunmakta olup, web tarayıcısı veya mobil uygulama kullanılarak her zaman ve her yerden erişilebilir.

Platform, dersler, alıştırmalar (veya uygulamalar), sınavlar ve oyunlar olmak üzere dört ana bileşenden oluşur. Dersler, öğrencilerin sınıf düzeylerine göre tasarlanmış animasyonlu videolar şeklinde sunulur ve kavramların öğrenilmesine odaklanır. Derslerin ardından, öğrenciler öğrendiklerini pekiştirmek ve yeni konuları uygulamak için interaktif alıştırmalar veya uygulamalar yaparlar. Her modülün sonunda, öğrencilerin öğrendiklerini değerlendirmelerine yardımcı olmak için bir sınav yer alır. Bu sınavlar genellikle çoktan seçmeli veya doğru/yanlış sorularını içerir. Ayrıca, her modülde oyun tabanlı öğrenme özellikleri de yer alır, bu da öğrencilerin öğrendiklerini uygulamak ve daha fazla öğrenme fırsatı bulmak için eğitici oyunlar oynamalarını sağlar. Platform içinden alınmış görüntüler Şekil 4 'de verilmiştir.

Platform içinde alınmış görüntüler aşağıdaki gibidir:

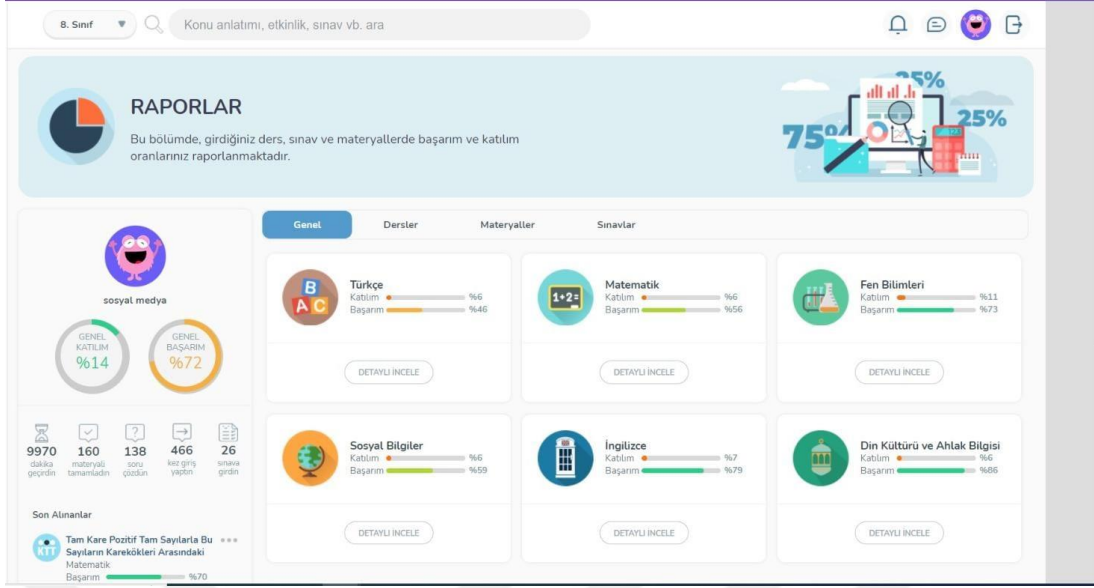


Şekil 4 : Ders İçe Örnek Resimler



Şekil 5: Sistem İçindeki Materyal Ekranı

Şekil 5’de görülmekte olan ekran 8. sınıf öğrencisinin Türkçe dersindeki materyalleridir. Öğrenci bu materyaller sayesinde dersi pekiştirebilmektedir.



Şekil 6: Sistem İçindeki Rapor Ekranı

Şekil 6 'de öğrencilerin durumlarının görüldüğü ekrandır. Burada öğrenciler hangi dersten ne kadar katılım sağladığı ve başarı durumları görülmektedir.

2. EĞİTİM PLATFROMUNDA KULLANILAN MAKİNE ÖĞRENME TEKNOLOJİLERİ

2.1. Pandas

Pandas, Python programlama dilinde yapılandırılmış veya tablo şeklindeki verilerin hızlı, kolay ve anlamlı bir şekilde işlenmesi için tasarlanmış üst düzey bir veri yapıları ve işlevleri kütüphanesidir. 2010 yılında piyasaya sürülen bu kütüphane, Python'un veri analizi konusunda güçlü ve üretken bir ortam olmasına katkı sağlamıştır. Pandas, veri manipülasyonu, filtreleme, sıralama, birleştirme ve gruplama gibi çeşitli işlemleri kolaylaştırarak, veri analizi sürecini daha hızlı ve etkili hale getirir (McKinney 2020).

2.2. Numpy

Numpy, 2005 yılında Travis Oliphant tarafından geliştirilmiştir. Diziler üzerinde işlem yapmak için oluşturulmuş Python Kütüphanesidir. Matris, doğrusal cebir ve fourier dönüşümlerinde kullanılmaktadır. Açık Kaynaklı bir kütüphanedir.

Python üzerindeki dizi listelerimizde yavaş olan işlemleri, numpy sayesinde 50 kat daha hızlı dizi nesnesi olarak kullanabiliriz (Balat 2022).

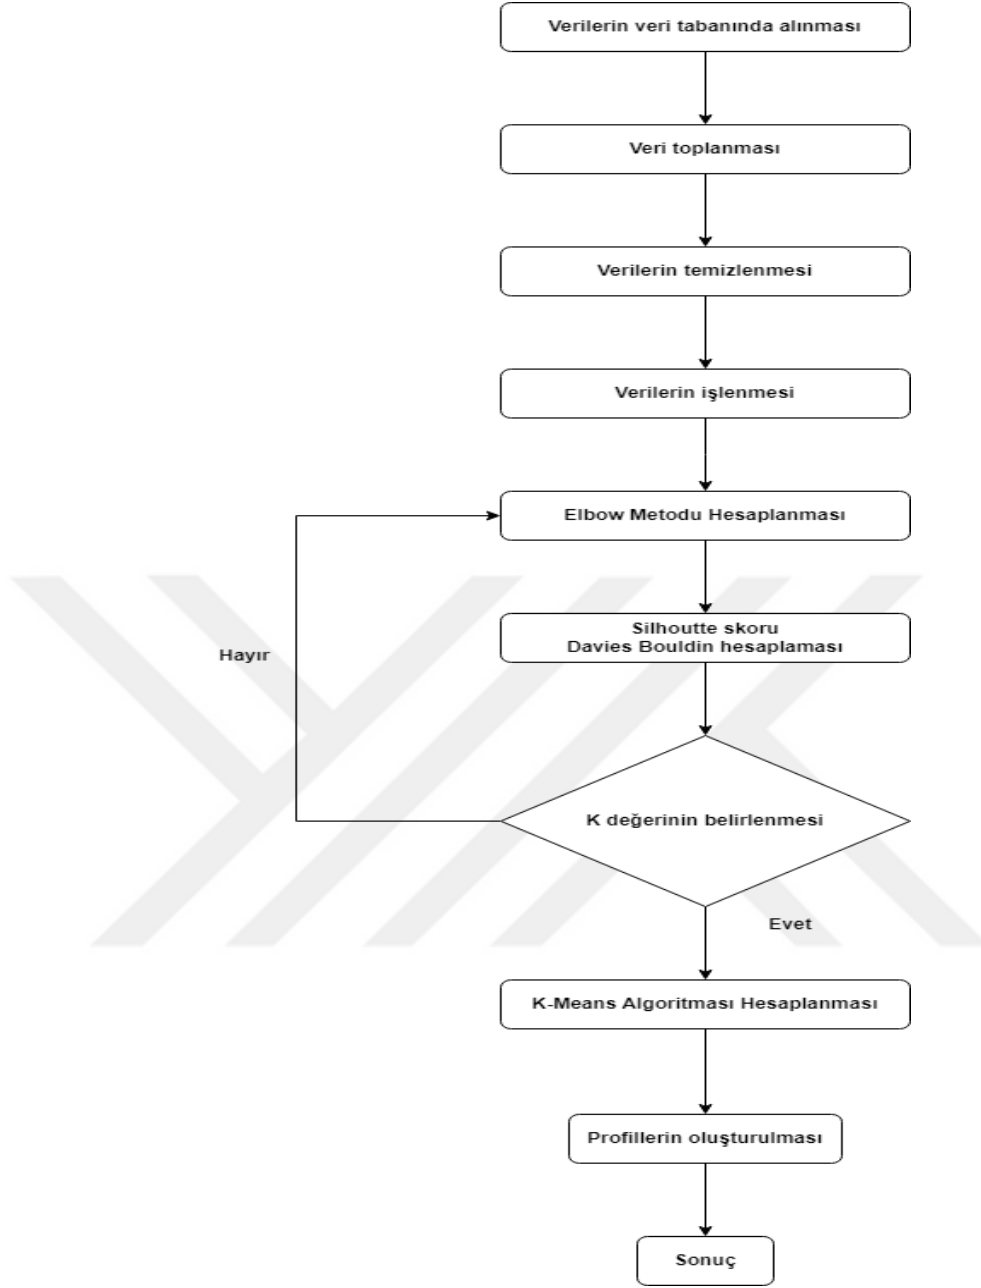
2.3. Anaconda

Anaconda, Python ekosistemindeki yazılımcıların veri bilimi, analiz ve yapay zeka gibi alanlarda paket, kütüphane ve framework işlemleri bir arada ve kolaylık yapmalarını sağlayan bir yapı sistemidir. Anaconda sayesinde birden fazla ortam oluşturulabilir ve bu ortamların her birine paketlerin farklı versiyonları yüklenebilir. Örneğin 1 ortama Python 2.0 yüklenirken diğer ortama Python 3.0 yüklenebilir ve bu ortamlar biri ile çakışma durumu yaşanmamaktadır. Anaconda yüklememizdeki amaç başka projeler ile versiyonların karışmaması içindir.

3. SİSTEMİN MİMARİSİ

Şekil 8'de sistem akışı görülmektedir. SQL veri tabanından 5 farklı tablodan veriler çekilmektedir. Çekilen verilerin toplanma işlemi verinin excel aktarılmasıdır. Visual studio editöründe python dilinde excel okunması için readexcel metodu oluşturuldu. Veri içerisinde geçersiz verilerin tespit edilip temizlenmesi sağlanır. Verilerin işleme kısmında öğrencileri girişlerine bakılarak materyaller arası geçişler tespit edilir daha sonra %100 olarak dağılım çıkartılır.

Çıkarılan veri içinde Elbow metodu kullanılarak en uygun küme sayısı tespit edilir. Silhouette skor ve Dbs (Davies Boulding skor) çıkan küme sayısı doğruluğu bakılır. Kmeans ile ideal küme sayıları belirlenir. Öğrencilerin sınıflar arasındaki hangi geçişleri yaptıkları tespit edilir. Buradaki öğrencilerin hareketlerine bakılarak profillendirme işlemi yapılır.



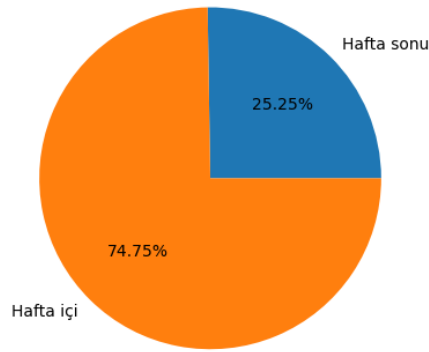
Şekil 7: Sistem Akış Şeması

4. UYGULAMADA KULLANILAN VERİLER

Bu çalışmada kullanılan veri seti, ilkokul ve ortaokul 1. sınıftan 8. sınıfa kadar olan öğrencilerin çevrimiçi öğrenme aktivite günlüklerini içermektedir. Günlükler, 1 aylık etkinlik verilerini (Eylül 2021) içermektedir ve bileşenine göre çeşitli veri tablolarında gruplandırılmıştır. Ders içeriği (777.791 kayıt), uygulama (454.999 kayıt), sınavlar (353.006 kayıt) ve oyunlar (271.696 kayıt) dahil olmak

üzere etkileşimde bulunulan çevrimiçi öğrenme sistemi. Her veri tablosu, anonimleştirilmiş ve dolayısıyla öğrencinin belirli veya belirlenebilir olmayacağı nitelikte bilgilerden olan kimliklerini, etkinliğin başlangıç ve bitiş tarihlerini ve etkileşimde bulunulan bileşenlerin kimliklerini içerir. Ayrıca yine öğrencinin tekilleştirilemeyeceği bilgilerden olan ders içerikleri ve uygulama tabloları, her bir öğrencinin içerikleri görüntüleme yüzdesini temsil eden katılım oranı sütunlarını, sınav ve uygulama tabloları ise her öğrencinin uygulama ve sınav bileşenlerindeki performansını yansıtan bir puan sütununu içerir.

Öğrencilerin platformu hafta içi ve hafta sonu kullanım oranları grafiği aşağıdadır. Buna göre hafta içi kullanan öğrenci sayısı yüksektir.



Şekil 8: Hafta İçi ve Hafta Sonu Öğrenci Devamlığı Grafiği

Tablo 1’de Veri setindeki deęişkenlerin Veri tipleri görölmektedir.

Tablo 1: Veri Seti Özellikleri Tablosu

Sınav-->Çalışma	Float
Sınav-->Konu	Float
Sınav-->Oyun	Float
Çalışma-->Sınav	Float
Çalışma-->Oyun	Float
Çalışma-->Konu	Float
Konu-->Sınav	Float
Konu-->Çalışma	Float
Konu-->Oyun	Float
Oyun-->Sınav	Float
Oyun-->Konu	Float
Oyun-->Çalışma	Float

DÖRDÜNCÜ BÖLÜM

UYGULAMA VE SONUÇLARIN DEĞERLENDİRMESİ

1. VERİ TEMİZLEME

Veri temizleme işlemi, verilerin kalitesini ve bütünlüğünü sağlamak için birkaç adım içeriyordu. İlk olarak, 30 saniyeden kısa süren oturumlar, anlamlı etkileşim için yetersiz oldukları düşünüldüğünden dışlandı. Benzer nedenlerle, 20 saniyeden kısa süren uygulama ve sınav etkinliklerine ilişkin günlükler de atılmıştır. Ayrıca ders ve uygulamalara katılım oranı %0 olan öğrenciler ile uygulama ve sınavlardan 0 alan öğrenciler, katılım düzeylerinin son derece düşük olması nedeniyle verilerden çıkarılmıştır. Bu filtreleri uyguladıktan sonra, veri seti 82.189 öğrenci günlük kaydından 67.686'ya düşürüldü ve bu, ilk verilerin %17,8'lik bir kaybını temsil ediyordu. Veri seti boyutundaki bu azalma, gürültüyü ortadan kaldırmak ve analize yalnızca anlamlı etkileşimlerin dahil edilmesini sağlamak için gerekliydi. Temizleme işleminde yine öğrencilerin belirli veya belirlenebilir olmasını sağlayabilecek nitelikte tekilleştirilebilirliğini sağlayan bilgiler de katılım düzeylerinin son derece düşük olması nedeniyle verilerden çıkartılmıştır.

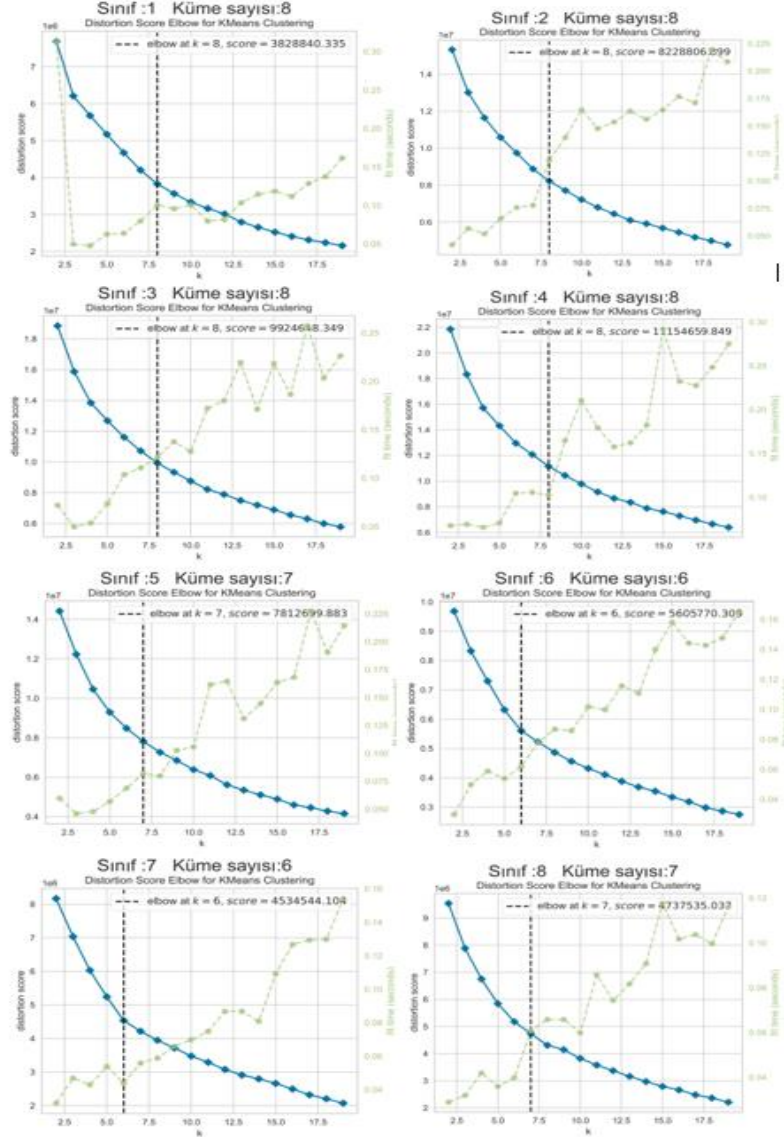
Nihai veri setine dahil edilen öğrenciler, Türkiye genelinde 81 farklı ilde bulunan 10.872 okuldaki 26.742 farklı sınıftan geldi.

2. VERİ İŞLEME

Öğrencilerin verilerini işlemek için Python Parser oluşturduk. Python Parser öğrencilerin günlük yapmış olduğu hareketleri (log kayıtlarını) tespit edip materyaller arasındaki geçişleri kontrol etmektedir. Her geçiş işlemi öğrencinin yönelim tespiti de kullanılacak bir değişken olmuştur. Bunlar örnek olarak Konu anlatımından, sınavlara geçiş “Konu anlatımı-Sınavlar bağımsız değişkenini bir artıracaktır. Günlük veriler çıkartıldıktan sonra öğrencinin aylık verileri tablo haline getirilmiştir. Gün içinde yapılan yönelimlerin yüzdeleri alınmıştır. Aylık düzenlemesinde öğrencilerin aritmetik ortalaması tespit edilmiştir. Veri içinde 12 bağımsız değişken oluşturulmuştur.

3. ÇIKTILARIN DEĞERLENDİRİLMESİ

Aşağıdaki grafikte sınıfların Elbow ile ideal kümeleri belirlenmiştir. 1., 2., 3., 4. sınıfta 8 kümeden oluşmaktadır. 5. ve 8. sınıflar 7 kümeden ve 6. ve 7. sınıflar 6 kümeden oluşmaktadır.



Şekil 9: Elbow Çıktı Grafikleri

Yukarıda yapılan Elbow ile belirlenen kümelerin doğruluğunu görmek için Silhouetter Skor, Davies Bouldin Index ve Calinski Harabasz Index ile ölçülmüştür.

Calinski harabasz Index (CHI) değeri oldukça yüksek bir değere sahiptirler. Bu, kümeleme sonuçlarının iyi tanımlanmış ve birbirlerinden ayrılmış kümeler ürettiğini gösterir.

Davies-Bouldin Index (DBI) deęerinin sifira yakın olması beklenmektedir. Bizim sınıflarımıza bakıldığında verilerimiz pozitif sonuçtur. Deęerlerin sifirdan çok yüksek olmaması kümelerin uygun olduğunu göstermektedir.

Silhouette skoru deęerinin 1'e yakın olması beklenmektedir. Sınıf modellerin deęerinin 0.28 ile 0.33 arasında olması küme sayılarının uygun olduğunu göstermektedir. Tablo 2'e bakıldığında Silhouetter Skor, Davies Bouldin Index ve Calinski Harabasz Index sonuçları görölmektedir.

Tablo 2: Küme Doğruluk Sonuçları Tablosu

Sınıf	1	2	3	4	5	6	7	8
Silhouetter Score	0.286	0.302	0.302	0.298	0.312	0.315	0.337	0.326
Davies Bouldin Score	1.163	1.322	1.382	1.375	1.392	1.335	1.359	1.344
calinski harabasz score	869.553	1.390.156	1.949.395	2.597.759	1.765.618	1.314.785	1.221.022	1.255.869

3.1. Profillerin Etiketleri

Şekil 10'a bakıldığında sınıflarda elde edilen kümelerin içerisinde tespit edilmiş profiller görölmektedir.

Tablo 3'ün içerisindeki deęişkenler 1: Sınav, 2: Çalışmalar, 3: Oyun, 4: Konu olduğunu ifade etmektedir.

	Döngüsel geleneksel öğrenciler
	Doğrusal teori-uygulama öğrencileri
	Yinelemeli ustalık sınavına girenler
	Sistem Ustası
	Ustalık gerektiren oyuncular
	Pratik odaklı sınav katılımcıları
	Teoriden pratiğe geçen gözden geçirciler
	Oyun odaklı sınav katılımcıları
	Doğrusal, oyun öncelikli yorumcular
	Doğrusal, uygulama öncelikli gözden geçirciler

Şekil 10: Profillerin Etiketlenmesi

Tablo 3'te Sınıflar içerisinde kümeler yapılmış ve hangi profilin yüzdesel olarak bölündüğü görölmektedir. Ayrıca kümelerde en yüksek kullanımlar dikkat edilerek etiketler oluşturulmuştur.

Tablo 3: Sınıf Dağılım Tablosu

Küme 0 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	1,416141	3,697622	3,442504	1,173674	39,89888	2,808155	2,268317	41,99734	0,32211	0,159134	0,784077	2,032052
2	0,03278	1,258201	1,633875	0,412544	6,192492	0,319908	0,103319	89,91933	0,063776	0	0	0,063776
3	0,082427	0,840811	1,350825	0,22997	4,69994	0,037092	0,045335	92,7136	0	0	0	0
4	4,650233	5,365557	7,227247	12,22576	7,593778	12,12045	4,489416	17,86331	9,710071	6,257801	7,099841	5,396528
5	2,476941	22,54401	26,16633	0,614876	7,051686	1,70627	3,444152	33,39924	1,255263	0,349933	0,23981	0,751494
6	1,080811	3,246112	3,862196	1,328266	38,88304	1,926725	1,888418	45,99592	0,297585	0,138492	0,449184	0,963254
7	3,165734	31,81317	2,204366	0,12551	5,073622	1,104202	49,05496	4,695375	1,135279	0,795789	0,342956	0,489046
8	2,204222	3,70866	5,35629	0,801328	40,16881	1,008217	2,135246	43,25594	0,35653	0,1175	0,390269	0,496996
Küme 1 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	0,379931	1,193102	0,882907	1,234769	4,958294	27,09929	0,90697	3,131614	0,577323	0,486345	1,972631	57,17682
2	1,832638	2,720205	6,976979	0,999068	2,211573	3,604321	6,408731	4,454696	41,69063	24,22841	3,03636	1,83639
3	0,433674	2,718249	1,568138	1,098259	3,780658	33,83401	1,697653	4,8657	0,958319	2,26847	1,138913	46,63795
4	0,065613	0,937237	1,559757	0,376759	7,024628	0,31964	0,022265	89,65329	0,016234	0	0	0,023674
5	0,015613	0,699138	1,187363	0,208821	6,152517	0,156128	0,04879	91,41844	0,052693	0,019516	0	0,040984
6	2,611286	20,1376	26,14105	0,653049	8,224362	1,793222	3,010431	34,18486	1,722808	0,54482	0,338707	0,727807
7	1,226646	2,590862	3,003821	1,155254	42,51578	1,258179	1,517334	45,34848	0,139695	0,121157	0,443539	0,679253
8	2,202624	41,4395	5,343516	0,127003	4,996103	0,814866	34,92676	7,25323	1,036495	0,933856	0,039514	0,884704
Küme 2 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	3,785512	27,39795	3,61963	0,72886	8,704369	3,376618	39,47338	7,248474	2,396953	0,941743	0,49814	1,828421
2	3,359851	29,63603	4,103176	0,271268	5,682667	3,04423	43,22014	5,445015	1,851293	1,562552	0,225763	1,598016
3	2,055182	4,692612	7,218923	1,364027	2,211583	5,244264	6,80039	5,165577	36,565	24,28376	2,515983	1,9787
4	0,234343	3,167551	1,308013	0,902115	4,489422	33,73866	2,307399	5,05138	0,956153	1,048551	1,247854	45,54856
5	2,732931	5,169168	6,71441	14,66126	7,467881	11,38965	4,343305	18,88359	9,816805	6,464462	7,735798	4,573703
6	31,095	3,719605	42,62882	1,024495	5,266741	0,539618	1,850716	9,521727	1,62664	0,776984	1,603668	0,345985
7	3,868318	19,66162	26,33271	0,758666	8,398125	1,302377	3,366147	33,52441	1,335847	0,512477	0,448365	0,490947
8	0,071725	0,659599	1,664083	0,199292	5,700051	0,281625	0,055402	91,29205	0,023084	0	0,034626	0,018467
Küme 3 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	4,06453	22,97107	23,79641	0,616612	8,249434	3,131362	4,370409	27,33085	2,011719	0,489907	0,936567	2,031132
2	1,542692	3,706411	4,644602	1,141762	39,91451	2,057916	2,129232	41,435	0,490329	0,267866	0,820348	1,77337
3	2,595589	30,50222	3,839099	0,176127	4,843423	2,380844	46,18945	5,550123	1,768543	0,667546	0,240156	1,626876
4	4,797435	21,42178	29,36594	0,531288	5,515471	1,872937	3,123921	29,86316	1,786493	0,40266	0,449194	0,872555
5	1,286811	3,535899	3,750554	1,561377	39,51236	2,358812	2,029107	43,22623	0,305496	0,145917	0,171649	1,575791
6	3,001093	31,87658	3,295986	0,099149	4,503822	1,764569	46,83328	5,683416	1,400138	1,023583	0,019763	0,749652
7	0,065331	0,718716	1,48004	0,098722	6,529941	0,08856	0,039634	90,80371	0,075348	0	0	0
8	3,830406	22,25754	29,00073	0,601577	5,890557	0,947753	3,401642	32,25532	0,928663	0,295337	0,331811	0,258662
Küme 4 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	2,592669	4,915133	5,989081	10,31519	9,525678	19,02964	4,228907	15,55614	6,196216	3,486931	6,553034	11,61138
2	2,383818	4,484034	5,57314	16,2253	7,90053	19,67454	3,399969	17,60759	4,499524	2,669378	7,294977	8,347203
3	2,274407	22,22455	26,74535	0,663665	5,754337	2,445035	3,434466	31,98034	2,565229	0,569557	0,37592	0,967146
4	1,308376	4,266704	4,113876	1,688833	37,95496	2,822912	2,239042	42,27036	0,320594	0,207052	0,77046	2,036832
5	30,55614	4,441704	44,20154	0,821963	3,428969	0,71353	2,412187	8,596084	2,216651	0,815503	1,29359	0,502342
6	0,024783	0,184103	0,232121	0,030979	0,367764	0,085192	0	99,05182	0,023234	0	0	0
7	2,025733	3,087852	3,935248	15,38041	6,163829	19,25367	2,40827	15,175	5,51441	3,176609	9,624586	14,25438
8	3,330701	3,607446	5,233265	13,72321	4,829776	14,7949	2,492474	12,12353	11,48977	7,459432	8,379788	12,53557
Küme 5 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	0	1,134516	1,452944	0,271003	5,405478	0,406504	0	91,09243	0,101626	0	0,067751	0,067751
2	2,278896	21,46642	26,79207	0,831256	5,546404	2,789962	3,257976	31,68558	2,916158	0,767532	0,526953	1,140795
3	1,340727	3,724372	4,179506	1,259603	40,45214	2,051798	2,159472	42,03118	0,400309	0,214611	0,577619	1,608637
4	2,505813	31,34117	3,8162	0,199936	4,219639	2,323527	45,26067	5,49343	2,370614	0,855797	0,140893	1,472308
5	2,620931	31,35673	3,040764	0,187824	4,662947	1,364564	48,34162	5,519502	1,580193	0,563253	0,086524	0,675145
6	0,926607	2,671551	2,561367	1,517266	7,413695	35,4075	1,899732	11,61546	1,333734	1,268707	1,362938	32,02145
7	34,71168	2,583418	46,00083	0,997333	3,236974	0,25137	1,595828	6,722755	1,448662	0,758556	1,667741	0,02486
8	35,67381	2,866693	48,67805	0,351484	2,38216	0,127061	1,453698	6,386533	0,959877	0,382241	0,695719	0,042678
Küme 6 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	0,102041	0,113379	0,102041	0,484694	0,170068	90,93537	0,368481	0,569728	0,255102	0	0,085034	6,814059
2	29,10767	5,54191	41,69096	1,743702	3,523416	0,957025	2,686542	8,280929	2,777107	0,94898	3,010853	0,739092
3	27,9785	4,834852	44,23729	1,209718	3,183822	0,784683	2,974244	7,852144	2,684582	0,801472	2,984183	0,474507
4	0	0	0	0	0	0	0	0	0	0	0	0
5	0,307257	2,167611	1,636768	0,945957	4,899946	37,17927	1,379641	6,515705	0,90398	1,364826	1,901957	40,79709
6	2,93677	2,370752	5,312429	22,7265	7,693123	5,790488	1,694321	16,52924	9,08377	6,916328	17,17405	1,77532
7	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0
Küme 7 içerisinde tespit edilen profiller												
Sınıflar	1-->2	1-->4	2-->1	2-->3	2-->4	3-->4	4-->1	4-->2	1-->3	3-->1	3-->2	4-->3
1	1,30854	0,149219	0,045914	0,118064	86,4758	0	0,998623	3,50387	0	0	6,766365	0,633609
2	0,253166	3,624588	1,00398	0,392437	5,705159	17,5096	1,121644	2,330707	0,66994	1,831784	1,458463	64,09913
3	2,768983	5,510196	7,451852	15,85908	9,12391	13,74245	3,580764	21,29397	4,364612	2,156657	7,512323	6,635202
4	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0

Tablo 3 incelendiğinde 1., 2., 3., ve 4., sınıflarda 8 küme görülmektedir. 5. ile 8.sınıf sınıf 7 küme ve 6. sınıf ile 7.sınıf 6 kümeden oluşmaktadır. Bu kümeler incelendiğinde her kümedeki yüksek değerler çıkartıldı. Çıkartılan değerler yukarıdaki tablo da renk olarak işaretlenmiştir. Bu işlem ile birlikte 10 farklı etiket

oluşmuştur. Örneğin Sınavdan Konu anlatımına, çalışmalardan sınavlara, konu anlatımından çalışmalara geçiş yapan öğrenciler “Döngüsel geleneksel öğrenenler” olarak etiketlenmiştir. Bu etiketlemeler aşağıda sıralanmıştır:

3.1.1. Döngüsel Geleneksel Öğrenenler

Döngüsel Geleneksel Öğrenen Öğrenciler, öğrenme süreçlerini belirli bir model içinde tekrarlayan ve dönüşümlü bir şekilde yönlendiren öğrencilerdir. Bu öğrenciler, geleneksel öğrenme yaklaşımlarını benimsemeyi tercih ederler ve bu yaklaşımları kapsamlı bir şekilde benimserler. Genellikle dersler, uygulamalar ve sınavlar gibi çeşitli kaynakları dengelemeyi hedeflerler.

Bu öğrenciler, öğrenme sürecinin bir parçası olarak odaklı çalışma, uygulama ve değerlendirmeye büyük önem verirler. Bilgiye hakim olma amacıyla içerikle etkileşimde bulunmayı tercih ederler. Bu nedenle, geleneksel öğrenme yöntemleri ve değerlendirmeleri onlar için önemlidir.

Oyun tabanlı öğrenme veya alternatif öğrenme yaklaşımları bu öğrenciler için genellikle daha az ilgi çekicidir. Bunun yerine, geleneksel öğrenme araçlarını kullanarak bilgiyi anlama ve uygulama üzerine yoğunlaşırlar.

Sonuç olarak, Döngüsel Geleneksel Öğrenen Öğrenciler, belirli bir öğrenme modelini benimseyen ve bu modeli tekrarlayan öğrencilerdir. Bu model, içeriğe hakim olmayı ve geleneksel öğrenme yöntemlerini benimsemeyi hedefler.

3.1.2. Doğrusal Teoriden Uygulamaya Öğrenenler

İki numaralı kümede çoğunlukla konuyu çalıştıktan sonra etkinliklerle alıştırmaya yapan ilkökul ve ortaokul öğrencileri vardır. Bu öğrenciler kendilerine öğrendikleri konuyu etkinlikle pekiştirme fırsatı sağlar. Ancak öğrenciler öğrenme anını oyunla eğlenceli hale getirmeyerek keyifli bir öğrenme süreci deneyimlemezler. Öğrencinin hevesi azalacağı için konu tekrarı yapma ihtimali düşebilir. Konunun tekrar edilmemesi bilginin kısa bellekte uzun süre kalamamasına

(Kurtuldu ve ark., 2010) ve bu olumsuz durum beraberinde çocuğun konu eksikliği yaşamasına neden olabilir.

3.1.3. Yinelemeli Ustalık Sınavına Girenler

Üç numaralı kümede çoğunlukla sınava girip sonra konu çalışan ve konu çalışıp sonra sınava giren ilkokul ve ortaokul öğrencileri vardır. Bu öğrenciler sınava girerek eksik oldukları konular hakkında farkındalık kazanırlar. Böylelikle eksikliklerine odaklanarak sınav sonrasında bu konulara çalışırlar. Öğrenmenin tamamlandığı konularla zaman kaybetmiş olmazlar.

Öğrenme sürecinde belirlenen kazanımlar doğrultusunda oluşturulan etkinlikler öğrencilerin keşfederek, istekli bir şekilde ve aktif katılım ile öğrenmesini sağlayarak öğrenilen bilgiyi işlemesini, önceden konu hakkında bildikleriyle yeni bilgiler arasında bağlantı oluşturarak anlayabilmesini sağlayabilmek amacıyla yapılır (Güneş, 2017). Ancak eksik bilgiye sahip oldukları konuya çalıştıktan sonra etkinlik yapmayarak kazandığı bilgiyi daha uzun süre keşfedememesine ve zihninde kavram haritasını oluşturamamasına neden olabilir.

3.1.4. Sistem Ustası

Dört numaralı kümede çoğunlukla konuyu öğrenip çalışma yapan, çalışma sonrası oyun oynayan ve oyun sonrası konu çalışmayı tekrar eden ilkokul ve ortaokul öğrencileri vardır. Bu öğrenciler öğrenmede çok yol veya yöntem kullanmış olurlar. Böylelikle oyun oynama becerilerinin gelişmesi sağlanır. Bu sayede farklı stratejiler üretip, birçok taktik öğrenmiş olurlar. Oyun oynarken kazanmak için kullanacakları birden fazla yol veya yöntemleri vardır. Farklı yollar deneyimleyerek problemlere yaklaşımını ve problem çözme becerisini geliştirir. Böylelikle oyunu da daha iyi kavrayabilir ve oyunda ustalaşabilir. Yöntemler öğrencilerin oyundaki kazanma ihtimalini de arttırır. Bu başarılı öğrenme yönteminde öğrenciler sınava katılmayarak sınav anında yaşayacağı stresi ve süre kullanımı planlayamayacaktır.

3.1.5. Usta Oyuncular

Beş numaralı kümede çoğunlukla önce oyun oynayıp sonra konu çalışan ve konu çalıştıktan sonra oyun oynayan ilkökul ve ortaokul öğrencileri vardır. Eğitimciler öğrencilerinin bilgiyi kazanırken, öğrenme sürecinin keyifli hale gelmesini ve ders çalışma motivasyonunun artmasını isterler. Bu öğrencilerin başarılı olarak kendini gerçekleştirmiş olma hissiyatı yaşamak temel ihtiyaçları arasındadır (Tekke, 2019). Öğrencinin oyun içerisinde basamak atlayamadığı veya görevi tamamlayamadığı zamanlar olabilir. Bu durum öğrenci de oyunun zor olduğu düşüncesini oluşturur ve hırs duygusunu arttırıp, hatasını fark edip, eksik olduğu konuyu bulmasını sağlar. Oyun da başarıya ulaşmak, seviye atlamak veya görevi tamamlamak için konu çalışarak eksiklerini kapatır. Sonra oyun oynama eylemini tekrarlayarak ustalaşır ve başarıya ulaşmayı sağlar. Basamak atladıkça başarı hissiyatı oluşur. Öğrencinin motivasyonu artar. Mutlu olur. Artan motivasyonla birlikte her zor seviyeden sonra konu üzerine çaba gösterip, oyun oynamayı yineler. Bu yineleme yöntemiyle öğrenme süreci keyifli hale gelir ve öğrenme de sağlanmış olur.

3.1.6. Pratik Odaklı Sınav Katılımcıları

Günümüz eğitim sistemi, öğrencilerin bilgiye erişimini ve anlama yeteneklerini değerlendirmek için yinelemeli ve pratik odaklı sınavlar gibi çeşitli ölçme araçları kullanmaktadır. Yinelemeli sınavlar, öğrencilerin öğrendikleri bilgiyi hatırlama ve tekrar etme becerilerini ölçerken, pratik odaklı sınavlar bilginin gerçek dünya problemlerini çözme ve pratik uygulama yeteneklerini değerlendirir. Her iki sınav türü de öğrencilere farklı beceriler kazandırabilir ve eğitim sürecini zenginleştirebilir, bu nedenle dengeleyici bir yaklaşım önemlidir.

3.1.7. Teoriden Pratiğe Geçen Gözden Geçirenler (Teoriden Pratiğe Yorumcular) (Pratik Gözden Geçirenler)

Yedi numaralı kümede çoğunlukla konu çalıştıktan sonra etkinlik çalışması yapan ve etkinlik çalışmasından sonra konu çalışan ilkökul ve ortaokul öğrencileri vardır. Bu öğrenciler bilgiyi birçok kez tekrar edip etkinlikle uygulamaya aktararak zihinlerinde öğrendikleri bilgi ile ilgili kavram haritası oluşur ve konu öğrenci için daha bağlantılı ve anlaşılır hale gelir. Konuyu kavrama yeteneğinin gelişmesini ve hafızasında konuya daha derinlemesine anlaşılabilirlik kazandırmasını sağlar. Bu

öğrenme sürecinin yinelenmesi uygulamalarda daha iyi performans sergileme fırsatı sunar. Tekrarların sürekli olması, yapılan yanlışların belirlenmesine ve yanlışların düzeltilmesine imkan tanır. Böylece öğrencilerin uygulamada daha iyi sonuçlar görmesini sağlar. Yinelenmenin devamlı olması öğrenme sürecinin de sürekli olmasını ve gelişimin de sürekli hale gelmesini sağlar.

3.1.8. Oyun Odaklı Sınav Katılımcıları

Sekiz numaralı kümede çoğunlukla oyundan sonra sınava giren ve sınavdan sonra oyun oynayarak bu öğrenme süresini devamlı yineleyen sadece 2. ve 3. sınıfın dahil olduğu ilkokul öğrencileri vardır. Öğrenme kadar öğrenme süreci de önemlidir. Süreci eğlenceli geçiren çocuklarda heves ve motivasyon artar. Öğrenmeye daha fazla zaman ayırabilirler. Bu öğrenme yönteminde de öğrenme sürecini oyun ile eğlenceli hale getirerek öğrencilerin bu sürecini etkili hale getirmektir. Öğrencilerin daha fazla egzersiz yapmalarına ve öğrenme kazanımlarını hızlı elde etmelerine yardımcı olabilir. Öğrenciler daha önce öğrendikleri bilgileri oyun ile pekiştirme fırsatı bulurlar. Bu da konuyu daha da iyi anlamalarına olanak sağlar. Fakat sadece oyun oynayarak ve sınava girerek öğrenme yeterli olmaz. Oyunda yaptıkları hataları hızlı geri bildirim sayesinde hemen fark ederler. Oyun ve sınav ile fark edilen eksik konular için öğrencilerin konuyu öğretmen veya ebeveyni yardımıyla tekrar etmeleri gereklidir. Böylelikle eksik konuları tamamlanmış olup, öğrenme daha etkili olacaktır. Konu tekrarının yinelenmesi bilgi kazanımında önemlidir. Oyun ile öğrenme konusunda bir diğer önemli nokta da güvenilir kaynaklardan oyunun seçilmesidir. Aksi halde öğrenme yetersiz veya yanlış bilgi sahibi olmaya neden olabilir. Oyunlar sayesinde öğrenciler aktif olmadan da deneyimleme şansı bulurlar.

3.1.9. Doğrusal Oyuna Öncelik Veren Öğrenciler (Oyunu İlk Gözden Geçirenler)

Dokuz numaralı kümede çoğunlukla oyun oynadıktan sonra öğrencinin kendi isteğiyle konu çalıştırılan sadece 1. sınıfın dahil olduğu ilkokul öğrencileri vardır. Okul öncesi dönemde oyun oynamaya alışık olan öğrenciler, yeni bilgi öğrenirken oyunu tercih edebilirler. Oyuna aşına olan bu öğrenciler için öğrenme kolaylaşabilir. Çocukların bir konuya odaklanma süresi, yetişkinlere göre kısadır. Bu sayede oyun süreci eğlenceli hale getirip sıkılmadan öğrenmelerine yardımcı olabilir.

Ancak 1. sınıf öğrencileri, okul öncesi dönemde oynadıkları oyunda amaçları sadece eğlenmek olduğu için oyunla öğrenme yönteminde öğrenme amacını göz ardı edebilirler. Öğrenciler oyunun öğrenme sürecinin bir parçası olduğu hakkında bilgilendirilmelidir.

Ayrıca sadece oyun ve sınav ile öğrenme yöntemleri öğrenme konusunda yetersiz kalabilir. Öğrendikleri konuları tekrar etmeleri öğrenme sürecinin önemli bir davranıştır. Öğrendikleri bilgileri birleştirerek daha kapsamlı bir anlayış sentezlemelidirler.

3.1.10. Doğrusal Uygulama Öncelikli Sınava Girenler (Pratik Öncelikli Sınava Girenler)

On numaralı kümede çoğunlukla çalışma etkinliklerinden sonra konu çalışan sadece 1. sınıfın dahil olduğu ilkökul öğrencileri vardır. Öğrenciler bu çalışma yöntemiyle önce etkinliklerle bol bol uygulama yapıp daha sonra konu içeriğindeki teorik bilgiyi öğrenirler. Öğrencilerin pratik yaparak öğrendikleri bilgiyi farklı etkinlikler içerisinde uygulayabilmesini geliştirir. Yani uygulama becerisi gelişim gösterir. Soru çeşitliliğini öğrenerek soru çözme tekniği geliştirir. Etkinliklerle uygulama yaptıktan sonra konu çalışarak edindikleri deneyimi bilgilerle daha kolay birleştirmiş olurlar. Bu öğrenme yöntemiyle öğrencilerin öğrendiklerini sınav anında daha iyi hatırlarlar. Böylece sınav başarısında artış yaşamaları sağlanır. Fakat öğrenciler daha 1. sınıf oldukları ve geçmiş yıllardan gelen bir bilgi birikimi olmadığı için konuyu tam anlamadan etkinlik çalışmalarını yapmaya çalışabilirler. Bu durumda öğrenci etkinlik çalışmasında kafası karışır, konuların zor olduğunu düşünebilir, ders çalışma motivasyonu azalır ve derslerinde başarılı olmayabilir.

Ayrıca tıpkı paragraf sorularında geliştirilen taktikler gibi bazı sorularda uygulanan pratik yollar, her aynı tip sorularda bile geçerli olmayabilir. Paragrafı çözerken sorunun anlam bilgisine de dikkat edilmelidir. Her öğrencinin kendine özgü öğrenme yöntemi vardır. Bu öğrenme yöntemi, her öğrencinin öğrenme tarzına uygun olmayabilir. Bu yöntem ile konuyu öğrenmeyi seçmeyebilir.

SONUÇ VE ÖNERİLER

Bu tezde öğrencilerin çevrimiçi eğitim platformundaki etkileşimlerinden profillerinin oluşturulabileceği araştırıldı. Pandemi sonrasında eğitim platformlarının günümüzde daha çok kullanıldığı görülmektedir. Aileler öğrencilerin okuldaki eksikliklerini kapatmak için çevrimiçi platformlara başvurduğu görülmektedir. Günümüzde tüm işlerde kullanılabilen makine öğrenimi eğitim içinde kullanılmaya başlamıştır. Kullanıldığı her alanda katkı sağlayan makine öğrenimi, eğitim sektöründe de öğrencilerin başarısını arttırmaya yardımcı olacaktır.

Öğrenme analitiği, öğrencilerin çevrimiçi ortamlarda etkileşimde bulunurken ve öğrenirken ürettikleri verilere dayanarak öğrenme süreçleri hakkında derinlemesine ve kapsamlı içgörüler sunmayı amaçlar. Bu alan önemli bir olgunluğa ulaşmış olmasına rağmen, ilkokul ve ortaokul düzeyindeki öğrencilerin öğrenme süreçlerini anlamaya ve iz verilerini kullanarak öğrenci profilleri oluşturmaya yönelik araştırmalar sınırlıdır. Bae ve DeBusk-Lane daha önceki çalışmalarında, genç öğrencileri katılım ve motivasyon profillerine göre sınıflandırmak için kendi beyanlarına dayalı verileri kullanmıştır ve bu verilerin öznel olduğu bilinmektedir

Araştırmalara bakıldığında genellikle Üniversite veya lise öğrencileri üzerine yapılmış makine öğrenmesi çalışmaları görülmektedir. Literatüre katkısı bakımından bu araştırmada ilkokul ve ortaokul öğrencileri üzerine yapılmış ilk araştırma olabilir.

Projede veri tabanından verilerin çekilmiştir. Python üzerinde "utils" adında bir sınıf yapılmıştır. Sınıf yazılmasının amacı nesne tabanlı programlama yaklaşımına uyulmak istemektedir. Bu yaklaşım ile kod tekrarlarından kaçınılmıştır. "utils" sınıfı sayesinde veri temizleme işlemi yapılmıştır.

Makine öğrenimi tekniklerinden olan Kmeans algoritması kullanılmıştır. Kmeans algoritmasının k sayısını belirlemek için Elbow metodundan yararlanılmıştır. Elbow metodunun doğruluğu içinde silhouetter score, davies bouldin index ve calinski harabasz index yararlanılmıştır.

Arařtırmada her sınıf için model oluřturulmuřtur. Toplamda 8 adet modelimiz bulunmaktadır. Modellerimizin 1.sınıftan 4.sınıfa kadar olan modeller 8 kümeden oluřmaktadır. 5. ile 8. sınıf 7 kümeden 6. ile 7.sınıf 6 kümeden oluřmaktadır. Küme sayısını yardımcı metodlar ile incelendiğinde başarılı sonuç alındığı görölmektedir. İlkokul öğrencilerinde aynı küme sayısı tespit edilmesi onları benzer etkileřimler gösterdiği söylenebilmektedir.

Oluřturulan kümelere bakıldığında 10 adet profil tespit edilmiřtir. Bu profiller öğrencilerin yoğunlukta kullandıkları etkileřimler üzerinden tespit edilmiřtir. Bu tez çalışması sonucunda ařağıdaki sonuçlar görölmektedir:

- Öğrencilerin sistem hareketlerinden kümeleme işlemleri yapılabilir
- Kümelenen veri üzerinden etiketleme işlemleri yapılabilir
- Bu sistemin öğrencilerin profilleri tespit etmede kullanılabilir ve öğrencinin derslerinde yardımcı olunabilir
- Velilere ve öğretmenlere erkenden öğrencinin yönelimi deęiřtięi bilgisi verilebilir
- Öğrencileri ideal öğrenim alanları keřfedilebilir.

Bu çalışmanın gelecekte daha iyi hale gelmesi için öğrencilerin okul sınav sonuçları etiketler ile birleřtirilebilir. Kümelemede modellerin belirli bir başarıyı elde ettięi görölmektedir, ancak iyileřtirmeler yapılabilir. Kullanılan veriler 1 aylığı kapsadığı için 3-4 aylık veriler ile kıyaslanabilir ve öğrencilerin profillerini daha iyi tahmin edilebilir.

KAYNAKÇA

- Akçapınar, Altun, Aşkar. 2016. "Çevrimiçi Öğrenme Ortamındaki Farklı Öğrenci Profillerinin Kümeleme Yöntemi İle Belirlenmesi"
- Aktan, Ertuğrul. 2018 "Büyük Veri: Uygulama Alanları, Analitiği ve Güvenlik Boyutu" Ankara Üniversitesi Bilgi Yönetimi Dergisi 1.1
- Alawi, Shahrane, Jamil. 2023. "Clustering Student Performance Data Using K-Means Algorithms"
- Andreswari, Fauzi, Izzati, Widartha, Dita. 2022. "Students Demography Clustering Based on The ICFL Program Using K-Means Algorithm"
- Arslan ,Kürşat. 2020. "Eğitimde Yapay Zeka ve Uygulamaları", İstanbul
- Atalay , Çelik. 2017. "Büyük Veri Analizinde Yapay Zeka Ve Makine Öğrenmesi Uygulamaları" Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi 9.22, 155-172
- Bae, C. L., ve DeBusk-Lane, M. 2019. "Middle school engagement profiles: Implications for motivation and achievement in science. Learning and Individual Differences," 74, 101753.
<https://doi.org/10.1016/j.lindif.2019.101753>
- BALAT, İsmet. "<https://kerteriz.net/python-numpy-kullanimi-nedir-ve-nasil-kullanilir/> "Wes McKinney "Python for Data Analysis" Data Wrangling with Pandas, NumPy, and Ipython
- Calinski, T., & Harabasz. 1974 "A dendrite method for cluster analysis. Communications in Statistics-theory and Methods", 3(1), 1-27
- Chang, Ji, Liu, Xiao, Che, Liu, Zhou. 2020 "Analysis of University Students' Behavior Based on a Fusion K-Means Clustering Algorithm"
- Çağlayan Akay. 2020. "Ekonometride Yeni Bir Ufuk: Büyük Veri ve Makine Öğrenmesi, İstanbul"

- Davies, Bouldin. 1979. "A cluster separation measure. IEEE transactions on pattern analysis and machine intelligence", (2), 224-227
- Eryılmaz. 2019. "Sanal Öğrenme Ortamlarındaki Öğrenci Davranışlarının Kümeleme Yöntemi ile Analiz Edilmesi"
- Ghazal, Hussain, Said, Nadeem, Hasan, Ahmad, Khan and Naseem, Muhammad. 2021. "Performances of K-Means Clustering Algorithm with Different Distance Metrics"
- Güneş, F. 2017. "Türkçe öğretiminde etkinlik yaklaşımı, Ana Dili Eğitimi Dergisi, Journal Of Mother Tongue Education ADED-JOMTE, 5 (1): 48-64
- Gürsakal, N. 2017. "Makine öğrenmesi ve derin öğrenme. Bursa: Dora Basım"
- Janiesch, Zschech, Heinrich. 2021. "Machine learning and deep learning Machine learning and deep learning"
- Kim, Cho, Kim, Kim. 2023. "Statistical Assessment on Student Engagement in Asynchronous Online Learning Using the K-Means Clustering Algorithm"
- Kurt, Erdem. 2012. "Öğrenci Başarısını Etkileyen Faktörlerin Veri Madenciliği Yöntemleriyle İncelenmesi"
- Kurtuldu, Güçlü. 2010. "Piyano Eğitiminde Planlı ve Eşit Tekrar Çalışmasının Öğrencilerin Başarısı Üzerindeki Etkileri. Elektronik Sosyal Bilimler Dergisi", 9(34):196-204. Retrieved from <https://dergipark.org.tr/en/pub/esosder/issue/6148/82555>
- Legg, S. ve Hutter, M. 2017. A collection of definitions of intelligence. Frontiers in artificial intelligence and applications, 7(157), 17-24.
- Liu, Yang, Liu, Zhang, Chen, Li, Ren, Tian, Wang. 2022. "Use of latent profile analysis and k-means clustering to identify student anxiety profiles"

- Madhulatha. 2012. "AN OVERVIEW ON CLUSTERING METHODS"
- Microsoft. 2023. "Yapay zeka nedir?" <https://azure.microsoft.com/tr-tr/resources/cloud-computing-dictionary/what-is-artificial-intelligence/#how>
- Moubayed, Injadat, Shami, Lutfiyya. 2020. "Student Engagement Level in e-Learning Environment: Clustering Using K-Means"
- Müller, Guido. 2016. "Introduction to Machine Learning with Python"
- Öztürk. 2021." Açık ve Uzaktan Öğrenmede Öğrenenlerin Davranış Örüntülerinin ve Profillerinin Modellenmesi, Akademik Performanslarının Tahmin Edilmesi ve Performans Değerlendirme Panelinin Etkilerinin İncelenmesi", İstanbul
- Purba, Tamba, Saragih. 2018. "The effect of mining data K-Means clustering toward students profile model drop out potential"
- Rousseeuw. 1987. "Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. Journal of computational and applied mathematics", 20, 53-65.
- Sari, Al-Khowarizmi, Batubara. 2021. "Cluster Analysis Using K-Means Algorithm and Fuzzy C-Means Clustering for Grouping Students' Abilities in Online Learning Process"
- Šarić-Grgić, Grubišić, Šerić, Robinson. 2020. "Student Clustering Based on Learning Behavior Data in the Intelligent Tutoring System"
- Şengür, Tekin. 2013. "Öğrencilerin Mezuniyet Notlarının Veri Madenciliği Metotları ile Tahmini"
- Talib, Majid, Sahran. 2023. "Identification of Student Behavioral Patterns in Higher Education Using K-Means Clustering and Support Vector Machine"

Tekke. 2010. “Maslow’un ihtiyalar hiyerarşisinin en son dzeyleri: kendini gerekleřtirme ve kendini ařmıřlık”. Eđitimde Nitel Arařtırmalar Dergisi, 7 (4), 1704-1712. Retrieved from <https://dergipark.org.tr/en/pub/enad/issue/49738/638210>

Yang, D., Cai, Z., Wang, C., Zhang, C., Chen, P. ve Huang, R. 2023. “ Not all engaged students are alike: patterns of engagement and burnout among elementary students using a person-centered approach. BMC Psychology,” 11(1), 38. <https://doi.org/10.1186/s40359-023-01071-z>

Yılmaz, Malik. 2009. “Enformasyon ve Bilgi Kavramları Bađlamında Enformasyon Yönetimi ve Bilgi Yönetimi.” Ankara Üniversitesi Dil ve Tarih-Cođrafya Fakültesi Dergisi 49.1 95-118

