

# AUTOMATSKO VREDNOVANJE ALGORITAMSKIH ZADATAKA

## *AUTOMATIC EVALUATION OF ALGORITHM TASKS*

Stjepan Šalković, Nenad Sikirica

*Veleučilište Hrvatsko zagorje Krapina, Šetalište hrvatskog narodnog preporoda 6, 49000 Krapina, Republika Hrvatska*

### SAŽETAK

Ishodi učenja algoritama i programiranja najvećim dijelom se usvajaju kroz rješavanje zadataka. Vrednovanje uradaka zahtijeva od nastavnika mnogo uloženog vremena i truda, pogotovo s većim brojem učenika. Važno je da svaki učenik dobije povratnu informaciju kako bi dodatno radio na sadržajima koje nije usvojio. Stoga je poželjno da nastavnik upotrijebi određeni alat kojim može evaluirati rješenja, voditi evidenciju o napretku, te eventualno i analizirati plagijate. U radu su analizirani rezultati vrednovanja učenika prema različitim elementima. Korištene su pisane provjere, automatska evaluacija i usvojenost sadržaja kroz kvizove. Nakon provedenog vrednovanja, uspoređeni su dobiveni rezultati. Vrednovanje po sva tri elementa se razlikuje, ali ne značajno. Raspodjela rezultata u Gaussovoj krivulji je pomaknuta udesno. Taj pomak je nešto veći za automatsko vrednovanje. Ono je provedeno pomoću alata Moodle Virtual Programming Lab i Autogradr.com. Eksperiment na nekoliko različitih cjelina pokazao je prednosti i nedostatke svakog alata. Vrednovanje je objektivno, ali često se kod jednostavnih zadataka događa da su riješeni u potpunosti ili nisu riješeni. Prednost uporabe alata je brza povratna informacija i jednostavno sučelje, a nedostatak je što nema interakcije, djelomična rješenja ne nose bodove, a studenti razmjenjuju gotova rješenja. Automatsko ocjenjivanje zahtijeva promjenu vremenskog rasporeda rada nastavnika. Mnogo više vremena potrebno je za pripremu, no zato se smanjuje vremenska opterećenost prilikom evaluacije. Učenici imaju više povratnih informacija, a vrednovanje i ocjenjivanje je objektivnije. Vrijeme koje nastavnik troši na evaluaciju neznatno raste s većim brojem učenika.

Usprkos uporabi alata, nastavnik je i dalje nezamjenljiv, kako u postupku usvajanja sadržaja, tako i prilikom uvježbavanja i stjecanja vještine rješavanja algoritamskih zadataka. Za vrednovanje rada učenika je poželjno osim automatske evaluacije pratiti napredak učenika i drugim metodama.

***Ključne riječi:*** *Automatsko vrednovanje, algoritam, Virtual Programming Lab, Autogradr*

### ABSTRACT

The learning outcomes of algorithms and programming are mostly adopted through task solving. Evaluating works requires a lot of time and effort from teachers, especially with a larger number of students. It is important for each student to receive feedback in order to further work on content that was not adopted. It is therefore desirable for a teacher to use a specific tool to evaluate solutions, keep track of progress, and possibly analyze plagiarism. The paper analyzes the results of evaluation of students by different elements. I have used written exams, automatic evaluation and quizzes. After the evaluation was over, the results were compared. Results of all three elements is different, but not significant. The distribution of results in the Gaussian curve is shifted to the right. This shift is somewhat higher for automatic evaluation. It was implemented using the Moodle Virtual Programming Lab and Autogradr.com tools. The experiment in several different units showed the advantages and disadvantages of each tool. Evaluation is objective, but often simple tasks are either resolved completely or not resolved.

The advantage is quick feedback and a simple interface, and the disadvantage is that there is no interaction, partial solutions do not carry points, and students exchange solutions. Automatic grading requires a change in the teacher's schedule. Much more time is needed to prepare, but reduces the time spent during the evaluation. Students have more feedback, and evaluation is more objective. The time spent by the teacher on the evaluation is slightly increasing with a larger number of students. Despite the use of the tool, the teacher is still unreplaceable, both in the process of adopting the content, as well as in training and acquiring the skill of solving algorithmic tasks. To evaluate students' work it is desirable to use automatic evaluation, but also to keep track of student progress with other methods.

**Keywords:** *Automatic evaluation, algorithm, Virtual Programming Lab, Autogradr*

## 1. UVOD

### 1. INTRODUCTION

Usvajanje vještine algoritamskog razmišljanja i rješavanja zadataka zahtijeva puno truda i vremena. Osim uporabe udžbenika, predavačke nastave i rješavanja zadataka na vježbama, nužno je da učenik samostalno rješava zadatke. Ukoliko nastavnik želi učenicima dati što više zadataka za samostalno vježbanje, postoji i potreba da se zadaci evaluiraju. Ukoliko nema evaluacije, nema ni povratne informacije i s vremenom učenici sve manje rješavaju zadatke. Posljedično tome, usvojenost znanja i vještina traženih na tržištu je puno manja. Moguća rješenja da nastavnik smanji opterećenje su smanjiti količinu zadataka, procijeniti slučajne uzorke zadataka, uključiti učenike u vrednovanje ili koristiti automatske sustave za vrednovanje zadataka.

Postoji više različitih načina kako koristiti evaluator. Neka od njih zahtijevaju instalaciju i održavanje poslužitelja. Takva rješenja bi od nastavnika zahtijevala dodatni angažman, pa nisu razmatrana u radu. Prema istraživanju Lidije Kralj 78% učenika više se sviđa učiti u virtualnom okruženju i smatraju da će na taj način naučiti više nego na klasičan način[1].

Evaluator uobičajeno radi kao crna kutija kojoj prosljeđujemo ulaze i provjeravamo izlaze. Postavlja se pitanje da li je takav princip dobar za poučavanje[2]. Na natjecanjima se rješenja učenika najčešće ne pregledavaju, no u nastavi je situacija ipak drukčija. Kako nastavnik ima mogućnost pregledati rješenja učenika, problem ipak nije toliko izražen.

Rješenja koja su razmatrana su online alati, odnosno modul koji je dostupan unutar Moodle-a. Naravno, Moodle također netko treba instalirati i održavati. Škole imaju rješenje na način da koriste Loomen, CARNetovu instalaciju Moodle-a koja ima i integriran AAI@EduHr sustav identifikacije i autorizacije. Autogradr je besplatan za uporabu u nastavi, a nastavnik će se pobrinuti kako bi se nastavnici prijavili unutar njegovog tečaja/ razreda.

## 2. VIRTUAL PROGRAMMING LAB

### 2. VIRTUAL PROGRAMMING LAB

Moodle platforma nudi nastavniku otvaranje kolegija kako bi kombinirao s nastavom u učionici ili se sva nastava može prebaciti online. Resursi su nastavni materijali za kolegij koje studenti pregledavaju ili pohrane. To mogu biti dokumenti, poveznice, multimedijске datoteke i slično. Obično nema interakcije s nastavnikom ili drugim učenicima.

Aktivnosti omogućuju interakciju nastavnika s učenicima, te učenicima međusobno. Odabir aktivnosti ovisi o koncepciji kolegija, prirodi sadržaja i procjeni nastavnika kako će najbolje dostići željene ishode učenja.

Virtual Programming Lab (VPL) je sustav za provjeru studentskih rješenja integriran unutar Moodle poslužitelja, a ta rješenja su računalni programi. Rješenje, odnosno računalni program se mora izvršiti kako bi se utvrdilo da li je točno. Izvršavanje i provjeru omogućuje VPL. Zbog sigurnosti se izvršavanje odvija na odvojenom virtualnom poslužitelju, tzv. Jail poslužitelju.

Može se koristiti za zadavanje domaćih zadaća, gdje se može, ali i ne mora koristiti automatsko pregledavanje i ocjenjivanje. Osim toga može se koristiti i za vrednovanje kao online test.



Slika 1 Postavke VPL-a

Figure 1 VPL settings

VPL omogućuje analizu sličnosti rješenja. Na taj način je učenicima u početku jasno da ne bi bilo dobro prepisivati rješenja. Analiza je pouzdanija kod zadataka koji zahtijevaju više koda, jer se u kratkim i jednostavnim zadacima može dogoditi da učenici imaju jako slična rješenja – iako nisu prepisivali.

Učenici dobivaju povratne informacije i mogu pratiti vlastiti proces učenja. Prema provedenim istraživanjima uporaba aktivnosti u sklopu Moodle-a doprinosi povećanju kvalitete i uspješnosti poučavanja, ali i smanjenju opterećenosti nastavnika [2].

## 2.1. POSTAVLJANJE ZADATKA

### 2.1. SETTING TASKS

Aktivnost VPL dodaje se u kolegij slično kao i ostale aktivnosti. Ima svoje ime, opis, vrijeme kad postaje dostupna i rok izvršavanja. U odjeljku ocjenjivanja podešava se broj bodova, ocjena za prolaz i postavke za smanjivanje ocjene nakon zatraženih novih evaluacija.

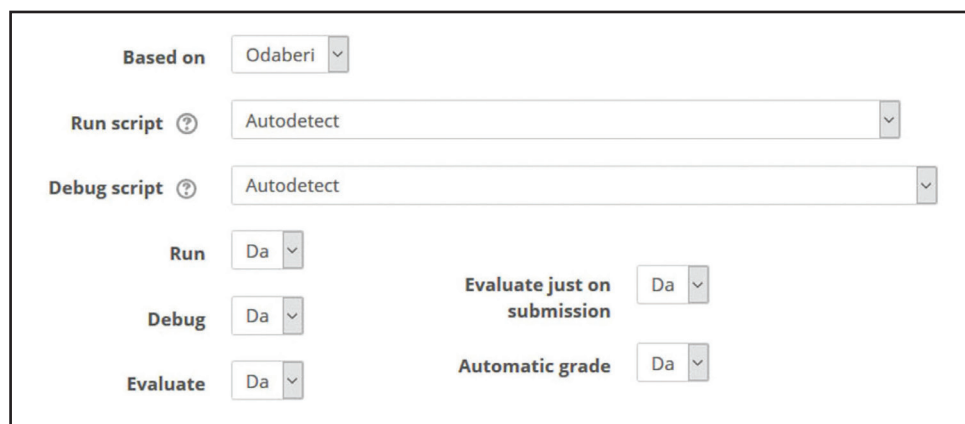
Automatska evaluacija moguća je ako postavimo testne primjere. Blok počinje ključnom riječi case (npr. case=prvi). Slijedi ključna riječ input koja podrazumijeva ulaze na kojima će biti testiran program. Iza ključne riječi output je izlaz koji bi program trebao generirati.

Moguće je koristiti i grade reduction koji označava smanjivanje ukupnog postotka zbog greške. Ako nije zadan, postotak se smanjuje kvocijentom ukupne ocjene i broja testnih primjera.

## 2.2. EVALUACIJA

### 2.2. EVALUATION

Postavka Execution options određuje da li će se rješenje moći pokretati i automatski evaluirati. Može se odabrati skripta za otkrivanje grešaka, i za pokretanje programa. Podržano je mnoštvo jezika: C, C++ (CPP-98, CPP-11, CPP-14, CPP-17), C#, Java, Python (Python 2 i Python 3). Nakon što učenici predaju svoja rješenja nastavnik može pogledati listu rješenja i ocjene.



Slika 2 Opcije evaluacije

Figure 2 Evaluation options

Svakom učeniku može dati povratnu informaciju, kako bi upotpunio proces učenja. Kako VPL podržava mnoštvo jezika te ima fleksibilne postavke, vrijedan je alat za vrednovanje programerskih vještina [3].

### 3. AUTOGRADR

#### 3. AUTOGRADR

Prilikom registracije na AutoGradr, moguća je registracija u svojstvu nastavnika ili učenika. Nastavnik u kontrolnoj ploči kreira tečaj. Tečaj ima kod koji će učenici upisati kako bi mu se pridružili. Na tečaju može biti više nastavnika, a nastavnik može učenicima slati i pozivnicu na mail. Podržani su najčešće korišteni jezici kao C, C++, C#, Python 2 i Python 3, Java, MySQL.

#### 3.1. IZRADA ZADATAKA

##### 3.1. MAKING TASKS

AutoGradr koristi dva tipa pitanja: zadatke (labs) i projekte. Zadaci su pogodni za obradu sadržaja. Sastoje se od manjih individualnih podzadataka. Učenik napreduje kroz gradivo rješavajući zadatke u pregledniku.

Projekt je obično kompleksniji algoritamski zadatak. Učenici rade u razvojnom sučelju koje im odgovara, a predaju gotovo rješenje. Zadaci i projekti se automatski evaluiraju.

Izrada zadataka i projekata je slična. Nastavnik upisuje tekst zadatka i test podatke (test case). Dio test podataka nastavnik ostavi vidljiv, kako bi učenik lakše razumio zadatak. Osim test podataka mogu se koristiti i datoteke.

### 3.2. EVALUACIJA

#### 3.2. EVALUATION

Nakon što učenici predaju zadatke AutoGradr vrednuje rješenja. Učenik će dobiti povratnu informaciju na kojim testnim podacima mu je rješenje radilo. Dio rješenja učenika koji treba pogledati nastavnik označen je, te nastavnik daje i konačni broj bodova.

### 4. ANALIZA VREDNOVANJA

#### 4. EVALUATION ANALYSIS

Sa ciljem usporedbe ostalih načina vrednovanja i automatske evaluacije, napravljena je usporedba ocjena prema različitim elementima. Prvi element bila je usvojenost sadržaja i vrednovana je zadacima objektivnog tipa, uglavnom provedenim kroz kvizove u Moodle-u. Drugi element bile su praktične provjere znanja provedene tako da su učenici pisali rješenja na papiru. Vrednovali su se i djelomično riješeni zadaci. Treći element bila je automatska evaluacija rješenja koje su učenici rješavali za domaću zadaću i tijekom vježbanja.

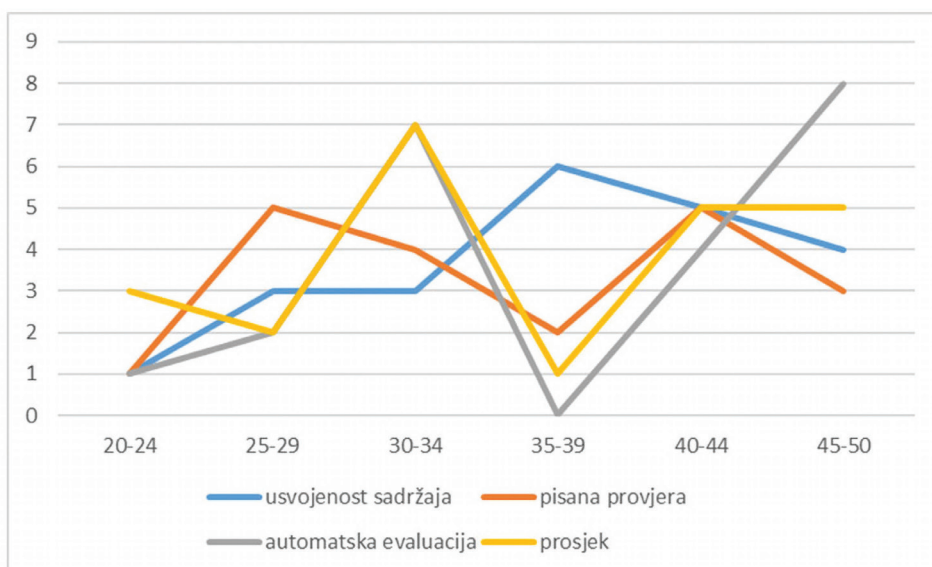
Uzorak na kojem je provedeno istraživanje je grupa od 23 učenika. Raspon bodova za svaki element je od 0 do 50 bodova u promatranom razdoblju.

Slika 4 prikazuje raspodjelu rezultata. Rezultati su grupirani po 5 bodova. Najmanji ostvareni broj bodova bio je 20,3, a najveći 50. Prosječni rezultat bio je 36,3 bodova. Raspodjela se većim dijelom poklapa sa Gaussovom krivuljom, s malim pomakom udesno.



Slika 3 Izrada zadatka u AutoGradru

Figure 3 Making task in Autogradr



Slika 4 Raspodjela rezultata u razredima veličine 5

Figure 4 Distribution of results grouped by 5

Kod automatske evaluacije krivulja je pomaknuta prema desno, odnosno trećina učenika većinu zadataka je uspješno riješila s tek ponekom greškom.

Na slici 5 je vidljivo da se vrednovanje po sva tri elementa uglavnom poklapa. Prosječni rezultat usvojenosti sadržaja je bio 36.4, a medijan 38. Prosječni rezultat pisanih provjera je bio 33.6, a medijan 33. Prosječni rezultat automatske evaluacije bio je 39, a medijan 40.


Kompetencije koje su učenici stekli su na zadovoljavajućoj razini. Rješavanje algoritamskih zadataka dio učenika smatra teškim, no nakon dovoljno vježbanja i uz uloženi trud moguće je postići zadovoljavajuće ishode učenja.

## 5. ZAKLJUČAK

### 5. CONCLUSION

Nakon što se uloži dosta vremena u pripremu zadataka i postavke, VPL i AutoGradr omogućuju automatsko pregledavanje i ocjenjivanje.

Vrednovanje je objektivno, ali često se kod jednostavnih zadataka događa da su riješeni u potpunosti, ili nisu riješeni jer učenik nije pročitao kako treba izgledati izlaz. Kroz kontinuiranu uporabu alata, ovaj problem s vremenom je sve manji. Prednost obaju alata je brza povratna informacija i jednostavno sučelje. Nedostatak je što nema interakcije studenta i nastavnika, djelomična rješenja ne nose bodove, a studenti razmjenjuju gotova rješenja zadataka koji su im dani za vježbanje.



Slika 5 Vrednovanje prema različitim elementima

Figure 5 Evaluation by different types

VPL ima ugrađenu mogućnost traženja sličnih rješenja, dok je u Autogradru ta mogućnost u najavi. Oba alata imaju jednostavno i intuitivno sučelje. Administracija učenika nije zahtjevna.

Analiza vrednovanja automatskom evaluacijom pokazala je da su rezultati ostvareni na taj način bili bolji od rezultata dobivenih pisanim provjerama i provjerom usvojenosti sadržaja. Kako učenici nisu imali ograničeno vrijeme za rješavanje zadataka, te im je bila dostupna literatura i pomoć, dio rezultata nije u potpunosti objektivn. Za pripremu automatskog ocjenjivanja nastavnik treba uložiti značajnu količinu vremena. Kad su jednom pripremljeni zadaci, znatno se smanjuje vremenska opterećenost nastavnika prilikom evaluacije. Učenici dobivaju više povratnih informacija odmah nakon evaluacije. Vrednovanje i ocjenjivanje na ovaj način je objektivnije i ne događa se halo efekt. Vrijeme koje nastavnik troši na evaluaciju raste s većim brojem učenika, ali ne značajno.

Usprkos uporabi online alata, automatskog vrednovanja i bilo kojeg drugog načina uporabe tehnologije, nastavnik je i dalje nezamjenljiv. U postupku usvajanja sadržaja i prilikom vježbanja nastavnik pomaže učenicima koji imaju poteškoća ili pak zadaje dodatne zadatke nadarenima. Time će učenici lakše stjecati vještinu računalnog razmišljanja i programiranja, toliko važnu u rješavanju problema u suvremenom poslovanju. Za objektivno vrednovanje rada učenika je poželjno osim automatske evaluacije pratiti napredak učenika i drugim metodama.

## 6. REFERENCE

### 6. REFERENCES

- [1.] Kralj L.; Učenje i suradnja u virtualnom okruženju za učenje; 2nd International Conference on Advanced and Systematic Research 2008.; Zbornik radova, ur. Cindrić, M.; Domović, V.; Matijević, M.; pp 157-170; ISBN 978-953-7210-12-0; Zagreb; 2008.
- [2.] Skūpienē J.; Automated evaluation of computer programs at undergraduate level: suitability study for competitive events; ISSN 2029-7564, Mykolas Romeris University; 2011.
- [3.] Jugo G.; Matotek I.; Carev M.; Domović D.; Uporaba Moodle-a 2.0 u vrednovanju znanja; Medijska istraživanja 18, br.1; pp 153-163; ISSN 1846-6605; Zagreb; 2012.
- [4.] Thiebaut D.; Automatic evaluation of computer programs using Moodle's virtual programming lab (vpl) plug-in; Journal of Computing Sciences in Colleges 30.6; pp. 145-151; ISSN:1937-4771; 2015.

## AUTORI · AUTHORS

**Stjepan Šalković** - nepromjenjena biografija nalazi se u časopisu Polytechnic & Design Vol. 6, No. 3, 2018.

### Korespondencija

stjepan.salkovic@vhzk.hr

**Nenad Sikirica** - nepromjenjena biografija nalazi se u časopisu Polytechnic & Design Vol. 6, No. 3, 2018.

### Korespondencija

nsikirica@vhzk.hr