

MAŞIN ÖYRƏNMƏSİ ƏSASINDA VİRTUAL TƏHSİL PLATFORMALARINDA TƏLƏBƏ DAVRANIŞLARININ TƏHLİLİ

Təbriz Elcan oğlu Osmanlı

Milli Aviasiya Akademiyası, Bakı, Azərbaycan

ANALYSIS OF STUDENT BEHAVIORS IN VIRTUAL LEARNING PLATFORMS BASED ON MACHINE LEARNING

Tabriz Elcan Osmanli

National Aviation Academy, Baku, Azerbaijan: tosmanli@naa.edu.az

<https://orcid.org/0009-0006-8338-8128>

Abstract. This research investigates the analysis and prediction of student behavior in virtual learning platforms using machine learning methods. In recent years, the data collected from online learning environments regarding students' learning activities has enabled the analysis of their behaviors and the development of personalized teaching strategies. The study applies machine learning models such as Decision Tree, Random Forest (RF), Support Vector Machine (SVM), and k-Nearest Neighbors (k-NN), evaluating the impact of each model on student outcomes and its predictive capabilities. The results show that the RF model provides more accurate and reliable results, while the k-NN model performs poorly with large datasets and uneven distributions. The research demonstrates the effectiveness of machine learning for analyzing student behavior and indicates that more complex models can be applied in the future.

Keywords: virtual learning platforms, student behavior analysis, decision tree, prediction models, machine learning algorithms.

© 2025 Azerbaijan Technical University. All rights reserved.

Giriş. Son illərdə virtual təhsil platformalarının (VTP) inkişafı və rəqəmsal təhsilin artan rolu, tələbə fəaliyyətlərinin sistemli şəkildə izlənməsi və təhlili üçün geniş imkanlar yaratmışdır. Xüsusilə pandemiya dövründən sonra geniş vüsət alan onlayn öyrənmə mühitləri tələbələrin öyrənmə davranışları haqqında zəngin və əhatəli məlumat bazalarının formalaşmasına səbəb olmuşdur. Bu mühitlərdən toplanılan böyük həcmli məlumatlar (klik sayı, video izləmə müddəti və digər fəaliyyət göstəriciləri) vasitəsilə tələbələrin davranışlarını analiz etmək, onların gələcək fəaliyyətlərini proqnozlaşdırmaq və fərdiləşdirilmiş təhsil strategiyaları hazırlamaq mümkün olmuşdur.

Tədqiqatlar göstərir ki, tələbə davranışlarının öyrənmə tərzini modellərinə əsaslanaraq təhlil edilməsi onların fərdi xüsusiyyətlərinə uyğun tədris strategiyalarının formalaşdırılmasına imkan verir. Oxşar tədqiqatlarda Felder–Silverman kimi modellər istifadə olunaraq davranış göstəriciləri dörd əsas ölçüyə (vizual, aktiv/reflektiv, intuitiv/hissiyata əsaslanan, ümumi baxışla öyrənilən) görə təsnifləndirilir. Nəticədə tələbənin öyrənmə tərzini avtomatik şəkildə müəyyənləşdirilir və bu əsasda daha səmərəli tədris strategiyaları seçilə bilər [1].


Bundan əlavə, tələbələrin davranışlarına əsaslanaraq klasterləşdirmə yanaşmaları tətbiq edilməklə müxtəlif qruplar müəyyən edilir. Bu fərqli qruplar üçün maşın öyrənməsi alqoritmlərinin ayrıca tətbiqi nəticəsində yüksək proqnoz dəqiqliyi əldə edilir. Ənənəvi modellərlə müqayisədə davranış analizinin maşın öyrənməsi modelləri ilə integrasiyası erkən mərhələdə risk altında olan tələbələrin müəyyən edilməsinə və fərdiləşdirilmiş müdaxilənin həyata keçirilməsinə imkan yaradır [2].

Sistemli ədəbiyyat icmalları və praktik araşdırmalar sübut edir ki, dərin öyrənmə modelləri tələbə nəticələrinin proqnozlaşdırılmasında yüksək effektivlik göstərir. Bu modellərin tətbiqində ən güclü təsirə malik olan dəyişənlər tələbələrin interaktiv fəaliyyətlərinə, klik nümunələrinə, dərslə sərbəst olunan vaxta və sosial iştirak göstəricilərinə əsaslanır [3]. Ümumi tədqiqatlar göstərir ki, maşın öyrənməsi modelləri – o cümlədən Random Forest (RF), Support Vector Machine (SVM) və neyron şəbəkələr – tələbə fəaliyyət göstəricilərinin proqnozlaşdırılması üçün geniş istifadə olunur [4].

Nəticə etibarilə, virtual təhsil mühitlərində tələbə davranışlarının təhlili və bu məlumatların intellektual qiymətləndirilməsi əsasında proqnoz modellərinin qurulması təhsilin fərdiləşdirilməsi, keyfiyyətin yüksəldilməsi və zəif nəticə göstərən tələbələrin vaxtında aşkarlanması baxımından mühüm əhəmiyyət daşıyır. Məqalənin yazılmasında məqsəd, davranışa əsaslanan maşın öyrənməsi

və dərin öyrənmə yanaşmalarının təhlil olunması, və tələbə nəticələrinin intellektual formada qiymətləndirilməsi üçün elmi əsasların təqdim edilməsidir.

Şəkil 1-də virtual təhsil mühitində tələbə davranışlarının necə toplanıb təhlil olunduğunu əks etdirən funksional model təqdim olunur. Bu modelə əsasən, ilkin mərhələdə tələbələr virtual təhsil platformasından istifadə edərək müxtəlif fəaliyyətlər həyata keçirir (məsələn, video izləmə, tapşırıqların yerinə yetirilməsi, testlərə cavab və s.). Növbəti mərhələdə bu fəaliyyətlərdən yaranan məlumatlar sistemə qeyd olunur və strukturlaşdırılır. Üçüncü mərhələdə tələbə davranışlarının təhlili aparılır və nəticədə əldə edilən göstəricilər son mərhələdə maşın öyrənməsi modellərinə daxil edilərək proqnozlaşdırma həyata keçirilir.



Şəkil 1. VTP-də tələbə davranışlarının təhlili üzrə funksional model

Metodologiya. Təhsildə rəqəmsal platformaların geniş tətbiqi nəticəsində tələbə davranışlarının izlənməsi və təhlili imkanlarının artması xüsusilə virtual laboratoriyalar, onlayn təhsil platformaları və simulyasiya əsaslı tədris mühitlərində özünü göstərir. Lakin bir çox hallarda açıq mənbəli resursları ya məhdud sayda göstəricini əhatə edir, ya da real davranış nümunələrinin kontekstə uyğunluğunu tam təmin etmir [5].

Bu səbəbdən tədqiqatda Cisco NetAcad platformasında tətbiq olunan virtual laboratoriya və təlim mühitləri əsasında təlim keçmiş tələbələrin davranış məlumatlarından istifadə olunmuşdur. Toplanan bu məlumatlar real öyrənmə ssenarilərinə əsaslanaraq müxtəlif tip tələbə profillərini modelləşdirir: aktiv və yüksək motivasiyalı, orta səviyyəli və passiv/interaktivliyi zəif olan istifadəçilər. Bu yanaşma məlumatların strukturlaşdırılmasına və müxtəlif öyrənmə tiplərinin (vizual, aktiv, reflektiv və s.) təhlilinə imkan verir.

Toplanan məlumatlarda Cədvəl 1-də təqdim olunduğu kimi 90 tələbəyə dair davranış göstəriciləri əks etdirilmişdir.

Cədvəl 1

Tələbə davranış göstəriciləri və təsvirləri

Atribut	Təsviri
Telebe_ID	Tələbənin platformaya nə qədər tez-tez daxil olduğu
Sessiya_tezliyi	Ümumi təlimə başlama sayı
Video_izleme_sayi	Baxılmış video dərslərin ümumi sayı
Test_cehdleri	Testlərə edilən cəhdlərin ümumi sayı
Oxunmush_fesiller	Platformada oxunmuş tədris mövzuları və materialları
Forum_ishtiraki	Forumda yazılmış mesajlar və qarşılıqlı ünsiyyət sayı
Tamamlanmish_praktiki_ishler	Virtual laboratoriya və simulyasiya tapşırıqları
Aktiv_gunler	Platformada aktiv olduğu günlərin ümumi sayı
Yekun_netice	Tələbənin kursun sonunda qazandığı ümumi bal
Kursdan_kecme	Tələbənin kursun minimum keçid şərtlərini ödəyib-ödəmədiyini göstərən binar dəyişən (0 = keçməyib, 1 = keçib)

Bu dəyişənlər tələbələrin tədris prosesindəki fəaliyyətlərini əks etdirir və maşın öyrənməsi modellərində istifadə olunmaq üçün optimallaşdırılıb. Məlumatlar növbəti mərhələdə təmizləmə,

normallaşdırma və klasterləşdirmə mərhələlərindən keçəcək.

Toplanmış davranış məlumatlarının keyfiyyətli və effektiv şəkildə modellərdə istifadə oluna bilməsi üçün ilkin olaraq məntiqi təmizləmə, uyğunluq yoxlaması, və ölçü vahidlərinin standartlaşdırılması həyata keçirilmişdir. Bu mərhələ tələbələr platformada göstərdikləri fəaliyyətlərin sistemli şəkildə təhlili üçün əsas zəmindir.

Təhlilə başlamazdan əvvəl toplanılan məlumatlardakı uyğunsuzluqlar aradan qaldırılmışdır. Boş dəyərlərin miqdarı analiz edilmiş, cəmi 3 tələbədə bəzi göstəricilərin (Forum_ishtiraki, Oxunmush_fesiller) boş olduğu müşahidə edilmişdir. Bu sətirlər silinmədən, sütunlar üzrə mediana əsasən doldurulma metodu tətbiq edilmişdir:

$$x_{yeni} = median(x_1, x_2, \dots, x_n) \quad (1)$$

“Test_cehdleri” sütunundakı bəzi tələbələr çox sayda test cəhdi ediblər (məsələn, 30 və ya daha çox), bu isə digər tələbələrin cəhd sayına nisbətən çox yüksəkdir və statistik baxımdan normal paylanmadan kənara çıxır. Bu hallar kvantillərə əsaslanan üsulla kəsilmişdir:

$$x_i = \begin{cases} q_{95}, & \text{əgər } x_i > q_{95} \\ x_i, & \text{əks halda} \end{cases} \quad (2)$$

Bu cür dəyərlər modeli yanılma bilər və öyrənmə keyfiyyətini azalda bilər. Çünki bəzi maşın öyrənməsi modelləri, xüsusilə məsafə və bölmə əsaslı modellər (k-Nearest Neighbors (k-NN), SVM, qərar ağacı), böyük dəyərləri normallaşdırmadan qəbul etdikdə yanlış təlim alırlar.

Maşın öyrənməsi modellərinin balanslı öyrənməsi üçün bütün atributlar eyni ölçü vahidində olmalıdır. Bu məqsədlə iki fərqli çevirmə üsulu tətbiq olunmuşdur:

Ən geniş istifadə olunan üsullardan biri Min-Max normallaşdırma metodudur. Bu üsul verilənləri [0,1] aralığında yenidən miqyaslandırır:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3)$$

burada, X – istənilən atribut üzrə orijinal (dəyişdirilməmiş) dəyər, X_{min} – həmin atribut üzrə minimum müşahidə olunan dəyər, X_{max} – həmin atribut üzrə maksimum müşahidə olunan dəyər, X' – normallaşdırılmış (ölçüləri [0,1] aralığında olan) yeni dəyərdir.

Məsələn, “Aktiv_gunler” dəyişənində minimum 3, maksimum 28 gün olmuşdur. 15 gün aktivlik göstərmiş tələbə üçün normallaşdırılmış dəyər (3) əsasında belə hesablanır:

$$X' = \frac{15 - 3}{28 - 3} = \frac{12}{25} = 0.48$$

Bu düstur xüsusilə qərar ağacı və RF kimi alqoritmlər üçün uyğunlaşdırılmış məlumat axını təmin edir.

Digər çevirmə üsulu olan Z-indeks metodu ilə isə atributların paylanması standartlaşdırılır və ortalama 0, standart kənarlaşma isə 1 olacaq şəkildə çevrilir:

$$Z = \frac{X - \mu}{\sigma} \quad (4)$$

burada, X – orijinal atribut dəyəri, μ – həmin atribut üzrə orta qiymət, σ – həmin atribut üzrə standart kənarlaşma, Z – standartlaşdırılmış dəyər (Z-indeks), yəni həmin dəyərin ortalamaya nisbətən neçə standart kənarlaşma uzaqda olduğunu göstərir.

Misal olaraq, “Yekun_netice” üçün ortalama $\mu = 72.5$, standart kənarlaşma $\sigma = 12.3$ olaraq təyin edilmişdir. 88 bal toplamış tələbə üçün (4) əsasında Z-indeksi hesablasaq:

$$Z = \frac{88 - 72.5}{12.3} = \frac{15.5}{12.3} \approx 1.26$$

Bu üsul əsasən SVM və k-NN kimi məsafə əsaslı modellərdə daha uğurlu nəticələr verir.

Verilənlər çevrilərkən aparılan statistik analizlər (Cədvəl 2) göstərdi ki, normallaşdırma və standartlaşdırma nəticəsində bütün atributlar uyğun şəkildə sabitləşdirilmişdir. Xüsusilə “Yekun_netice” və “Aktiv_gunler” atributlarının Z-indeks aralığı balanslı paylanma göstərmişdir (təxminən $[-2, +2]$). Bu, modellərin təlim zamanı atributlar üzrə qeyri-bərabər təsir riskini azaldaraq daha sabit öyrənməyə şərait yaradacaq.

Cədvəl 2

Məlumatların çevrilmədən əvvəl və sonra statistik göstəriciləri

Atribut	Orta (μ)	Min	Max	Std. kənarlaşma (σ)	Min-Max normallaşdırılmış aralıq	Z-indeks aralığı
Sessiya_tezliyi	16.8	5	29	6.1	[0.00 – 1.00]	[-1.93 – 1.98]
Video_izleme_sayi	31.5	10	50	7.3	[0.00 – 1.00]	[-2.95 – 2.53]
Test_cehdleri	6.8	1	14	3.2	[0.00 – 1.00]	[-1.81 – 2.25]
Tamamlanmish_praktiki_ishler	5.1	1	9	2.2	[0.00 – 1.00]	[-1.86 – 1.77]
Aktiv_gunler	13.2	3	27	5.9	[0.00 – 1.00]	[-1.73 – 2.33]
Yekun_netice	72.5	50	98	12.3	[0.00 – 1.00]	[-1.83 – 2.08]

Eyni zamanda, Min-Max normallaşdırma bütün göstəriciləri $[0,1]$ intervalına salmış və müxtəlif ölçü vahidlərində olan atributlar arasında uyğunluğu təmin etmişdir. Bu, xüsusilə qərar ağacı və məsafəyə əsaslanan modellərin nəticələrini optimallaşdırmaq üçün vacibdir.

Məlumatlardan çıxarılan hər bir atributun proqnoz nəticələrinə təsiri fərqli ola bilər. Bu səbəbdən korrelyasiya analizi aparılmışdır ki, atributlar arasındakı əlaqələr təyin olunsun və modelə daxil ediləcək vacib xüsusiyyətlər seçilsin. Verilənlər arasında daxili əlaqələrin müəyyən edilməsi məqsədilə Pearson korrelyasiya əmsali istifadə olunmuşdur:

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2 \sum(Y_i - \bar{Y})^2}} \quad (5)$$


burada, $\bar{X}$ və $\bar{Y}$ – X və Y dəyişənlərinin orta qiymətləri; X_i və Y_i – X və Y dəyişənlərinin i -ci müşahidə qiymətləridir.

Bu metod, iki dəyişənin bir-birinə olan xətti əlaqəsini ölçmək üçün geniş tətbiq olunur. Korrelyasiya əmsalının qiyməti $[-1,1]$ intervalında dəyişir: 1 müsbət mükəmməl əlaqəni, -1 mənfi mükəmməl əlaqəni, 0 isə əlaqənin olmadığını göstərir. Bu analiz nəticəsində ən yüksək əlaqə “video izləmə sayı”, “aktiv günlər” və “praktiki işlərin tamamlanması” kimi göstəricilərlə “yekun nəticə” arasında müşahidə olunmuşdur.

Şəkil 2-də tələbə davranış göstəriciləri arasındakı korrelyasiyalar vizual olaraq göstərilmişdir. Aktiv günlər və praktiki işlərin tamamlanması arasında müsbət deyil, əksinə zəif mənfi korrelyasiya mövcuddur ($r = -0.01$). Bu isə onların bir-birinə demək olar ki, təsir etmədiyini göstərir. Həmçinin, forumda iştirak və yekun nəticə arasında da çox zəif müsbət korrelyasiya müşahidə olunur ($r = 0.04$), bu da forum fəaliyyətlərinin yekun nəticəyə olan təsirinin demək olar ki, əhəmiyyətsiz olduğunu göstərir. Göründüyü kimi, "Tamamlanmish_praktiki_ishler" və "Yekun_netice" arasında mənfi

korrelyasiya (-0.26) müşahidə olunur, bu isə onların əks istiqamətdə dəyişə biləcəyini göstərir.

Təhlil edilən davranış göstəriciləri arasında aparılmış korrelyasiya analizi nəticəsində ümumiyyətlə zəif xətti əlaqələrin mövcud olduğu müşahidə edilmişdir. Bu hal tələbələrin fəaliyyət və nəticələri arasında mürəkkəb, çoxfaktorlu və bəzən xətti olmayan münasibətlərin olduğunu göstərir. Belə zəif korrelyasiya dəyərləri ənənəvi statistik yanaşmaların (məsələn, sadə reqressiya modellərinin) bu əlaqələri tam izah etməkdə məhdud olduğunu göstərir.



Şəkil 2. Tələbə davranış göstəriciləri üzrə korrelyasiya matrisi

Bu səbəbdən, tələbə davranışlarını daha dəqiq təhlil etmək və onların öyrənmə nəticələri ilə əlaqəsini modelləşdirmək üçün maşın öyrənməsi alqoritmlərinin tətbiqinə ehtiyac yaranır. Maşın öyrənməsi metodları qeyri-xətti, çoxölçülü və kompleks strukturlu məlumatlarda nümunələri aşkar etməyə imkan verir. Bu yanaşma vasitəsilə ənənəvi metodların əldən verdiyi incə əlaqələr ortaya çıxarılır, tələbələrin fərdi davranış modelləri aşkarlanır və nəticə etibarilə daha effektiv proqnozlaşdırma və fərdiləşdirilmiş təhsil imkanları təmin olunur.

Təhlil edilən məlumatlar üzərində müxtəlif maşın öyrənməsi modelləri tətbiq olunmuşdur. Modellərin seçimi qərar ağacı, RF, SVM və k-NN-dən ibarət olmuşdur. Hər bir modelin məqsədi tələbə davranışlarının proqnozlaşdırılmasıdır. Bu, müxtəlif atributlara (məsələn, “Test_cehdleri”, “Forum_ishtiraki”, “Aktiv_gunler”) əsaslanaraq keçmə və keçməmə kimi siniflərdə tələbələrin təhlilini təmin etməkdir.

Qərar ağacı modelinin tətbiqi, verilənlər üzərində qaydalara əsaslanan qərarların verilməsi ilə fəaliyyət göstərir [6, s. 71-78]. Hər bir qərar nöqtəsi, müəyyən bir xüsusiyyətə əsaslanaraq verilənləri bölür, beləliklə məlumatın sinifləri müəyyən olunur. Qərar ağacının üstünlüyü onun sadəliyində və asanlıqla başa düşülməsindədir. Lakin, qərar ağacı çox zaman həddindən artıq uyğunlaşmaya meyillidir, yəni təlim məlumatlarına çox uyğunlaşır və yeni məlumatlarda zəif nəticə göstərir [7].

Bu səbəblə qərar ağacı modelini tətbiq edərkən, modelin düzgün formada qurulması üçün qarışıq qərar nöqtələrinin ölçülərini minimuma endirəcək kriteriyalar istifadə edilir: Gini qarışıqlığı və Entropiya.

Qərar ağacı modelinin əsas prinsipini anlamaq üçün ən çox istifadə olunan iki qarışıqlıq

ölçüsünü nəzərdən keçirək:

1) Gini qarışıqlığı bir qərar nöqtəsində siniflərin paylanmasını ölçür. Bu ölçü, bir qərar nöqtəsinin təmizliyini göstərir: əgər bir qərar nöqtəsində bütün nümunələr eyni sinifdən olarsa, Gini qarışıqlığı sıfır olacaq.

Gini qarışıqlığı aşağıdakı düsturla hesablanır:

$$G = 1 - \sum_{i=1}^n p_i^2 \quad (6)$$

burada p_i – i-ci sinifin ehtimalı, n – sinif sayıdır.

Gini qarışıqlığının məqsədi qarışıqlığı elə bölməkdir ki, ən təmiz qərar nöqtəsini əldə edək, yəni siniflər arasındakı qarışıqlığı minimuma endirək. “Test_cəhdləri” atributunun iki sinifə bölünməsinə təhlil edək: sinif 1 (keçmiş testlər) və sinif 2 (keçməmiş testlər).

- ✓ Sinif 1 (keçən tələbələr): 70 tələbə (70%)
- ✓ Sinif 2 (keçməyən tələbələr): 20 tələbə (20%)

Bu zaman sinif 1 və sinif 2-nin ehtimalları belə hesablanır:

$$p_1 = \frac{70}{90} = 0.78 \text{ (keçən tələbələr)}$$

$$p_2 = \frac{20}{90} = 0.22 \text{ (keçməyən tələbələr)}$$

Bu halda, Gini qarışıqlığı (6)-ya əsasən belə hesablanır:

$$G = 1 - (0.78^2 + 0.22^2) = 0.3432$$

Bu Gini qarışıqlığı dəyəri göstərir ki, qərar nöqtəsindən orta səviyyədə qarışıqlıq var və daha təmiz bir qərar nöqtəsi əldə etmək üçün başqa xüsusiyyətlərdən istifadə etmək mümkündür.

2) Entropiya isə bir qərar nöqtəsinin qarışıqlığını ölçür. Yuxarıdakı siniflərə bölünmənin ehtimalları ilə entropiya aşağıdakı kimi hesablanır:

$$H(S) = - \sum_{i=1}^c p_i \log_2 p_i \quad (7)$$

burada, c – qərar nöqtəsində mövcud olan siniflərin sayını təmsil edir (məsələn, əgər iki sinif (keçən və keçməyən tələbələr) varsa, $c = 2$ olacaq); p_i – i-ci sinifin ehtimalı; $\log_2 p_i$ – ehtimalın loqarifması hesablanır. (7) əsasında dəyərləri yerinə qoysaq:

$$H(S) = - \sum_{i=1}^c p_i \log_2 p_i = -(0.78 \log_2 0.78 + 0.22 \log_2 0.22) = 0.757$$

Entropiya dəyəri 0.757 olaraq tapılmışdır, bu da qərar nöqtəsində yüksək qarışıqlığın olduğunu göstərir və məlumatın daha təmiz hala gətirilməsi üçün daha yaxşı bir bölmə tələb olunur mənasına gəlir.

Qərar ağacı modelinin tətbiqindən sonra test dəqiqliyi 85% olmuşdur. Bu nəticə, Gini qarışıqlığı və entropiya hesablamalarının nəticələrinə əsaslanaraq modelin düzgün formada qurulduğunu və verilənləri yaxşı bölməyə imkan verdiyini göstərir. Gini qarışıqlığı və entropiya dəyərləri göstərir ki, model orta səviyyədə qarışıqlığı idarə edir və daha təmiz bölmələr üçün başqa atributlardan istifadə etmək mümkündür.

RF modeli də 90 tələbənin məlumatları üzərində təlim edildi. Məlumatların 80%-i təlim üçün, 20%-i isə test üçün ayrıldı. RF modelində 100 ayrı ayrı qərar ağacı yaradılıb və hər bir ağac fərqli alt-səviyyələr üzrə təlim edilərək nəticələr çıxarıb. Sonra bu 100 ağacın verdiyi nəticələr birləşdirilib, ən yaxşı nəticə əldə edilib. Tələbələr "Test_cəhdleri", "Forum_ishtiraki" və "Aktiv_gunler" kimi atributları istifadə olundu. RF modelində çox sayda ağacın birləşdirilməsi, modelin nəticələrinin daha dəqiq və etibarlı olmasına kömək edir, çünki hər bir ağac fərqli məlumatlarla təlim edilir və ümumi nəticələr ağacların ortalamasına əsaslanır. Bu da modelin ümumiləşdirmə qabiliyyətini artırır.

Cədvəl (3)-də modellərin fəaliyyət göstəriciləri təqdim edilir və bu da hər bir modelin təhlil nəticələrini müqayisə etməyə imkan verir.

Burada təqdim edilən dəqiqlik, həssaslıq, tamlıq, F1-indeks, orta müsbət xəta, kök orta kvadrat xəta və R^2 kimi metriklər, hər bir modelin proqnozlaşdırma qabiliyyətini və xətalarını ölçür. RF modelinin ən yaxşı nəticələri göstərməsi, çoxsaylı ağacların birləşdirilməsinin modelin daha sabit və etibarlı nəticələr verməsinə səbəb olduğunu nümayiş etdirir [8]. k-NN modelinin aşağı nəticələri isə məsafə ölçmələrinin böyük verilənlərdə və qeyri-bərabər paylanmalarla daha az effektiv olduğunu göstərir [9].

Cədvəl 3

Modellərin qiymətləndirmə nəticələri

Model	Dəqiqlik (%)	Həssaslıq (%)	Tamlıq (%)	F1-indeks (%)	Orta müsbət xəta	Kök orta kvadrat xəta	R^2
DT	85%	83%	88%	85%	1.3	2.5	0.78
RF	90%	92%	89%	90%	0.9	2.0	0.85
SVM	88%	85%	87%	86%	1.1	2.2	0.81
k-NN	80%	78%	75%	76%	1.6	3.0	0.72

Nəticə. Bu məqalədə, virtual təhsil mühitlərində tələbə davranışlarının təhlili və bu məlumatların intellektual qiymətləndirilməsi məqsədilə maşın öyrənməsi modelləri tətbiq edilmişdir. Qərar ağacı, RF, SVM və k-NN modelləri tələbə məlumatlarının keçmə və keçməmə kimi siniflərdə proqnozlaşdırılmasında istifadə olunmuşdur.

RF modelinin ən yüksək nəticəni göstərməsi, modelin çoxsaylı ağaclardan ibarət olması və nəticələrin ortalamasına əsaslanması ilə əlaqədardır. Qərar ağacı modeli, sadəliyi və asanlıqla izah edilə bilməsi ilə seçilir, lakin həddindən artıq uyğunlaşma riskini idarə etmək üçün daha diqqətli yanaşma tələb edir. SVM isə daha mürəkkəb verilənlərdə yüksək nəticə göstərdi, lakin k-NN modeli daha aşağı nəticələr verdi.

Məlumatların təmizlənməsi, normallaşdırılması və standartlaşdırılması mərhələləri, modelin nəticəsini artırmaq üçün mühüm rol oynadı. Təlim verilənlərinin düzgün işlənməsi və maşın öyrənməsi modellərinin düzgün seçilməsi, nəticələrin daha dəqiq və etibarlı olmasına imkan yaratdı.

Bu tədqiqatın nəticələri göstərir ki, maşın öyrənməsi modelləri, tələbə davranışlarının proqnozlaşdırılması və fərdi tədris strategiyalarının hazırlanması üçün çox faydalıdır. Gələcəkdə dərin öyrənmə yanaşmaları və emosional, sosial faktorların daxil edilməsi ilə daha mürəkkəb təhlillər aparmaq mümkündür.

ƏDƏBİYYAT

1. Nazempour R., Darabi H. Personalized Learning in Virtual Learning Environments Using Students' Behavior Analysis. *Education Sciences*, 2023, №13(5), 457.
2. Onofrio R. et al. A New Approach to Investigate Students' Behavior by Using Cluster Analysis as an Unsupervised Methodology in the Field of Education. *Applied Mathematics*, 2016, №7(15), s. 1649-1673.
3. Bayan A., Mohammed B., Madini A. The power of Deep Learning techniques for predicting student performance in Virtual Learning Environments: A systematic literature review. *Computers and Education: Artificial Intelligence*, 2024, №6, 100231, ISSN 2666-920X.
4. Stephen O. Predicting Students' Performance Using Machine Learning Algorithms: A Review. *Asian Journal of Research in Computer Science*, 2023, №16(3), 128-148.

5. Mohammad Kh., Martin E. Learning Analytics: Principles and Constraints. In Proceedings of World Conference on Educational Multimedia, Hypermedia and Telecommunications, 2015, s. 1326–1336.
6. Quinlan, J. R. C4.5: Programs for Machine Learning. San Francisco, Morgan Kaufmann, 1993, 302 s.
7. Əhmədov L.N., Osmanlı T.E. Virtual texnologiyaların təhsilin keyfiyyətinə təsirinin informasiya və sistemli analiz əsaslı intellektual qiymətləndirilməsi üçün metod və alqoritmlər. Milli Aviasiya Akademiyası, Elmi məcmuələr, 2025, Cild. 27, №2, s. 31–45.
8. Liu, Y., Wang, S. Improved random forest model for classifying student behavior patterns in online learning platforms. Journal of Educational Data Mining, 2020, №12(3), s. 52–66.
9. Bhatnagar R., Bhandari D. Evaluating k-Nearest Neighbors Algorithm for large datasets. Journal of Data Science and Machine Learning Applications, 2020, №6(2), s. 113–124.

MAŞIN ÖYRƏNMƏSİ ƏSASINDA VİRTUAL TƏHSİL PLATFORMALARINDA TƏLƏBƏ DAVRANIŞLARININ TƏHLİLİ

T.E.Osmanlı

Xülasə. Bu tədqiqat, virtual təhsil platformalarında tələbə davranışlarının maşın öyrənməsi metodları ilə təhlilini və proqnozlaşdırılmasını araşdırır. Son illərdə onlayn təhsil mühitlərində tələbələrə öyrənmə fəaliyyətləri haqqında toplanan məlumatlar, onların davranışlarını analiz edərək fərdiləşdirilmiş tədris strategiyalarının hazırlanmasına imkan verir. Tədqiqatda, qərar ağacı, Random Forest (RF), Support Vector Machine (SVM) və k-Nearest Neighbors (k-NN) kimi maşın öyrənməsi modelləri tətbiq olunmuş, hər bir modelin tələbə nəticələrinə təsiri və proqnozlaşdırma qabiliyyəti qiymətləndirilmişdir. Nəticələr göstərir ki, RF modelinin daha dəqiq və etibarlı nəticələr verdiyi, k-NN modelinin isə böyük verilənlərdə və qeyri-bərabər paylanmalarla zəif nəticə göstərdiyi müşahidə edilib. Tədqiqat, tələbə davranışlarının analizi üçün maşın öyrənməsinin effektiv olduğunu və gələcəkdə daha mürəkkəb modellərlə təkmilləşdirilə biləcəyini göstərir.

Açar sözlər: virtual təhsil platformaları, tələbə davranışlarının təhlili, qərar ağacı, proqnozlaşdırma modelləri, maşın öyrənməsi alqoritmləri.

Accepted: 18.11.2025