

Primjena klasterske analize u identifikaciji i analizi poteškoća u nastavi matematike¹

ANGELA BAŠIĆ-ŠIŠKO², IVAN DRAŽIĆ³ I VALENTINO MARKOVIĆ⁴

Sažetak

Hibridni oblici održavanja nastave u kojima se kombinira tradicionalni kontaktni pristup s elementima online učenja sve se češće primjenjuju u suvremenoj nastavi matematike. Takav pristup omogućava zadržavanje socijalnog aspekta tradicionalnog pristupa obrazovanju koji je nemoguće u potpunosti ostvariti online, a s druge strane omogućava primjenu novih tehnologija i metoda poučavanja poput obrnute učionice i sveprisutnog učenja [3].

Svima je jasno da je matematika ključna sastavnica STEM obrazovanja koje se danas smatra pokretačem napretka društva i kao takva zaslužuje najbolje i najmodernije pristupe obrazovanju, a razvoj znanosti i tehnologije zahtijeva sve češće i sve veće zahvate u matematičkom kurikulumu, kako na sadržajnoj tako i na metodičkoj razini. Ono što se događa u industriji, odnosno četvrta industrijska revolucija, mora imati odgovarajući utjecaj na obrazovanje i moderno poučavanje, što je koncept poznat kao Obrazovanje 4.0 [1].

Dok tradicionalni pristup učenju daje vrlo ograničenu količinu podataka o nastavnom procesu, online platforme za e-učenje koje su integralni dio hibridnih kolegija nepresušan su izvor podataka idealnih za različitu vrstu analiza. Većina platformi za e-učenje u sebi ima integrirane alate za obradu podataka, ali najčešće se radi o jednostavnoj statističkoj analizi koja pruža vrlo sužen pogled na stvarno stanje. Štoviše, pojašnjenja dobivenih rezultata ili smjernice nastavnicima za daljnje djelovanje gotovo su nepostojeće. Stoga se i u hibridnoj nastavi dinamička prilagodba pristupa nastavi događa gotovo isključivo na temelju intuicije i subjektivnog doživljaja sudionika, a neka dublja analiza uglavnom je retrospektivna.

¹Predavanje održano na 9. kongresu nastavnika matematike 2022. u Zagrebu

²Angela Bašić-Šiško, Sveučilište u Rijeci, Tehnički fakultet

³Ivan Dražić, Sveučilište u Rijeci, Tehnički fakultet

⁴Valentino Marković, Sveučilište u Rijeci, Tehnički fakultet

Velike količine podataka dostupne u sklopu platformi za e-učenje moguće je efikasno iskoristiti na dobrobit nastavnog procesa korištenjem različitih naprednih metoda obrade podataka [4]. U ovom radu prikazana je upotreba klasterne analize na podacima iz platforme Moodle na kojoj se temelje glavni sustavi za e-učenje u hrvatskom obrazovnom sustavu [2]. Pažnja se pridaje interpretaciji dobivenih rezultata i odgovarajućim smjernicama za postupanje, a naglasak je stavljen na identifikaciju ključnih čimbenika u procesu poučavanja i detektiranje njegovih slabih točaka te pripadno grupiranje učenika u vidu primjene različitih pedagoško-didaktičkih intervencijskih postupaka. Drugim riječima, dobiva se alat kojim vrlo brzo i nadasve objektivno možemo detektirati probleme i poteškoće te odgovarajućim postupcima na njih promptno djelovati, što nesumnjivo poboljšava kvalitetu nastave.

Ključne riječi: klasterna analiza, platforme za e-učenje

Uvod

Suvremeno obrazovanje nužno treba pratiti konstantne društvene promjene, a posebice socijalni, znanstveni i tehnološki napredak. Današnji svijet baziran je na tehnologiji koja je toliko uznapredovala da veći dio populacije mora proći prilično opširno i kvalitetno školovanje kako bi se njome prije svega mogao ispravno koristiti. Slobodno možemo reći da si kao društvo ne možemo dopustiti greške u obrazovanju i da svaki pojedinac koji u sklopu edukacije ne iskoristi svoje urođene potencijale koči razvoj čitavog društva. Sve to govori da se neke ustaljene obrazovne paradigme trebaju mijenjati i osuvremeniti, drugim riječima trebamo se uklopiti u fenomen Obrazovanje 4.0 (eng. Education 4.0), koji je nastao kao odgovor obrazovnog miljea na četvrtu industrijsku revoluciju.

Treba istaknuti i da je situacija u svijetu sve manje deterministička i činjenicu da se sve manje možemo osloniti na neke ustaljene obrasce ponašanja. U prilog tome dovoljno govore još uvijek aktualna pandemija i rat u Ukrajini, na što kao društvo jednostavno nismo bili spremni. Sada je potpuno jasno da današnjim učenicima treba pomoći da se nauče nositi s nepredvidivostima suvremenog života i s događajima u kojima im sva dosad stečena znanja neće biti od neke velike koristi.

S druge strane, neke ustaljene prakse ne treba iz korijenja mijenjati već samo prilagoditi. Tako je primjerice individualizacija nastavnog procesa praksa koja je prisutna u obrazovanju već godinama, posebice na nižim razinama/stupnjevima. Individualizacijom se od svakog učenika može izvući maksimum na način da se nastavni proces usmjeri upravo onim sadržajima i vještinama koje kod učenika stvaraju određene poteškoće. Međutim, individualizacija zahtijeva male obrazovne grupe, a samim time i značajne resurse u obliku nastavničkog kadra, prostora, materijala za rad i slično, kojima sustav oskudijeva. Drugim riječima, možemo reći da smo u procesu obrazovanja naišli na nove izazove s kojima se trebamo naučiti nositi, a pomoć u tome prije svega tražiti u tehnologiji.

Pandemijske okolnosti stubokom su promijenile pristup obrazovanju i dobrim ga dijelom premjestile u virtualno okruženje. S pedagoško-psihološke strane, pristup nastavi kod koje se umanjuje „face-to-face” uvid u studentsku problematiku zasigurno odmiče od tzv. ljudske komponente u nastavi i primiče nas industrijalizaciji nastavnog procesa, što je daleko od nastave kakvoj treba težiti. Ipak, e-nastava nam je dala i jedno neprocjenjivo bogatstvo u vidu ogromne količine podataka o samom nastavnom procesu, koji proizlaze iz niza mjerljivih aktivnosti dostupnih u sustavima za e-učenje. Upravo su te dvije činjenice bile glavni motiv za pisanje ovoga rada. Htjeli smo napraviti održiv hibridni model nastave kod kojeg ćemo prikupljene podatke iskoristiti kako bismo nastavu individualizirali, minimizirali stres i druge negativne pedagoške učinke virtualnog okruženja, a u konačnici i povećali prolaznost na predmetu.

U radu se fokusiramo na kolegij Inženjerska matematika ET druge godine studija elektrotehnike na Tehničkom fakultetu Sveučilišta u Rijeci, ali smatramo da je naš model izrazito robustan te da se može bez većih problema prenijeti i na niže razine obrazovanja.

Inženjerska matematika ET obrađuje sadržaje napredne matematike prilagođene potrebama studija elektrotehnike (Laplaceova transformacija, Fourierova analiza, Vektorska analiza, Krivoljni i plošni integrali, Kompleksna analiza, Uvod u vjerojatnost i statistiku) kroz tri sata predavanja i tri sata auditornih vježbi tjedno te vrijedi 7 ECTS bodova. Glavne komponente ocjenjivanja su klasične, pisani kolokviji te završni pismeni i usmeni ispit, a tijekom virtualizacije, odnosno hibridizacije kolegija uveli smo i tjedne domaće zadaće bazirane na on-line testovima. Upravo je ta posljednje navedena komponenta poslužila kao izvor podataka na kojima se temelji analiza u ovome radu.

Glavni cilj rada bio je ispitati postoje li sličnosti među studentima s obzirom na poteškoće s kojima se susreću i mogu li se prema tim sličnostima sastaviti manje grupe u kojima bi se provodile odgovarajuće didaktičke intervencije.

Metodologija

Klasterska analiza postupak je formiranja grupa u skupu objekata tako da elementi svake grupe budu međusobno sličniji u nekom relevantnom smislu nego što su u odnosu na elemente drugih grupa. Počela se razvijati tridesetih godina prošlog stoljeća kao dio antropologije i psihologije, a danas postoji veliki broj pristupa i algoritama, pri čemu su najpoznatiji hijerarhijsko klasteriranje, k -sredine, neuralne mreže i mnogi drugi. Temeljna ideja svih algoritama za klasteriranje podataka je da su slični objekti međusobno „blizu”, dok je između „udaljenijih” objekata sličnost manje izražena. Glavne značajke klasterske analize su objektivnost prilikom formiranja grupa te automatizirana mogućnost identifikacije postojanja različitih grupa kod većeg broja ulaznih varijabli, a osobito ako se radi o višedimenzijским podacima. Naime, u problemima grupiranja velikog skupa višedimenzijских podataka manualni je pristup podložan subjektivnosti i predrasudama osobe koja obavlja zadatak, a takav je pristup i iznimno neučinkovit, a u slučaju složenijih tipova ulaznih podataka gotovo neizvediv.

Podatke koje je potrebno grupirati prikazuju se uređenim n -torkama (t_1, t_2, \dots, t_n) te one predstavljaju objekte u klasterškoj analizi. Koncept udaljenosti, odnosno blizine među objektima može se definirati na razne načine te se s obzirom na odabrani način mjerenja udaljenosti razlikuju brojni različiti algoritmi. Primjerice, u hijerarhijskom klasteriranju udaljenost između dva objekta mjeri se nekom metrikom definiranom na skupu n -torki, a najčešće se koristi Euklidska (tzv. L_2) metrika.

Hijerarhijsko klasteriranje [5] skupina je pohlepni algoritama koji ima dva osnovna pristupa. U prvom su svi objekti svrstani u jedan klaster koji se zatim rekurzivno dijeli na manje klasterne, sve dok svaki objekt ne čini vlastiti klaster. Nasuprot tome, u drugom pristupu u prvom koraku svaki element čini jednočlani klaster, a zatim se klasteri spajaju po nekom izabranom kriteriju kako algoritam napreduje kroz hijerariju. U posljednjem koraku svi objekti pripadaju jednom jedinom klasteru. Postoje mnogi različiti kriteriji spajanja klastera, a najpoznatiji su:

- Jednostavno klasteriranje: spajaju se ona dva klastera u kojima se nalaze dva elementa koja su najbliža s obzirom na izabranu metriku, a ne nalaze se u istom klasteru.
- Potpuno klasteriranje: spajaju se ona dva klastera koja imaju minimalnu najveću udaljenost svojih elemenata.
- Wardova metoda: klasteri za spajanje biraju se tako da varijanca unutar klastera nakon spajanja bude minimalna.


Hijerarhijsko klasteriranje grafički se prikazuje stablo-dijagramom koji se naziva dendrogram. Listovi stabla predstavljaju klasterne, a visina pojedinog čvora udaljenost među njegovom djecom.

Za provođenje analize u ovom radu korišten je programski paket *Stata 13.0*.

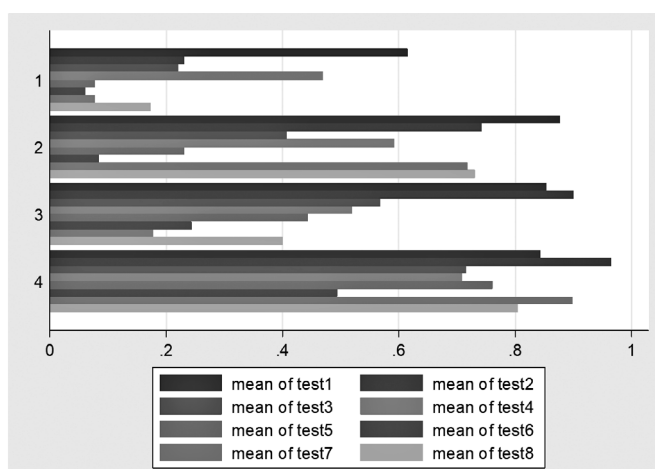
Klasterška analiza na podacima za kolegij Inženjerska matematika ET

U ovom poglavlju prezentiramo rezultate provedene klasterške analize na podacima prikupljenima na kolegiju Inženjerska matematika ET koji se održava na drugoj godini preddiplomskog sveučilišnog studija elektrotehnike na Tehničkom fakultetu Sveučilišta u Rijeci. Analizirani podatci prikupljeni su u zimskom semestru akademske godine 2021./2022. te je ukupna veličina uzorka 64.

Cilj ove analize je na temelju rezultata koje su studenti ostvarili u prvom dijelu semestra (osam online domaćih zadaća i prvi kolokvij) grupirati studente s obzirom na poteškoće s kojima se susreću te u skladu s dobivenim rezultatima za svaku skupinu studenata identificirati točan uzrok problema i osmisliti grupno-specifične postupke koji bi pridonijeli povećanju uspješnosti. Podatci su grupirani u četiri klastera. Pripadni dendrogram prikazan je na Slici 1. U prvom i drugom klasteru nalazi se po 13 (cca. 20 %), trećem 15 (cca. 23 %), a u četvrtom 23 studenta (cca. 37 %).




Slika 1.
Dendrogram
klasterske
analize



Slika 2. Srednje vrijednosti rezultata na domaćim zadaćama za svaki klaster

Kako bismo identificirali specifičnosti svakog klastera, napravljena je deskriptivna analiza na svakom klasteru zasebno. Na Slici 2. prikazane su srednje vrijednosti rezultata na svakoj pojedinoj domaćoj zadaći po klasterima, a na Slici 3. box-plot dijagrami za rezultate prvog kolokvija za svaki klaster.

Na temelju dobivenih podataka moguće je detektirati zajedničke karakteristike studenata u istom klasteru te ih interpretirati u traženom kontekstu. Studenti koji pripadaju prvom klasteru imali su loše rezultate testova na početku semestra, a tijekom semestra postajali su još gori. Rezultati na prvom kolokviju najniži su među svim klasterima te se među njima može uočiti veliko raspršenje. Studenti u drugom klasteru imali su dobre rezultate na početku semestra te pad u rezultatima tijekom semestra nije toliko značajan kao kod studenata iz prvog klastera, ali rezultati na prvom kolokviju gotovo su jednako loši kao i kod prve skupine. Studenti iz trećeg klastera imali su najbolje rezultate na prvom kolokviju, međutim njihovi su se rezultati na domaćim zadaćama tijekom vremena drastično pogoršali. Studenti koji pripadaju četvrtom klasteru imali su konzistentno dobre rezultate na zadaćama i na prvom kolokviju.



Slika 3. Rezultati prvog kolokvija za svaki klaster

Na temelju ovih karakteristika identificirali smo sljedeće poteškoće s kojima se susreću studenti u pojedinom klasteru te smo naveli pripadne prijedloge za djelovanje u cilju poboljšanja rezultata u nastavku semestra. Kod studenata u prvom klasteru jasno je uočljiv pad motivacije tijekom semestra te bi trebalo djelovati na način da se ponovno pobudi njihov interes za kolegij, primjerice poticanje dolazaka na demonstrature i konzultacije te poticanje individualnih razgovora o pristupu učenju. Za studente koji pripadaju drugom klasteru možemo reći da imaju određenih poteškoća s postizanjem dobrih rezultata na kolokviju, vjerojatno stres i strah povezan s uvjetima održavanja kolokvija u učionici u odnosu na domaće zadaće koje su studenti rješavali kod kuće. Za studente raspoređene u treći klaster možemo reći da su s vremenom odlučili sve manje napora ulagati u rješavanje zadaća i posvetiti se pripremi za kolokvij budući da rezultati kolokvija imaju puno veći udio u konačnoj ocjeni. Studente koji pripadaju drugom i trećem klasteru trebalo bi individualno i grupno poticati na redovitost u radu te jačati motivaciju korištenjem suvremenih obrazovnih pristupa kao što je igrifikacija, te naglašavanjem primjena matematičkog gradiva kolegija u njihovoj struci (elektrotehnika). Kod studenata raspoređenih u četvrti klaster nisu identificirane nikakve poteškoće te je kod njih potrebno samo održati postojeću razinu motivacije.

Rezultati

Opisani model proveden je u djelo na istoj skupini studenata. Anketa provedena među studentima na kraju semestra pokazala je da 91 % studenata podržava cjelokupan didaktički koncept kolegija, a čak 66 % izražava snažnu podršku. Studenti su kao najbitnije karakteristike istaknuli komunikaciju s nastavnicima, opuštenu, ali radnu atmosferu, dostupnost nastavnika, video snimki nastave i pisanih materijala. Želimo istaknuti da svega 30 % studenata daje prednost klasičnoj „face-to-face” nastavi u odnosu na virtualnu i hibridnu. Analiza kvantitativnih podataka pokazuje da je 88 % studenata ostva-

rilo pristup završnom ispitu, odnosno imalo barem 50 % ukupno dostupnih bodova na kolokvijima i zadaćama. U prva dva ispitna roka 55 % studenata položilo je kolegij, pri čemu je prosječna ocjena 3,03, a 30 % studenata ostvarilo je ocjenu vrlo dobar i odličan.

Zaključak

Na kolegijima s velikim brojem studenata nastavnica je u praksi nemoguće provesti bilo kakvu individualizaciju u nastavi, što može biti uzrok neuspjeha studenata i male prolaznosti na kolegiju. U ovom radu pokazano je da se klastera analiza može koristiti za detekciju manjih grupa, klastera, studenata na velikim kolegijima. Pojedinom klasteru pridruženi su studenti koji imaju neke zajedničke karakteristike. U opisanom primjeru promatrane se karakteristike odnose na tip poteškoća u ostvarivanju dobrih rezultata na kolegiju s kojima se studenti susreću. Identifikacija manjih grupa studenata koji se susreću sa sličnim poteškoćama pomaže u formiranju grupno-specifičnih pristupa, prilagodbe pedagoško-psiholoških i didaktičkih metoda u nastavi po grupama s ciljem poboljšavanja ispitnih rezultata. Analiza ovog tipa osobito je primjenjiva na kolegije u kojima se koriste platforme za e-učenje budući da je velika količina podataka potrebnih za analizu lako dostupna putem alata platforme.

Na primjeru prikazanom u radu pokazalo se da je za tri od četiri identificirane skupine studenata potrebna intervencija nekog tipa. Budući da su poteškoće identificirane već sredinom semestra (nakon rezultata prvog kolokvija), za očekivati je da akcije poduzete kako bi se studenti motivirali i potakli na promjene u pristupu kolegiju mogu imati značajan pozitivan utjecaj na rezultate ostvarene na kraju semestra.

Provedbom ankete pokazano je da su studenti iznimno zadovoljni realizacijom prezentiranog modela u nastavi, a kvantitativna analiza konačnih rezultata na kolegiju potvrđuje njegovu uspješnost. Na kraju valja napomenuti da je glavni rezultat ovog rada metodologija objektivnog i o edukatoru neovisnog formiranja podgrupa svih studenata na predmetu koja se na isti način može primijeniti na svim razinama obrazovanja, pa tako i na osnovnoškolskoj i srednjoškolskoj.

Literatura

1. Dražić, I., Čotić Poturić, V., Marković, V. (2022.): An example of the process of hybridising a mathematics course at a STEM oriented higher education institution, INTED2022 Proceedings, str. 9243-9247.
2. Dražić, I., Črnjarić-Žic, N., Bašić-Šiško, A. (2022.): Possibilities of applying data-driven algorithms to improve hybrid education systems, INTED2022 Proceedings, str. 9155-9160.
3. Ross, B., Gage, K. (2006.): Global perspectives on blending learning, The Handbook of Blended Learning, Bank, JC, Graham and RC, Eds., str. 155-168.
4. Thille, C., Schneider, E., Kizilcec, R.F., Piech, C., Halawa, S.A., Greene, D.K. (2014.): The Future of Data-Enriched Assessment, Research & Practice in Assessment, br. 9, str. 5-16.
5. Nielsen, F. (2016.): Introduction to HPC with MPI for Data Science, Springer International Publishing Switzerland