INTELIGENTNI SISTEM ZA UPRAVLJANJE PROCESIMA U VISOKOŠKOLSKIM INSTITUCIJAMA

Sažetak: *Izbor prediktivnog modela za rano prepoznavanje studenata u riziku povezuje sposobnost razlikovanja, pouzdanost, interpretabilnost, trošak grešaka i stabilnost s eksplicitnim prioritetima visokoškolske ustanove.*

Centralni doprinos je porodica višekriterijskih modela odlučivanja s početnom i revidiranom konfiguracijom. U početnoj konfiguraciji značenje težina zavisi od raspona kriterijskih vrijednosti u skupu kandidata; ta dijagnoza obrazložila je fiksne referentne vrijednosti u revidiranoj konfiguraciji. Prihvatljivost prethodi poređenju, a postupak predviđa obrazloženi ishod bez preporuke i iskazivanje osjetljivosti preporučenog izbora. Trag omogućava nezavisan izračun odluke iz zabilježenih ulaza. Provjerom početne implementacije zadovoljeni su svi unaprijed određeni kriteriji usklađenosti s deklarisanim postupkom.

U sekvencijalnom istraživanju učestvovalo je 90 studenata završne godine s dodijeljenom ulogom dekana; primarna analiza obuhvatila je 38 koji su prošli provjeru razumijevanja. Nakon strukturiranog iskazivanja vrijednosti kriterija i težina prikazana im je preporuka, a izbori su u prosjeku postali usklađeniji sa zamrznutom referentnom politikom, izvedenom iz procjena tri stručnjaka za mašinsko učenje; dio te promjene zabilježen je prije prikaza preporuke. Primarni test podržao je glavnu hipotezu. U primarnoj analizi smjer je na materijalu bez kasnije utvrđenih nedostataka zadržan, ali je statistički jasan bio samo pod skalom početne konfiguracije.

Retrospektivna računska evaluacija revidirane konfiguracije bez učesnika zabilježila je obrazložen ishod bez preporuke u 3 od 8 evaluacijskih slučajeva: dva u zamrznutoj primarnoj analizi i jedan u unaprijed planiranoj analizi osjetljivosti. Model omogućava transparentan i provjerljiv izbor prema prioritetima; slijedi evaluacija u stvarnom radu ustanove.

Ključne riječi: višekriterijsko odlučivanje, izbor modela mašinskog učenja, rano prepoznavanje studenata u riziku, visoko obrazovanje, vrijednosni prioriteti, inteligentni agent, operativna radna tačka

INTELLIGENT SYSTEM FOR MANAGING PROCESSES IN HIGHER EDUCATION INSTITUTIONS

Abstract: *Selecting a predictive model for the early identification of at-risk students links discrimination, reliability, interpretability, error cost, and stability with the explicit priorities of a higher education institution.*

The central contribution is a family of multi-criteria decision models with an initial and a revised configuration. In the initial configuration, the meaning of the weights depends on the range of criterion values in the candidate set; this diagnosis justified fixed reference values in the revised configuration. Admissibility precedes comparison, and the procedure provides a justified no-recommendation outcome and reports the sensitivity of the recommended choice. The trace allows the decision to be recomputed independently from the recorded inputs. Verification of the initial implementation met all predefined criteria of consistency with the declared procedure.

The sequential study involved 90 final-year students assigned the role of dean; the primary analysis included the 38 who passed the comprehension check. After a structured presentation of criterion values and weights, they were shown the recommendation, and their choices became, on average, more consistent with a frozen reference policy derived from the assessments of three machine learning experts; part of this change was recorded before the recommendation was shown. The primary test supported the main hypothesis. In the primary analysis, the direction was maintained on material without later-identified deficiencies, but it was statistically clear only under the scale of the initial configuration.

A retrospective computational evaluation of the revised configuration without participants recorded a justified no-recommendation outcome in 3 of 8 evaluation cases: two in the frozen primary analysis and one in a preplanned sensitivity analysis. The model enables transparent and verifiable selection according to priorities; evaluation in actual institutional practice is the next step.

Keywords: multi-criteria decision making, machine learning model selection, early identification of at-risk students, higher education, value priorities, intelligent agent, operating point