

Zdenko Balaž
Tehničko veleučilište u Zagrebu
zbalaz@tvz.hr

Marjan Marino Ninčević
Fakultet hrvatskih studija
mnincevic@hrstud.hr

Marijan Milinović
Sveučilište VERN'
marijan.milinovic@vern.hr

00-00

METODE I ALATI KOGNITIVNE KIBERNETIKE ZA EDUKACIJU TEHNIKE

Sažetak: U radu su prezentirana provedena istraživanja Kognitivnom kibernetikom i konceptom „Big Data“ oslonjenim na „Promethee“ metodu, (Preference Ranking Organization METHod for Enrichment Evaluations), kroz održanu nastavu primjenom novih platformi, alata i metoda vođenog učenja, (Leading/Learning) kompatibilnog s Europskim okvirom digitalnih kompetencija za obrazovatelje. Nastava je održavana pet stručnih predmeta elektrostruke u Strojarskoj tehničkoj školi Fausta Vrančića u Zagrebu, i na kolegiju Inteligentni sustavi Elektrotehničkog odjela Tehničkog veleučilišta u Zagrebu. Promethee metoda služi za višekriterijsko odlučivanje u skupu ponuđenih izbora koji sa svojim značajkama nisu uvijek potpuno definirani. Primijenjena na obrazovanje i edukacije kao sustave s karakteristikama složenosti i prilagodljivosti, učinkovito pomaže u savladavanju gradiva, sjecanju znanja i samostalnim istraživačkim aktivnostima. Analizom više kriterijskog odlučivanja, (MCDA- Multi Criteria Decision Analysis), traganje za rješenjem svodi se na prikaz „ispravne“ odluke među alternativama od kojih se izabire najbolja. Brzo razumijevanje problema, vizualizacijom omogućuje alat Visual PROMETHEE s grafičkom interaktivnom provedbom analize, GAIA, (Graphical Analysis for Interactive Aid). Metode i alati s konceptom totalne integrirane automatike, umjesto teorijskog učenja, na portalima nove generacije inženjerskih platformi i programa, navođenjem od strane edukatora pružaju odlične mogućnosti i kompatibilne su sa STEM, IKT i e-Školskim programima. Stjecanje znanja uz promjene međuljudskih odnosa, pod utjecajem je tehnologija i tehnika koje se stalno razvijaju i mijenjaju. Stoga sve snažniji utjecaj i privrženost zaslonskom okruženju zahtijeva ažuriranje čimbenika stjecanja kompetencija zbog graničnih kaptoloških i disruptivnih integracijskih fenomena čovjeka i tehnologija te se razmatra i nova faza života „zbišnjost“.

Ključne riječi: Leading, Larning, Promethee, metoda, edukacija

Uvod

Na temelju provedenog istraživanja izložene su najnovije spoznaje o čimbenicima stjecanja kompetencija kroz kognitivna rješenja inteligentnih sustava u novim edukacijskim programima. Odabirom kriterija za nove edukacijske programe te njihovom obradom s pozicije edukacije tehnike, postavljeni su okviri za budućnost. Kao kognitivno rješenje inteligentnih sustava za analizu, sintezu i prikaz rješavanja višekriterijskih problema za potrebe novih edukacijskih programa odabrana je i primijenjena PROMETHEE metoda. U procesima stjecanja znanja danas se sve više koriste tehnologije odnosno inteligentni sustavi. Njihova primjena ako nije pod nadzorom zdravog razuma, (*sensus communis*), ne pridonosi razumskim promišljanjima o životnim izazovima koji se potiču STEM programima. Stoga se kao hipoteza u ovom radu postavlja pitanje kako, u kojoj mjeri i koje interaktivne inteligentne tehnologije prihvatiti za uporabu u obrazovanju koje teži edukacijskim programima primjene ITK i e-Škola, povezanih sa stanjem na tržištu rada te uključivanjem kroz edukaciju u sam radni proces. Kako sama kognitivna kibernetika potiče navedene radnje u razvijanju novih znanja i osposobljavanja „inženjera znanja“, pokazalo se pozitivnim primijeniti je u edukacijskim programima spremnim i fleksibilnim za budućnost edukacije tehnike.

Popis kratica

CARNET – engl. *Croatian Academic Research Network* – Hrvatska akademska istraživačka mreža

GAIA – engl. *Geometrical Analysis for Interactive Aid* – Geometrijska analiza interaktivne pomoći

EKO – Europski klasifikacijski okvir

ELO – Elektrotehnički odjel

ERO – Europski referentni okvir

ES – ekspertni sustav

FONK – (*fear of not knowing*) = strah da se nešto neće znati ako se nije uz tehnologije

ICILS – engl. *International Computer and Information Literacy Study* – Međunarodno istraživanje računalne i informacijske pismenosti

ICT – Informations & communication technology

IKT – informacijske i komunikacijske tehnologije

IS – inteligentni sustav

KAPTOLOGIJA – engl. *CAPTOLOGY* (*Computers As Persuasive TechnOLOGY*)

LEADING, LERNING – Metoda vođenog učenja

LKE – engl. *Lean Knowledge Engineers*

MCDA – engl. *Multiple Criteria Decision Analysis* – Metoda analize višekriterijskog odlučivanja

MKN – izraženo u milijunima kuna

MOKSA – metoda obrade, akronim od: Model Opservacije Konvolucijsko Separacijskom Analizom

ONK – Okvirni nacionalni kurikulum

PETAP – pretraživački algoritam, akronim od: Pomoćni Eminentni Tekst Aplikativne Paradigme

PISA – engl. *Programme for International Student Assessment*. – Međunarodni programi ispitivanja znanja i vještina učenika.

PLN – engl. *Personal Learning Network* – osobna mreža za učenje

PROMETHEE – engl. *Preference Ranking Organization METHod for Enrichment Evaluations* – Metoda organizacije rangiranja preferencija za obogaćivanje procjene

STEAM – engl. *Science, Technology, Engineering, Arts and Mathematics* – Znanost, tehnologija, umjetnost, inženjerstvo i matematika

STEM – engl. *Science, Technology, Engineering and Mathematics* – Znanost, tehnologija, inženjerstvo i matematika

STEMTEC - engl. *Science, Technology, Engineering and Mathematics Teacher Education Collaborative*

TIAA – engl. *Teachers Insurance and Annuity Association of America*

TVZ – Tehničko veleučilište u Zagrebu

4E-MODEL – kognicija kao spoznaja: utjelovljena –(engl. *embodied*); enaktivna - (engl. *enactive*); proširena - (engl. *extended*) i ukorijenjena - (engl. *embedded*)

1. Pripreme za istraživanje

Edukacijski inteligentni sustavi i važnosti kolaborativne interakcije s edukatorom promoviraju se svake godine kroz rezultate aktualnog svjetskog istraživanja, „Projekt HOROZON 2017-2021“, koji je usredotočen na četiri načela:

- postavljanje u središte onih koji se educiraju,

- naglašavanje interakcije između inteligentnih edukacijskih sustava i educiranih,
- timski rad i
- istraživanje i razvijanje rješenja za stvarne životne izazove.

Kolaborativno učenje, širina i otvorenost prema različitosti, omogućuje edukatorima da sudjeluju u razmjeni ideja kroz koje prate napredovanje. Iako je trend poučavanja ukorijenjen od samog početka u pedagogiji, danas se on povezuje s implementacijom tehnologija. Raspoloživost usluga temeljenih na servisima iz oblaka, aplikacijama, platformama i drugim digitalnim alatima omogućuje i promiče trajnu povezanost, a raspoložive se tehnologije koriste za savjetovanje, razmjenu podataka i izvedbu koja kontinuirano poboljšava edukacijski proces.

Aktivno učenje učvršćuje sve zajednice znatiželjnih, od učenika, srednjoškolaca, studenata i svih koji su u procesima cjeloživotnog obrazovanja. Kroz zajedničke projekte i prezentacije, otvaraju se zajedničke istraživačke mogućnosti u kojima timovi na čelu s edukatorima istražuju i rješavaju implikacije i tekuće svjetske izazove a sve u cilju razvoja.

Autentičnije inicijative i procjene uz mjere kvalitete i dispozicije ključ su uspješnog zajedničkog učenja koje iako povećava bogatstvo analitičkog učenja ukazuju na potrebe:

- Novih tehnološko prilagođenih zajedničkih prostora za učenje
- Novih modela zajedničkog učenja
- Integracije zajedničkih platformi i alata za efikasnije učenje
- Efikasnog rada u malim grupama
- Prepoznavanja značajki koje podržavaju interkulturalno i pluriperspektivno učenje

Brojni primjeri potvrđuju koliko se daleko otišlo. Značajni izazovi za usvajanje inteligentnih tehnologija u višem obrazovanju potvrđeni su na temelju istraživanja Delphi metodom i razvrstavanjem po prirodi u tri definirane kategorije:

- izazovi koje je moguće razumjeti i riješiti,
- izazovi koji su dobro shvaćeni ali bez rješenja i
- izazovi kompleksni za definiranje koji zahtijevaju dodatne podatke i spoznaje prije mogućih rješavanja.

U tu svrhu razmatra se:

A. Šest značajnih izazova koje će trebati detaljnije razvijati kroz:

1. Poboljšanje digitalne pismenosti
2. Integraciju formalnog i neformalnog učenja
3. Razlike u postignućima
4. Rastući sraz u pristupu digitalnim tehnologijama
5. Upravljanje zastarjelosti znanja
6. Adekvatno prepoznavanje uloge edukatora

B. Šest glavnih razvojnih kategorija inteligentnih tehnologija:

- prepoznavanje govora,
- sučelja osjetljiva na dodir,
- prepoznavanje geste,
- praćenje očiju,
- haptičke tehnologije i
- distribuirana pohrana preko sučelja.

Sve to potvrđuju činjenice i dobro poznate teorije Vygotskog i Illich o resursima za učenje u budućnosti koji su osim nastavnog sadržaja razvijanog kroz kolaborativna ostvarenja za stjecanje kompetencija, isticali umješnost edukatora, [1-2]. Institucije diljem svijeta ponovno preispituju primarne odgovornosti nastavnika i ukazuju na rastuća očekivanja povezana s posljedicama društvenih promjena i evolucijskih modela u kojima su u sve većem postotku nastave angažirani edukatori koji nisu stalni zaposlenici sveučilišta i veleučilišta.

Visoko obrazovanje sve više uključuje aktivnosti koje kroz kolaborativno učenje promiču rješavanje problema angažmanom na aplikativnim projektima personaliziranim i kontekstualiziranim učenjem za obrazovanje utemeljeno na kompetencijama. Znanstvenici kao eksperti više nisu jedini autoritativni izvor

informacija i od njih se ne može više očekivati da praktički pomognu studentima u savladavanju i stjecanju vještina. To moraju uraditi mentori operativni praktičari koji se uspješno služe novim tehnologijama. Kustosi koji su kao akademski obrazovani činovnici, čuvari nekih zbirki, u budućnosti postaju etički čuvari ali i voditelji iskustva u učenju koje potiče studente da bolje razvijaju istraživačke navike, formuliraju dublja pitanja i prepoznaju vrijednost znanja. Potvrđeno je da se tradicionalni modeli fakulteta nakon razdvajanja bolje specijaliziraju, i to odvajanjem nositelja kolegija od mentora. Poticaj da se radi na protu-intuitivan način izazov je za sve jer je na velikom broju sveučilišta pokazano kako razvoj kurikuluma zahtijeva oblikovanje procjena prije sadržaja, [3].

Dokazano je kako je gospodarski prosperitet u razvijenim i zemljama u razvoju ovisan o izgradnji sveučilišta. Kvalificirana radna snaga i njihov tradicionalni obrazovni sustav moraju se razvijati kako bi učinkovitije proizveli diplomante, kreativne i adekvatno pripremljene za rješavanje izazova iz stvarnog svijeta. Za takav učinak stručnjaci su zaključili da je na prestižnim obrazovnim institucijama sve veći broj nastavnika koji radi sa skraćenim radnim vremenom i koji misle više kao projektni menadžeri s iskustvom u tumačenju podataka, praćenju dinamike i upravljanju pitanjima o informacijskim i inteligentnim tehnologijama. Nove vještine tzv. *Enterprise* profesora (profesor iz industrije odnosno poduzetništva) generiraju se iz različitih disciplina koje osim inženjerstva, uključuju ekonomiju, umjetnost, filozofiju i drugo.

Projekt *Horizon 2017 – 2021* koji je uzet kao dobar primjer s naslova angažiranih suradnika jer se tijekom svake godine objelodanjuju ažurirani rezultati istraživanja stručnjaka za obrazovanje i tehnologiju. Njihov je zaključak, unatoč raznolikosti podrijetla i iskustva, da dijele konsenzus da će svaka od profiliranih tema imati značajan utjecaj na praksu visokog obrazovanja širom svijeta u sljedećih pet godina. Postupak odabira tema u izvješću temelji se na modificiranoj Delfi metodi koja je do sada već tijekom pripreme od prije 15 godina uključila više od 2000 međunarodno priznatih sudionika i stručnjaka. U samoj pripremi a tako i danas svake se godine trećina članova zamijeni novima kako bi se osiguravao protok novih perspektiva. U zadanom roku kada se panel za određeno izdanje konstituiru, njihov rad započinje sustavnim pregledom literature - novinskih isječaka, izvješća, eseja i drugih materijala koji se odnose na tehnološki razvoj, trendove i izazove, trenutna istraživanja i još mnogo toga povezanog s edukacijom. Članovima je osiguran ekstenzivni skup pozadinskog materijala kada projekt započne, a zatim se od njih traži da ih komentiraju, identificiraju one koji se čine osobito vrijednima i dodaju prikupljenom materijalu. Nakon pregleda literature, stručni odbor sudjeluje u samom središtu procesa i kroz istraživačka pitanja raspravlja o postojećim aplikacijama i manifestacijama trendova, izazova i tehnoloških napredaka dok istovremeno razmišlja o novima. Ključni uvjet za uključivanje teme u ovo izdanje je njena potencijalna važnost za učenje i kreativno istraživanje u visokom obrazovanju.

Uz Projekt *Horizon* još su dva izvora bila relevantna za pripremu istraživanja. Prvi, Studija pod naslovom *Éducation & société: les défis de l'an 2000*, Éditions La Découverte et Journal Le Monde, koju je objavio u Parizu 1988. godine Jacques Lesourne, direktor *Le Monde*. Izrađena za Francuskog ministra prosvjete koji je tražio da se pokuša uobličiti osnovna pitanja koja valja, srednjoročno i dugoročno, postavljati da bi se pripremila budućnost odgojno-obrazovnog sustava Francuske [4].

Drugi, studija u kojoj Wulf objelodanjuje fascinantne rezultate dvanaestogodišnjeg istraživanja o mimetičkim djelatnostima u socijalnom svijetu koji su povezani s ulogom obitelji, škole, vršnjačkih skupina i medija, a što su čimbenici stjecanja kompetencija. Okvir odabrane institucije bio je UNESCO-ov model škole u Berlinu i dopunsko istraživanje interesnih skupina uz proučavanje komunikacijskih utjecaja kroz masovne medije [5].

Kao zaključak pripreme za istraživanje svih izvora činjenica je kako je potrebno usuglasiti uz socijalni kontekst i pozitivan učinak inteligentnih edukacijskih tehnologija, koje moraju biti vođene zdravim razumom, i načelima kognitivne kibernetike. Takav način edukacije tehnike objedinjuje sve pozitivne učinke inteligentnih tehnologija ali i uzima u obzir i biološko stanje čovjeka, njegovo „sazrijevanje“ kroz određene faze života. Upravo u tome i leži najveći doprinos prepoznatim novim činjenicama za potrebama cjeloživotnog obrazovanja i usavršavanja, empatičnosti prema drugima i emocionalne sigurnosti. Na tim se osnovama može prepoznati nova faza života - zbiljnost koja postaje shvaćeni bitak, s tim da su prepoznate razine zbiljnosti opisane kao:

actus de se est illimitatus – (lat. = *zbiljnost je po sebi neograničena*), tim se izrazom potvrđuje da zbiljnost ne može istovremeno biti i mogućnost. Ograničavajući princip zbiljnosti na određeni način bivovanja jest bit (*esentia*) bića koje se biološki profilira empirijski.

actus essendi – (lat. = čin bivovanja), izraz kojim Toma Akvinski označava metafizičke osnove zbiljnosti bića, odnosno bitka shvaćenog kao zbiljnost. Prema tome biće jest snaga čina bitka i ograničenja vlastite biti koju čovjek može tek spoznati svojom samoaktualizacijom.

lat. **actus et potentia realiter distinguuntur** – (zbiljnost i mogućnost se stvarno razlikuju). To znači da je zbiljnost u prvotnom i vlastitom smislu, dok je mogućnost u ovisnosti o zbiljnosti. Za prepoznavanje te razlike potrebni su i empirija i samoostvarenje.

lat. **actus in se subsistens est simpliciter infinitus** – (subsistentna zbiljnost je po sebi neograničena). Tom se konstatacijom želi kazati kako zbiljnost opstoji bez ikakve mogućnosti (ograničenja, nesavršenosti) i nužno je neograničena i prepoznaje se kao Apsolutno biće.


lat. **actus non limitatur nisi per potentiam** – (zbiljnost nije ograničena osim po mogućnosti). To znači da zbiljnost ne može samu sebe ograničiti, nego to čini mogućnost kao različit princip.


lat. **actus hominis** – (čin čovjeka), čovjekovo djelovanje izvršeno po zakonima ljudske naravi nije uvijek isključiva oznaka ljudskog djelovanja jer je moralno indiferentna.

lat. **actus humanus** – (ljudski čin), čovjekovo djelovanje izvršeno slobodnim samoodređenjem, uporabom slobodne volje pripada čovjeku, kao ljudskom biću, ukoliko proizlazi od razuma i slobodne volje tipično ljudskih sposobnosti, koje ga razlikuju od drugih bića. Kao slobodan čin podliježe moralnoj prosudbi i može biti moralno diferencirana.

lat. **actus purus** – (čisti čin), čista zbiljnost, savršena egzistencija, bez ikakve pasivne potencijalnosti u skolastičkoj filozofiji je bitna oznaka za Apsolutno biće (*ipsum esse subsistens*) i obilježje je najviše ontološke savršenosti čiji se nauk temelji još na Aristotelovoj filozofiji.


Takva razrada kroz filozofski pristup dovodi do postavljene teorije potpune anatomske i funkcionalne razvijenosti čovjeka koja je rezultat „sazrijevanja“ i uz zrelost uvodi novu fazu života, obvezujuću kategoriju nazvanu „zbiljnost“, [6], koja se temelji na prepoznatoj samoaktualizaciji, (samoostvarenju) koje je empirijska cjeloživotna funkcija ali prepoznata u vremenskom ostvarenju, slika 1.





Sl. 1. Faze i godine života od rođenja i programiranja mozga

Kategoriju zbiljnosti koja se afirmira i epistemološki, (teorija spoznaje i nauke) i ontološki potvrđuje metodološki pristup koji uključuje Wilberove heurističke i Chardinove duhovne principe koji se u današnjem vremenu dominacije inteligentnih tehnologija mijenjaju, ali ostaju na čvrstim temeljima Kierkegaardovog egzistencijalizma, slika 2.



Sl. 2. Razrada metodološkog pristupa obrazloženja zbiljnosti

U kontekstu već današnjih a posebice budućih mogućnosti inteligentnih tehnologija stjecanje znanja će postati brže, njegova pohrana sve plića ali raspolaganje njime i njegova moć će se prepoznati tek u zrelosti. Prepoznavanjem stvarnih mogućnosti i učinka inteligentnih tehnologija, prve faze života od djetinjstva preko odrastanja do mladosti će se sve brže mijenjati i drugačije razvijati a vjerojatno i principi smisla edukacije koji su danas prepoznati i oslonjeni na:


1. Motivacijske potrebe Abrahama Maslowa, [7],
2. Enkulturu vlastitog identiteta kroz programiranje mozga, Brucea Liptona, [8] i
3. Teoriju obrazovanja Vittorina Andreolia, [9].

Kroz teorije zrelosti u biološkom i psihološkom smislu, koja se promatra kroz stupanj potpune ili relativne razvijenosti nekog procesa, sposobnosti ili funkcije, ona ima svoje aspekte, i to:

1. fizički,

2. seksualni,
3. intelektualni,
3. emocionalni,
4. moralni i
5. socijalni.

Današnji pojmovi „sazrijevanja“ i „zrele“ ličnosti nužno su pod utjecajem sociokulturnih čimbenika i vrijednosti. Ti su čimbenici u teorijskim i empirijskim razmatranjima o zrelosti naročito u psihološkom smislu dokazano potvrđeni i vezani za životnu dob, učenje i stjecanje znanja kroz sve godine života, kroz način na koji se osoba nosi s krizom te kako donosi važne odluke. Susan Peters je pokazala da se izvor psihološke zrelosti očituje kroz roditelje, a Freud je ustvrdio da puna životna zrelost nastupa s čovjekovim trajnim vezivanjem uz jednu profesiju kao i uz jednog životnog partnera. Upravo je to izravno povezano uz koncept odgovornosti te sposobnost odgađanja zadovoljstva. Naime, zrela osoba zna da se za svako istinsko dobro treba potruditi i biti strpljiv, a danas to postaje problem, jer snažni utjecaj privrženosti zaslonском usmjerenju graniči fenomenima ovisnosti kao što su: 1. FONK – (engl. *fear of not knowing*) = strah da se nešto neće znati ako se nije uz tehnologije, 2. FOMO – (engl. *fear of missing out*) = strah da će se nešto propustiti ako se one ne koriste, 3. YOLO – (engl. *you only live once*) = uvjerenje kako se samo jednom živi, 4. OHEN – (engl./lat. *only hic et nunc*) = opsjednutost životom koji je samo sada i ovdje i sl. Sve to ukazuje na ...“integriranost s vanjskim svijetom i situaciju u kojoj je iskustvo ljudskih života zasjenjeno posredno iskustvom izvješćivanja, objavljivanja i dobivanja povratnih informacija o nama samima“ [10]. To potvrđuju teorije o oblikovanju mozga, tj. kako kroz godine života na određene dobne skupine utječu inteligentne tehnologije, [11-12], slika 3.



Sl. 3. Godine života i utjecaj inteligentnih tehnologija na mozak, (Spitzer, Demarin)


Snažni utjecaj privrženosti zaslonском usmjerenju koji osim što graniči fenomenima ovisnosti pod neposrednim je kaptološkim utjecajem koji dovodi do integrativnosti čovjeka i tehnologije koja neupitno utječe na reprogramiranje mozga koji zrcali evoluciju, [13-15], slika 4.

PARAMETRI INTEGRATIVNOSTI ČOVJEKA I TEHNOLOGIJE

Osjećaj jedinstvenog bića	Subjektivno stanje mozga	Promjena identiteta	Kompulzivno ponašanje kao osobina ovisnosti
• Subjektivnost našeg neposrednog iskustva • Objektivno neuroznanstveno objašnjenje • Potpuna funkcionalnost uma • Prethodna stajališta i iskustva za shvaćanje zbivanja u okruženju			
• Ontogeneza zrcali filogenezu – razvoj ljudskog mozga zrcali evoluciju • Prefrontalni korteks kod ljudi postaje potpuno zreo i funkcionalan tek u ranim dvadesetim • „Razmišljanje je kretanje ograničeno na mozak“ • Sve misli dijele zajednički niz uzroka i posljedica: početak, sredina i kraj, (bez obzira radi li se o nadi, sjećanju logičnom argumentu, poslovnom planu ili žaljenju) • Emocije su usredotočenost na nešto što se osjeća upravo sada i samo sada • Svjesna misao se širi dalje od neposrednosti trenutka • Obrada informacija je odgovarajuća reakcija na podražaj • Razumijevanje zahtjeva da se podražaj uključi u konceptualni okvir, (razvoj veza između moždanih stanica koje se formiraju nakon rođenja te ih cijelog života potiču, oblikuju i jačaju pojedina iskustva za stjecanje znanja, mudrosti i umnosti „DIJAGNOSTIČKO STATISTIČKI PRIRUČNIK MENTALNIH POREMEĆAJA (DSM-5), 2013. “Poremećaj korištenja interneta“			

Sl. 4. Parametri integrativnost čovjeka i inteligentnih tehnologija uz opaske iz Dijagnostičko statističkog priručnika mentalnih poremećaja

Stoga u postupku pripreme za istraživanje koje je u osnovi prepoznavanje edukacije tehnike leži njezin učinak a to su čimbenici stjecanja kompetencija. U Hrvatskoj preuzet i preveden dio materijala iz tzv. Europskog referentnog okvira, (ERO) navodi kako kompetencije usvojene tijekom obveznog obrazovanja nisu, i ne bi trebale biti, vezane za određeni predmet već se one odnose na šire međupredmetne ciljeve i time predstavljaju poveznicu od poučavanja prema cjeloživotnom učenju za koje je izdvojeno i definirano sedam međupredmetnih tema: 1. Osobni i socijalni razvoj, 2. Učiti kako učiti, 3. Građanski odgoj i obrazovanje, 4. Zdravlje, 5. Poduzetništvo, 6. Uporaba informacijske i komunikacijske tehnologije i 7. Održivi razvoj. Prema dostupnim materijalima Europski kvalifikacijski okvir, (EKO) predlaže podjelu ključnih kompetencija prikazanih kroz njihov profil, nadopunjen čimbenicima stjecanja, slika 5.



Sl. 5. Kompetencije, prema EKO i čimbenici stjecanja kompetencija

Edukacija tehnike odabrana za razmatranje, provedbu analize i donošenje zaključaka prepoznata je u edukacijskim programima tzv. projekta škole za život i svodi se na, [16-17]:

1. Uporabu IKT-a (informacijske i komunikacijske tehnologije) u nastavi,
2. STEM edukacijski program i
3. Edukacijski program e-Škole.

IKT nisu samo sredstva u nastavi, najčešće dobivena IKT oprema, već i baze podataka i baze znanja koje se pune provedbom radionica i webinarima što utječe na podizanje kvalitete edukacijskog sustava kroz

primijenjene tehnike. IKT kao uspostava centraliziranog, jedinstvenog i standardiziranog sustava za informatizaciju edukacije, poslovanja i praćenja svih procesa. Na razini web aplikacija pristupa je omogućen kroz internetske preglednike i nije potrebna instalacija aplikacije na računala. Pristup je moguć s bilo kojeg mjesta koje ima internetsku vezu (on-line). Korisnici ne moraju brinuti o tehničkim rješenjima jer im je osigurana tehnička i korisnička podrška a posebna značajka sustava je i mogućnost korištenja cijelog sustava ili samo pojedinih modula ovisno o potrebama.

STEM edukacija interdisciplinarni je način učenje četiri područja (prirodne znanosti, informatika, inženjerstvo i matematika) koji ima svoju mjerljivu i jasnu primjenu. Za razliku od školskog obrazovanja koje je podijeljeno na predmete, STEM edukacija obuhvaća rješavanje određenog problema koristeći znanje iz navedenih područja čime se potiče učenje koje obuhvaća činjenice, nego uporabljivo znanje. Stoga se iz STEM sadržaja može uporabiti samo jedan način rješavanja ako problem pripada skupini prirodnih znanosti (u akronimu S – „Science“), ili primjena znanja iz ostalih „slova akronima“: **Technology, Engineering, Mathematics**). U STEM obrazovanju ključni su edukatori, učitelji koji poznaju metodiku STEM-a, kako bi bili osposobljeni samostalno osmišljavati i za edukaciju prilagođavati STEM sadržaje. Za to je potreban sustavan, temeljit i dugogodišnji rad ali i jasna vizija.

e-Škole su sustavno i redovito korištenje najmodernije tehnologije u učenju i poučavanju, adekvatna infrastruktura i moderna računalna oprema kao i raspoložive brojne razvijene e-usluge za nastavne i poslovne procese te niz edukacija za razvoj digitalnih kompetencija kako edukatora tako i onih koje oni educiraju. Stupanj integracije digitalne tehnologije u život i rad škole vrednuje se konceptom *Digitalne zrelosti* koji se provodi početnim samovrednovanjem i vanjskim vrednovanjem. Program e-Škole cjelovita je informatizacija procesa poslovanja škola i nastavnih procesa u svrhu stvaranja digitalno zrelih škola za 21. stoljeće oslonjen na Europski okvir digitalnih kompetencija za obrazovatelje (DigCompEdu), znanstveno utemeljen okvir koji je izradio i objavio Zajednički istraživački centar Europske komisije (Joint Research Centre), a opisuje što znači biti digitalno kompetentan obrazovatelj te pruža referentne smjernice za razvoj digitalnih kompetencija specifičnih za učitelje, nastavnike i druge vrste obrazovatelja u Europi. DigCompEdu namijenjen je obrazovateljima na svim razinama obrazovanja, od ranog i predškolskog odgoja i obrazovanja, do visokoškolskog obrazovanja i obrazovanja odraslih, uključujući osnovnoškolsko, srednjoškolsko i strukovno obrazovanje te obrazovanje učenika s teškoćama u razvoju, ali i neformalne oblike obrazovanja, [18].

1.1. Provedena istraživanja

Na osnovama izloženog i u namjeri primjene provedena su istraživanja, u Strojarskoj tehničkoj školi Fausta Vrančića u Zagrebu, (šk. god. 2019/2020.), [19] i na Elektrotehničkom odjelu, Tehničkog veleučilišta u Zagrebu, (ak. god. 2019/2020 i 2020/2021.), [20-21], tijekom:

- 1) nastave licem u lice, odnosno personaliziranom korespondencijom s učenicima za pet elektrotehničkih srednjoškolskih predmeta od drugog do četvrtog razreda,
- 2) nastave licem u lice za redovne i izvanredne studente kolegija Inteligentni sustavi veleučilišnog stručnog i specijalističkog diplomskog studija,
- 3) nastave nakon pojave pandemije koronavirusa, prijelazom na online za redovne i izvanredne studente kolegija Inteligentni sustavi veleučilišnog stručnog i specijalističkog diplomskog studija,
- 4) deset mentorstva diplomskih radova na veleučilišnom studiju, (ELO TVZ), i
- 4) edukacije cjeloživotnog usavršavanja licenciranih specijalista, tablica 1.

Tablica 1. Pregled istraživanja tijekom srednjoškolske i veleučilišne nastave i cjeloživotnog obrazovanja

Ustanova Institucija /Polaznici	ELO -TVZ ¹ redovni studenti kolegija IS ²	ELO -TVZ izvanredni studenti kolegija IS	ELO -TVZ diplomanti kolegija IS	STŠ-FV ³ učenici II- IV razreda, pet el. teh. predmeta	AEROING ⁶ polaznici cjeloživotno usavršavanja
Broj polaznika	55(2020) 18(2021)	47(2020) 69(2021)	16 ⁴ , 5 ⁵	142	25
Satnica	30h predavanja i	30h predavanja i	30h ⁴ /60h ⁵ konzultacija	8h predavanja i 12h vježbi tjedno	30h ^{4/5} predavanja i 30h ⁴ /60h ⁵ vježbi

	30h vježbi	60h ⁵ vježbi			
Način provedbe	F2F ⁴	OnL ⁵	F2F/OnL	F2F	F2F/OnL
Način provjere	5-min test/vježba	5-min test/vježba	5-min konzultacije diplomskog rada	5-min test	5-min test
Ishod-Učinak %	100%	80%	100%/50%	100%	75%

¹ – Elektrotehnički odjel, Tehničko veleučilište u Zagrebu

² – IS = Kolegij Inteligentni sustavi

³ – Strojarska tehnička škola Fausta Vrančića u Zagrebu


⁴ – F2F = provedba licem u lice

⁵ – OnL = provedba Online

⁶ – AEROING d.o.o. Specijalizacija cjeloživotnog usavršavanja za ELO TVZ

Istraživanja su na veleučilištu provedena s jedne strane primjenom novih platformi, alata i metoda za stjecanje znanja vođenjem od strane edukatora, (*Leading/Learning*), [20-21], a s druge strane praćenjem njihovog samostalnog rada uporabom „*PROMETHEE*“ metodu, (*Preference Ranking Organization METHod for Enrichment Evaluations*), [22-23]. Svi su savladavali vještinu donošenja odluka sa skupa ponuđenih izbora s više kriterija programskom analizom više kriterijskog odlučivanja, (*Multi Criteria Decision Analysis - MCDA*), pronalazili su najbolja rješenja, odnosno donosili najbolje odluke iz ponude više alternativa. Odluke su vizualizirali pomoću alata *Visual PROMETHEE*, i to kreacijom grafičkog prikaza analize, (*Graphical Analysis for Interactive Aid - GAIA*). Metode i alate koji su dostupni u ažuriranim besplatnim demo verzijama na Internetu studenti su samostalno pronašli, savladali korištenje i kroz vođeno učenje stjecali znanje i kompetencije i uspješno izradili svoje seminare i diplomske radove na osnovama navođenja i poticanja.

Srednjoškolci obuhvaćeni ispitivanjem, pomoću naputka nastavnika su iz pripremljenih podloga na aplikativnim IKT platformama *Logo Soft Comfort*, *Bascom* i *Arduino* kroz vježbe u praktikumu na STEM strategijama savladavali u nastavnim predmetima konkretnu problematiku razumijevanja logičkih sklopova. Upućivanjem na primjenu algoritama i alata totalne integrirane automatike, umjesto teorijskog učenja, na portalima nove generacije inženjerskih programa, kroz prilagođeno okruženje uz pomoć *Promethee* metode razvijali su, uređivali i pratili logike potrebne za upravljanje aplikacijama. Komercijalni instalirani ali i aplikativno razrađeni portali programske tehnologije u intuitivnom korisničkom sučelju omogućavaju navigaciju i brzo prepoznavanje željenih funkcija programiranja i uređivanja. Prema pripremljenim podlogama i vođenju učenja zadaci se svode na izradu i obradu baza podataka na osnovama mogućnosti inteligentnih sustava kognitivne kibernetike i to kroz razine kognitivne analize do kibernetičke sinteze. Kroz vođenje, edukator na osnovama ekspertnosti, raspoloživosti i angažiranosti poučava i upućuje na odabir uzorka. Cijeli se postupak oslanja i kroz njega se usvaja proces *Delfi metode* koja je u osnovi povezana na donošenje odluka i model je za kreaciju ekspertnog sustava. U tekstualno pretraživačkim procesima se koristi originalno razvijeni alat *PETAP* – akronim od: *Pomoćni Eminentni Tekst Aplikativne Paradigme*, [24]. U procesima uvida i primjene strategija koristi se originalno razvijeni model *MOKSA* - akronim od: *Model Opservacije Konvolucijsko Separacijskom Analizom*, [25]. Rezultati kao Prikaz nalaza koriste se po Modelu strojnog učenja preko Ocjenjivača i Generatora opetovanja, slika 6.



Sl. 6. Kognitivna i kibernetička operabilnost za Leading/Learning model stjecanja znanja

2. Prijedlog strukture provedbe poučavanja na osnovama kognitivne kibernetike


2.1. Kolaborativna provedba nastave

Na prethodno izloženom za Sveučilište VERN, za planirani početak izvođenja tri nova sveučilišna preddiplomska studija:

- 1) Cyber komunikacije i znanost o mreži,
- 2) Internet stvari i
- 3) Transmedijska dramaturgija,

načinjen je prijedlog kolaborativne provedbe nastave za transformirani kolegij Ugradbeni sustavi na Inteligentni sustavi i Kognitivna kibernetika, opširno razrađeno u [26], slika 7.

Kolaborativni je model izrade seminarskih radova studenata organiziranih u seminarske timove proširen uz voditelja s još dvije nove funkcije: 1. demonstratora i 2. kustosa seminarskog tima. Na taj je način seminarski rad finaliziran kao autorsko prezentacijsko i debatno djelo. On priskrbljuje u sveučilišne privatne, (ali komercijalno dostupne baze), programe, alate, metode i algoritme iz koji se kreiraju baze podataka i baze znanja za učenje i zaključivanje, a što je sve u funkciji stjecanja kompetencija. Za model provedbe Lead-In/Learning nastava koja može biti oči u oči ili On-Line, odgovoran je edukator profila PraKMEZ – *Praktičar, Kustos, Mentor, Ekspert i Znanstvenik*, [1 i 3].



Sl. 7. Blok prikaz pripreme kolaborativne provedbe novih studijskih programa Sveučilišta VERN

2. 2. Sudionici i uloge u poučavanju na osnovama kognitivne kibernetike

Kolaborativni način poučavanja kao inovacija producira znanje kao resurs i prepoznaje da stjecatelji znanja, koji teže stjecanju kompetencija, (učenici, studenti,...) posjeduju svoje tri dimenzije:

- racionalnu – inteligentna sposobnost shvaćanja i rješavanja problema
- emotivnu – sreća koja se ne ostvaruje proračunato
- društvenu – sposobnost komuniciranja s drugima

Za razvoj znanja kroz poučavanje poučavatelji, (treneri, edukatori, učitelji,...), moraju posjedovati dimenzije: autoriteta, svetosti uloge, karizme, sudjelovanja kroz psihologiju situacije, užitka poučavanja, tehnika sporazumijevanja, i kompetentnosti, [27-29]. Kroz te dimenzije moguće je prenositi znanje prepoznate primjene, tzv. aplikativno znanje što podrazumijeva da je u procesu stjecanja znanja postignut

kontinuitet koji je osnova za stjecanje kompetencija, [30]. Upravo zbog potrebe postizanja kontinuiteta pojavljuje se apsurd kada se u stjecanje znanja uključe inteligentne interaktivne tehnologije zbog učinka fragmentiranosti i prisile, [31]. Njihov je pak persuazivni učinak jedna strana medalje a druga strana medalje je kognitivni potencijal, mozak kao hardver i um kao softver, koji je kako je prethodno naznačeno podložan programiranju/reprogramiranju, [32-35].

Fragmentirani um, kako ističe Andreoli (2009) napreduje u djelićima, bez čvrstih veza, spojenih pukim asocijacijama po podudarnosti, čudesnim simboličkim spletovima, ali ujedno sasvim nasumičnih, a to treba izbjeći kako je potvrđeno u [9]. Kognitivna kibernetika to prepoznaje u svim računalnim simulacijama kreiranim inženjerskim modeliranjem primjenom računalnih alata. S jedne strane to je velika prednost budući se matematički modeli i simulacije učinkovito provede na računalu, ali s druge strane se postavlja pitanje kakav to učinak ima u stjecanju znanja. Ukratko u teoriji sustava, za dinamičke sustave osnova je princip kauzaliteta, odnosno uzročno-posljedične veze. Taj je dio teorijske osnove potrebno savladati kroz nastavno gradivo i povezati ga s Wienerovom teorijom sustav. Svaki sustav ili njegove komponente koji može biti bilo koja prepoznatljiva cjelina ili samo dio neke cjeline određen je u svakom trenutku vremena svojim izlaznim veličinama, ulaznim veličinama i oblikom njihovih promjena. Za matematičke metode inženjerskog modeliranja potrebno je:

1. Odabrati pretpostavke i aproksimacije koje će rezultirati što jednostavnijim, ali dovoljno točnim modelom s obzirom na svrhu modeliranja
2. Razlaganje sustava na elementarne komponente u skladu s polaznim pretpostavkama i aproksimacijama
3. Matematičko formuliranje fizikalnih zakona koji određuju uzročne posljedične veze između ulaza i izlaza definirati na osnovama:
 - a) determinizma, tj. da isti uzroci uvijek izazivaju iste posljedice i
 - b) kontinuuma, tj. da su zadržana infinitezimalna fizikalna svojstva.

Prilikom matematičkog modeliranja osim osnovnih pretpostavki, (koje se najčešće podrazumijevaju), u svakom se pojedinačnom slučaju uvodi i niz drugih pretpostavki i aproksimacija kojima se ostvaruje kompromis između točnosti i složenosti modela. Od matematičkog modela sustava očekuje se da u nekom obliku sadrži jednoznačnu i dovoljno točnu informaciju o funkcijama $i_1(t)$, $i_2(t)$, $i_3(t)$, ..., $i_r(t)$ po kojima se izlazi mijenjaju od početnog stanja sustava pa nadalje ako se ulazi od početnog trenutka pa nadalje mijenjaju po proizvoljno zadanim funkcijama $u_1(t)$, $u_2(t)$, $u_3(t)$, ..., $u_p(t)$. Stoga se može sažeti postupak modeliranja u koracima:

1. Definiranje svrhe modela
2. Intuitivna analiza zbivanja u sustavu
3. Razlaganje modeliranog sustava na elementarne komponente
4. Definiranje pretpostavki i aproksimacija
5. Izvođenje modela
6. Definiranje modela stacionarnog stanja sustava
7. Provjera modela

U koracima modeliranja prepoznaje se poveznica s Promethee meodama na vrlo jednostavan i slikovit, (vizualiziran) način. Definiranje konteksta, isto je što i definiranje svrhe modela, odnosno identificiranje dostupnih mogućnosti, što odgovara intuitivnoj analizi zbivanja u sustavu. Na isti se način povlači analogija učinka i primjena kognitivne kibernetike kao i pomoć računalnih simulacija i uporabe računalnih alata, metoda, modela sustava i procesa u stjecanju znanja, [6].

3. Novi edukacijski programi

3.1. Nacionalni kurikulum

Programi, neovisno o području i sadržaju koji pokrivaju u edukaciji, imaju svoje uporište u Nacionalnom kurikulumu, [36]. Nacionalni kurikulum Republike Hrvatske predstavlja sustav koji služi ujednačavanju i podizanju kvalitete odgojno-obrazovnoga procesa te ispunjavanju zajednički određenih

odgojno-obrazovnih ciljeva, očekivanja i ishoda neovisno o odgojno-obrazovnoj ustanovi koju djeca i mlade osobe pohađaju. Nacionalni kurikulum Republike Hrvatske čine tri sastavnice:

1) Sustav nacionalnih kurikulum dokumenata – kroz njega se, na nacionalnoj razini, iskazuju nastojanja povezana sa svrhom, ciljevima, očekivanjima, ishodima, iskustvima djece i mladih osoba, s organizacijom odgojno-obrazovnoga procesa i s vrednovanjem

2) Primjena nacionalnih kurikulum dokumenata – u suštini, ono što je prikazano dokumentima se ostvaruje na nacionalnoj razini

3) Vrednovanje – unutar ove sastavnice vrši se evaluacija ciljeva, očekivanja, ishoda i procesa, čime se prati primjena i izvedba namjera iskazanih nacionalnim kurikulum dokumentima

Svaki od nacionalnih kurikulum dokumenata oblikovan je, i ima u fokusu središnjeg sudionika odgojno-obrazovnog procesa, djeteta i mladu osobu. Tako su kroz kurikulum dokumente, odmah od početka, jasno prikazana odgojno-obrazovna očekivanja i ishodi koja su postavljena pred njih. No, ne odnose se ta očekivanja i ishodi samo na njih, već i na roditelje, ali i na odgojno-obrazovne radnike. Svi kurikulum dokumenti imaju jasnu i konciznu strukturu, no to ne znači da nisu otvoreni prema promjenama. Baš naprotiv, ako potreba djece i mladih osoba to iziskuje, pristupa se prilagodbi sukladno potrebnim promjenama. Također, promjene spomenutih dokumenata mogu nastupiti i radi potreba ustanova kao odgovor na utjecaj novih znanstvenih i tehnoloških spoznaja u području odgojno-obrazovne prakse.

Okvir nacionalnog kurikulumuma (ONK) je krovni nacionalni kurikulum dokument, koji na općoj razini određuje elemente kurikulum sustava za sve razine i vrste do visokoškolskoga odgoja i obrazovanja. ONK čini osnovu po kojoj se izrađuju svi nacionalni kurikulum dokumenti za pojedine razine i vrste odgoja i obrazovanja, a njegove postavke također utječu i na izradu ostalih nacionalnih kurikulum dokumenata, kao i dokumenata izrađenih na ostalim razinama.

Nacionalni kurikulum za pojedine razine i vrste odgoja i obrazovanja određuju se svrha, vrijednosti, ciljevi i načela određenih dijelova sustava odgoja i obrazovanja i čine ga:

- Nacionalni kurikulum za rani i predškolski odgoj i obrazovanje
- Nacionalni kurikulum za osnovnoškolski odgoj i obrazovanje
- Nacionalni kurikulum za strukovno obrazovanje
- Nacionalni kurikulum za gimnazijsko obrazovanje
- Nacionalni kurikulum za umjetničko obrazovanje

Nacionalni dokumenti područja kurikulumuma koristimo se za određivanje svrha, ciljeva, struktura i odgojno-obrazovnih očekivanja povezanih s učenjem i poučavanjem u širim odgojno-obrazovnim područjima. Ovi dokumenti izravno utječu na izradu predmetnih i modularnih kurikulumuma.

Nacionalni kurikulum međupredmetnih tema služimo se za potrebe determiniranja svrha, ciljeva, struktura, odgojno-obrazovnih očekivanja, učenja i poučavanja, ali i za vrednovanje određene međupredmetne teme.

Nacionalni kurikulum nastavnih predmeta određuju svrhu i ciljeve učenja i poučavanja nastavnoga predmeta, zatim strukture pojedinog predmeta u cijeloj odgojno-obrazovnoj vertikali, potom odgojno-obrazovne ishode, pripadajuće razrade i opise razina usvojenosti ishoda, kao i učenje i poučavanje te vrednovanje u pojedinom nastavnom predmetu.

Nacionalni sektorski/podsektorski kurikulum te kurikulum za stjecanje kvalifikacije u redovnome sustavu strukovnoga i umjetničkoga obrazovanja određuju se za pojedini sektor/podsektor, odnosno specifičnu kvalifikaciju. Njihov sadržaj determinira svrhe, ciljeve, organizaciju odgojno-obrazovnoga procesa, učenje i poučavanje te vrednovanje povezano sa strukovnim obrazovanjem u određenome sektoru/podsektoru.

Okvir za vrednovanje procesa i ishoda učenja u odgojno-obrazovnome sustavu Republike Hrvatske, Okvir za poticanje i prilagodbu iskustava učenja te vrednovanje postignuća djece i učenika s teškoćama i Okvir za poticanje iskustava učenja i vrednovanje postignuća darovite djece i učenika predstavljaju nacionalne kurikulum dokumente kojima se osiguravaju rješenja koja se sustavno ugrađuju u sve nacionalne kurikulum dokumente, a odnose se i na kurikulum dokumente izrađene na ostalim razinama.

Posebni nacionalni kurikulum određuje svrhu, ciljeve, očekivanja, ishode i organizaciju odgojno-obrazovnoga procesa i vrednovanje za pojedine posebne oblike odgoja i obrazovanja, [37]. Nacionalni kurikulum kao edukacijski program sadržan je i u međupredmetnim temama uz preporuku uporabe IKT (informacijske i komunikacijske tehnologije) u nastavi.

3.2. Međupredmetne teme - Sadržaji programa

Međupredmetne teme su teme općeljudskih vrijednosti i kompetencija za život u 21. stoljeću i kao takve su na poseban način svakodnevno prisutne u odgojno obrazovnom radu cjelokupne obrazovne vertikale. Oblikuju se međusobnim povezivanjem odgojno-obrazovnih područja i nastavnih tema svih nastavnih predmeta. U Europskom referentnom okviru navodi se kako kompetencije usvojene tijekom obveznog obrazovanja nisu, i ne bi trebale biti, vezane za određeni predmet. Objašnjava se kako se zapravo odnose na šire međupredmetne ciljeve i time predstavljaju poveznicu od poučavanja prema cjeloživotnom učenju. Izdvojeno je i definirano sedam međupredmetnih tema:

1. Osobni i socijalni razvoj
2. Učiti kako učiti
3. Građanski odgoj i obrazovanje
4. Zdravlje
5. Poduzetništvo
6. Uporaba informacijske i komunikacijske tehnologije
7. Održivi razvoj

3.3. Analiza, sinteza i prikaz rješavanja višekriterijskih problema u edukaciji

Kriteriji vrednovanja novih edukacijskih programa

Prema [38], odabrani edukacijski programi za analizu, kao edukacija i tehnika obuhvaćaju:

1. Uporabu IKT (informacijske i komunikacijske tehnologije) u nastavi, kao Nacionalni kurikulum i edukacijski program sadržan i u međupredmetnim temama,
2. STEM edukacijski program i
3. Edukacijski program e-Škole.

Kod analize kriterija za vrednovanje pojedinih programa prilikom procesa donošenja odluke vodi se sljedećim značajkama:

- upoznatost s trenutnom situacijom (razlozi, trenutno stanje stvari, koga obuhvaća i slično),
- poznavanjem mogućnosti i cilja,
- ispravno analizirati značaj pojedinog kriterija i odabrati najsvrsishodniji
- izračunom diferentnih vrijednosti (rezultat više odražava stav donositelja odluke nego li ispravnost kriterija)

Proučavanjem i analizom navedenih edukacijskih programa odabrani su kriteriji algoritmom PETAP, [24], sa svojim težinskim faktorima, tablica 2. i 3.

Proračun programa – predstavlja predviđen iznos potreban za uvođenje određenog edukacijskog programa izraženog u milijunima kuna (MKN)

Lokacijska mogućnost izvođenja programa – utvrđen je kao kvalitativni kriterij koji se iskazuje vrijednošću na skali od 1 do 5, s tim da broj 1 označava nedovoljno dobru mogućnost, broj 2 označava dovoljno dobru

mogućnost, broj 3 označava dobru mogućnost, broj 4 vrlo dobru mogućnost, te konačno broj 5 izvrsnu mogućnost. Kako u Republici Hrvatskoj nisu u svim dijelovima države jednaki uvjeti za izvođenje nastave, opremljenost škola, mogućnost Internet konekcije u školi i izvan škole, ovim se kriterijem utvrđuje, sukladno zahtjevima programa, njegova ostvarivost na globalnoj razini države

Mogućnost iskorištavanja nepovratnih sredstava – kvalitativni financijski kriterij povezan s program koji odražava njegovu povezanost s iskorištenim nepovratnim sredstvima iz EU fondova. Kao i prethodni kriterij, izražen je skalom od 1 do 5 s istim opisima uz brojeve u danoj skali

Primjena na svim obrazovnim razinama – također kvalitativni kriterij. Povezan je s primjenjivosti programa na svim razinama obrazovanja počevši od rane dobi pa skroz do studija. Isto je iskazan skalom od 1 do 5 s ranije utvrđenim opisima uz pojedini broj na skali

Autentičnost programa – kriterij koji pokazuje preklapanje jednog programa s ostalim, postojećim programima. Izražava se u postotcima, s tim da se teži što manjem postotku koji ukazuje na originalnost navedenog programa odnosno njegovu autentičnost

Tablica 2. Kriteriji i njihove mjerne jedinice

Kriterij	Mjerna jedinica/Skala
Proračun programa	Milijuni kuna (MKN)
Lokacijska mogućnost izvođenja programa	Skala 1-5
Mogućnost iskorištavanja nepovratnih sredstava	Skala 1-5
Primjena na svim obrazovnim razinama	Skala 1-5
Autentičnost programa	Postotak (%)

Tablica 3. Kriteriji i dodijeljene težine

Kriterij	Težina kriterija
Proračun programa	25
Lokacijska mogućnost izvođenja programa	15
Mogućnost iskorištavanja nepovratnih sredstava	20
Primjena na svim obrazovnim razinama	25
Autentičnost programa	15

Obrađenim izabranim kriterijima dodjeljuju se težinske vrijednosti. Težinske vrijednosti predstavljaju stavove donositelja odluke, pri tome da je veća težina dana kriteriju koji ima izravni utjecaj na primjenu edukacijskog programa, dok je niža težina dana kriteriju koji ne utječe izravno na sam odabir edukacijskog programa, ali daje značajan doprinos procesu odabira najpovoljnijeg (po stavu donositelja odluke) od razmatranih.

Težinska vrijednost kriterija se promatra kao postotak i ne ovisi o mjernoj jedinici ili skali. Viša težinska vrijednost kriterija predstavlja ujedno i veću vrijednost samog kriterija. Za dodijeljene težinske vrijednosti moraju se odrediti i značajka maksimiziranja ili minimiziranja radi ispravnosti i točnosti podataka i analize. One značajke koje negativno utječu na proces donošenja odluke se minimiziraju i težnja je da one budu što niže, kao što je to proračun programa. Isto tako, pozitivne značajke se maksimiziraju s težnjom za što većom vrijednošću. Primjer je mogućnost iskorištavanja nepovratnih sredstava. S tim se zapravo pokazuje o kakvom je parametru riječ (preferencija ili indiferencija).

Prikaz rješavanja višekriterijskog problema

Unos kriterija i njihovih vrijednosti u programski paket Visual PROMETHEE, prati se na početnom zaslonu programske podrške, slika 8. Unesene vrijednosti su presjeci kriterija i alternativa, koji se temelje na podacima dobivenim proučavanjem navedenih edukacijskih programa.


		☒	☒	☒	☒	☒	
	Edukacijski progra...	Proračun	Lokacijska m...	Mogućnost is...	Primjena na ...	Autetntičnos...	
	Unit	MKN	Opisna ocjena	Opisna ocjena	Opisna ocjena	%	
	Cluster/Group						
	Preferences						
	Min/Max	min	max	max	max	min	
	Weight	25,00	15,00	20,00	25,00	15,00	
	Preference Fn.	V-shape	Level	Level	Level	V-shape	
	Thresholds	absolute	absolute	absolute	absolute	percentage	
	- Q: Indifference	n/a	1,00	1,00	1,00	n/a	
	- P: Preference	50,00 KN	2,00	2,00	2,00	2	
	- S: Gaussian	n/a	n/a	n/a	n/a	n/a	
	Statistics						
	Minimum	167,00 KN	3,00	4,00	3,00	10,00	
	Maximum	307,00 KN	4,00	5,00	4,00	20,00	
	Average	224,67 KN	3,33	4,33	3,67	15,00	
	Standard Dev.	59,76 KN	0,47	0,47	0,47	4,08	
	Evaluations						
☒	Upotreba IKT		200,00 KN	Vrlo dobro	Vrlo dobra	Vrlo dobra	10,00
☒	STEM program		167,00 KN	Dobro	Izvrсна	Vrlo dobra	20,00
☒	e-Škole		307,00 KN	Dobro	Vrlo dobra	Dobra	15,00

Sl. 8. Visual PROMETHEE, početni zaslon

Odabirom potpunog ili parcijalnog rangiranja, (engl. *PROMETHEE Rankings*), dobivaju se dvije vrste grafičkih prikaza, PROMETHEE I i PROMETHEE II, metode koje prezentiraju realne i relevantne informacije, a temelje se na:

- ukupnom toku Φ i
- usporedbi pozitivnog (Φ^+) i negativnog (Φ^-) toka.


Usporedbom tokova, kod PROMETHEE I, kod zahtjevnih slučajeva su naglašene alternative koje su teške za usporediti pa je to odmah uočljivo, slika 9.



Sl. 9. Visual PROMETHEE, prikaz rangiranja


Pregledom grafova vidljivo je kako najveću težinu ima STEM edukacijski program, dok edukacijski program e-Škole ima najmanju, te je samim time na začelju rangiranja. Iz navedenog i prikazanoga može se zaključiti kako bi edukacijski program STEM bio najprihvatljiviji budući da po zadanim kriterijima iskazuje najbolje rezultate.

Uvidom u alternativni dvodimenzionalni prikaz dobivenih rezultata, (tzv. dijamantni prikaz), sve su alternative prikazane točkama u ravnini pozitivnog i negativnog toka, a ukupni tok je prikazan „visinom“ alternative (sjecištem vertikale), Slika 10.




Sl. 10. Visual PROMETHEE, „dijamantni prikaz“

Kao što je to bio slučaj rangiranja i „dijamantni prikaz“ potvrđuje edukacijski program STEM kao najbolju alternativu, budući da ne postoje preklapanja alternativa sva tri edukacijska programa su usporediva. Ako se alternative brojčano prikažu, pomoću vrijednosti ulaznog i izlaznog toka, dobiva se tzv. mrežni graf, pregled koji se sastoji od strelica i čvorova, slika 11.



Sl. 11. Visual PROMETHEE, mrežni graf

Vizualni uvid u rezultate potpunog rangiranja kroz slojevite i zasebno prikazane doprinose odabranih kriterija moguć je tzv. duginim grafom koji koristi vizualni prikaz parametara ukupnog toka s prezentacijom pozitivne i negativne strane svake alternative, slika 12.



Sl. 12. Visual PROMETHEE, dugin graf


Slika 12. kroz dvije boje prikazuje pozitivne i negativne komponente promatranih edukacijskih programa (gornje dio grafa obuhvaća pozitivne dok donji dio negativne karakteristike alternativa). Komponente označene zelenom bojom odnose se na kriterije koji su vezani za financijski aspekt edukacijskih programa, a žutom bojom su označeni oni kriteriji koji su povezani s edukacijskim aspektom programa. Nastavno na to, uvidom u grafikon, može se vidjeti kako je STEM edukacijski program onaj koji ima najviše pozitivnih karakteristika, dok je edukacijski program e-Škole ocijenjen kao program s najviše negativnih karakteristika. Isto tako, iz grafikona se može uvidjeti kako je s edukacijske strane gledano program Upotreba IKT onaj s najviše pozitivnih karakteristika, no kako se u razmatranje mora uzeti aspekt financija, to čini STEM program najbolje ocijenjenim.

Tablični prikaz rezultata s pozitivnim, negativnim i ukupnim toka, najjednostavnija je usporedba koja daje samo poredak ali ne i prikaz kriterija i alternativa, slika 13.

PROMETHEE Flow Table					
Rank	Edukacijski program		Phi	Phi+	Phi-
1	STEM program		0,1794	0,2075	0,0281
2	Upotreba IKT		0,0737	0,1563	0,0825
3	e-Škole		-0,2531	0,0094	0,2625

Sl. 13. Visual PROMETHEE, tablični prikaz


Prikaz rezultat preko koordinatnog sustava u tri perspektive, (tzv. „GAIA“ prikaz, engl. *Graphical Analysis for Interactive Aid*) ima za svrhu donositelju odluka ukazati na sličnosti (razlike) alternativa, međusobne konflikte (podudarnosti) kriterija te njihov utjecaj na rangiranje. Shodno tome, alternative su prikazane kao žuti kvadratići, kriteriji su prikazani osima (zelene osi su kriteriji povezani s financijskim aspektom programa, a žute osi su kriteriji povezani s edukacijskim aspektom programa), a težina kriterija je prikazana (crveno) tzv. osi odluke (engl. *Decision Axis*), slika 14.



Sl. 14. Visual PROMETHEE, GAIA graf, tri perspektive


Što je manja udaljenost između određenih alternativa, to je njihova sličnost veća. Dalje, smjer osi kriterija ukazuje na njihove sličnosti i razlike. Kriteriji istog usmjerenja (i iste boje) se međusobno podupiru, dok različiti smjer označava konflikt, odnosno karakteristiku po kojoj financijski ili edukacijski aspekt nije od glavnog interesa. Također, duljina samih osi kriterija nije značajna već je značajnija lokacija alternative u odnosu na sam smjer kriterijske osi. Tako npr. za donositelja odluke edukacijski program „Uporaba IKT“ imao bi najveću težinu ako bi se smatralo kako je Autentičnost programa najznačajniji kriterij.

Multikriterijski kategorizirani prikaz snaga i slabosti alternativa, (tzv. graf profila alternativa) omogućava uvid u snage alternativa, (gornji dio grafa) i slabosti, (donji dio), slika 15. Pregledom alternativa može se vidjeti kako je edukacijski program e-škole onaj s najviše slabosti, pa bi se iz toga dalo zaključiti kako bi se donositelj odluka morao odlučiti za uklanjanje slabosti da bi se bazirao na taj edukacijski program, odnosno morao pristupiti njegovom unapređivanju.



Sl. 15. Visual PROMETHEE, profili alternativa


Interaktivni uvid u raspodjelu težinskih kriterija i rezultat njihovog utjecaja na alternative, (engl. *walking weights*), omogućuje prikaz pojedinih fiksiranih kriterija uz promijene drugih tako da se može promatrati trenutni utjecaj na alternative, slika 18. Prilikom određivanja/promjene težinskih kriterija može se provjeravati njihov utjecaj. Npr. ako se težinski kriteriji koji nisu povezani s edukacijskim aspektom programa smanje, (prema nuli) za posljedicu se trenutno prikazuje povećanje preostalih težinskih kriterija, kao i promjena odnosa pozitivnih i negativnih komponenti alternativa. Na slici 16. je lijevo prikazano stanje prije, a desno stanje poslije smanjivanja, a gornji dio slike prikazuje utjecaj na rezultat.



Sl. 16. Visual PROMETHEE, uz promjene težinskih kriterija

Detaljan prikaz utjecaja promjene težine pojedinačnog kriterija na alternative dobiva se pomoću grafa intervala stabilnosti, (engl. *visual stability intervals*), slika 17. Može se uočiti kako edukacijski program e-Škole prednjači u odnosu na STEM program samo ako kriterij Proračun, ne igra veliku ulogu,

odnosno ako je u biti zanemariv. Također, ista stvar se odnosi i na program Uporaba IKT ukoliko je težina kriterija proračuna manja od 14%. U ostalim slučajevima, kako se težina kriterija (proračun) povećava, edukacijski program STEM postaje sve značajniji, [39-42].



Sl. 17. Visual PROMETHEE, intervali stabilnosti

3.4. Kompleksnost problematike edukacije tehnike

Savladavanje i primjena Promethee metoda u višekriterijskim odlučivanjima posebice s razradom uz pomoć aplikacije "Decision Lab", način je učenja i poučavanja kao edukacija tehnike na osnovama umjetne inteligencije, [43-45]. Brojni su primjeri, koliko je edukacija tehnike za stjecanje kompetencija, naročito došla u centar pozornosti kada se potvrdila nužnost primijene metoda online života u trenutnim pandemijskim okovima, [46-45]. Također se otvorilo pitanje budućnosti uz cyberpsihologiju, [47] i persuzivne tehnologije.

Paradigma COVID-19, pokazala je kako je umjetna inteligencija već danas a posebice će doći do izražaja u bliskoj budućnosti, nezamjenjiva komponenta u svim sferama života, učenja, stjecanja i primjene znanja. Provedena istraživanja, priprema i razrada nužno su nametnula potrebu za filozofskim pristupom kako bi se dosadašnje teorije potpune anatomske i funkcionalne razvijenosti čovjekova „sazrijevanja“ odnosno zrelosti kao faze života, proširile na obvezujuću kategoriju nazvanu „zbiljnost“ koja postaje shvaćeni bitak koji je nužan za kompetencije.

Postizanjem brzine informiranja, maksimalne prezentacije djelotvornosti i učinka znanosti u borbi kao i integriranosti paradigme COVID-19 u egzistencijalnu ovisnost, nove su informacijske tehnologije, postale vladavina za koju sve više do izražaja dolazi potreba ukazivanja na disruptivnu komponentu. U svim sferama života predominantna obuzetost koronavirusom blokirala je sposobnost promišljanja, raspolaganja znanjem i intelektualnim kognitivnim resursima. Razlog tomu je što se iz ponude Big Data kroz recikliranje, informacija prihvaća kao relevantna teorija „rekla kazala“ koja zasjenjuje znanost pa se zbog brzine sve uzima „zdravo za gotovo“. Istraživanje povezano s pobjedom nad virusima i donedavne životne vrijednosti u žarište interesa ne postavljaju više apokaliptičnost civilizacijskog smisla egzistencije i strah već lažni osjećaj sebstva kroz pitanje koje postavlja Torre u [48]: „Ima li života prije smrti? - iskustva prvog lica“. Sve je to poveznica na edukaciju i tehniku koje su osim učenja i stjecanja znanja važne za stjecanje kompetencija.

Kao što Huizinga, podsjeća na podrijetlo kulture iz igre, [49], a Paić, kroz svoje tri studje o Kierkegaardu ukazuje na sfere egzistencije, politiku identiteta i kultura kao novu ideologiju, [50- 51], Glasser upućuje na svoju „Teoriju izbora kao novu psihologiju osobne slobode“, [52]. U nadolazećim novim generacijama inteligentnih tehnologija bit će sve teže iz ponude Big Data prepoznati 'Razumijevanje medija' kao čovjekovih produžetaka, [53], jer će oni u ponudi „Teorije svega kao integralne vizije za biznis, politiku, znanost i duhovnost“, [54-55] zasjeniti kognitivnu kibernetiku u nadolazećem globalitarizmu, [56-58]. A sve su to komponente čimbenika stjecanja kompetencija.

Zaključak

U radu su prezentirani rezultati konkretnih primjera savladavanja određenog novog nastavnog gradiva i stjecanja znanja uz pomoć Promethee metode, (*Preference Ranking Organization METHod for Enrichment Evaluations*). Primjenom platformi i alata totalne integrirane automatike, umjesto teorijskog učenja na interaktivnim portalima nove generacije inženjerskih programa, navođenjem od strane edukatora postizani su odlični rezultati u učenju koje je kompatibilno sa STEM, IKT i e-Školskim programima. To se potvrdilo na konkretnom primjeru nastave u Strojarskoj tehničkoj školi Fausta Vrančića u Zagrebu. Alati kognitivne kibernetike, a to znači postupci vođeni zdravim razumom i pojednostavljenom vizualizacijom pomažu postizanju visoke učinkovitosti i univerzalne primjenjivosti ali i otvaraju smjerove daljnjih istraživanja povezanih s višekriterijskim odlučivanjem, a što su potvrdili studenti Tehničkog veleučilišta u Zagrebu.

Konceptom velikih podataka, (*Big Data*), njihovom obradom, pohranom i razmjenom poboljšava se sve više procesa u kojima čovjek i inteligentne tehnologije „suraduju“. Kognitivna kibernetika, nova znanstvena disciplina prokazuje tu suradnju kroz kibernetičko djelovanje razlikujući interakciju od integracije. Rezultati provedenih istraživanja o primjeni novih alata i metoda za novo, vođeno učenje za stjecanje znanja, (*Leading/Learning*) kao što je uporabljena *PROMETHEE* metoda, potvrđuju učinkovitost dobivenih vizualiziranih rezultata. Konkretno u obradi skupova ponuđenih izbora provedeno višekriterijsko odlučivanje analizom MCDA, (*Multi Criteria Decision Analysis*), pronalazi i prikazuje najbolje rješenje pomoću alata Visual PROMETHEE, tzv. GAIA, (*Graphical Analysis for Interactive Aid*). Metode i alati dostupni u ažuriranim demo verzijama potvrđuju se kao odlično sredstvo za učenje kako licem u lice, tako i na daljinu ali uz nužnu personaliziranu korespondenciju nastavnika i studenta.

Na Tehničkom veleučilištu u Zagrebu studenti su u osam kolaborativnih seminarskih timova savladali bez prethodnog znanja primjenu Promethee metode za obradu aktualnih tema navođeni i poticani od strane nastavnika na timski angažman. Oni su kroz angažman svako u svojem timu odabrali voditelja koji je kao koordinator i animator organizirao rad kroz debate. Taj je primjer poslužio za razradu nastavnih sadržaja i za nove sveučilišne studentske programe VERN-a. Kolaborativni je model izrade seminarskih radova studenata organiziranih u seminarske timove oplemenjen uz voditelja s još dvije nove funkcije: 1. demonstratora i 2. kustosa seminarskog tima. Na taj je način seminarski rad finaliziran kao autorsko djelo, (tekst, prezentacija i debata). On priskrbljuje u sveučilišne privatne, ali komercijalno dostupne baze, programe, alate, metode i algoritme koji se koriste za usvajanje znanja i vještina, a što je sve u funkciji stjecanja kompetencija.

Literatura

- [1] Z. Balaž, & M. M. Ninčević, *Kognitivna kibernetika – Računska racionalnost misaonih sustava*, GK, Zagreb, 2019.
- [2] S. Vrcelj, M. Mušanović: *Suvremenost teorije obrazovanja Ivana Illicha*, Pregledni rad, UDK 37:316.3(05), Vol. 4, No. 8, pp: 681 – 694, 2013.
- [3] Z. Balaž, M. M. Ninčević, Z. Groznica, *Filozofija kognitivne kibernetike za edukacije budućnosti*, HRO CIGRE, 9. simpozij, Povijest i filozofija tehnike / Z. Benčić, Zagreb, 2020.
- [4] Z. Balaž, M. M. Ninčević, *Kognitivna kibernetika za novu povijest i filozofiju tehnike*, 8. Simpozij PiFT, Urednik Zvonko Benčić, Zagreb, 2019.
- [5] W. Christoph, *Antropologija u globaliziranom svijetu*, Matica hrvatska, Zagreb, 2019. Z. Balaž: *Integration of Cognitive Cybernetics into Intelligent Human Systems?*, 1st International Conference on Intelligent Human System Integration, Dubai, January 2018.
- [6] Z. Balaž, *Inteligentni sustavi, modeli, metode, alati i algoritmi kognitivne kibernetike*, Predavanja kolegija Inteligentni sustavi ELO TVZ, Zagreb, akademska godina 2021/2021.
- [7] A. H. Maslow, *A Theory of human motivation*, Psychological Review, 50(4), 370–396, 1943.
- [8] B. H. Lipton, *Biologija vjerovanja – Znanstveni dokazi o nadmoći uma nad materijom*, Zagreb, Tisak Denona, 2007.
- [9] V. Andreoli, *Pismo učitelju*, Zagreb, Školska knjiga, 2009.

- [10] S. Greenfield, *Promjene uma, Kako digitalne tehnologije utječu na naš mozak*, Školska knjiga, Zagreb, 2018.
- [11] M. Spitzer, *Digitalna demencija – Kako mi i naša djeca silazimo s uma*, Nakladnik Ljevak d.o.o., Zagreb, listopad 2018.
- [12] V. Demarin, *Zdrav mozak danas za sutra*, Medicinska naklada, Zagreb, 2017.
- [13] Z. Balaž, B.-I. Balaž, *Human Computer Interaction, Cognitive Cybernetic & Captological Education*, on-line edition, Progress in Human Computer Interaction, Whioce Publishing Pte. Ltd., Singapore, 2018.
- [14] Z. Balaž, *Cognitive Cybernetics vs. Captology*, istraživačka studija ELO TVZ, Zagreb, HS Offenburg, 2017. – 2019.
- [15] Z. Balaž, *Kaptološka integracija čovjeka i inteligentnih tehnologija*, Uvodno predavanje za 41. Međunarodno savjetovanje PLANIRANJE I PROJEKTIRANJE u okviru Europskog zelenog plana, Elektrotehničko društvo Zagreb, EDZ P&P 2020, Zagreb, 5.-6. studenog 2020.
- [16] Hrvatska akademska istraživačka mreža, e-Škole: Uspostava sustava razvoja digitalno zrelih škola (pilot-projekt); "Priručnik – Strateško planiranje i upravljanje školom", Zagreb, 2018.
- [17] Hrvatska akademska istraživačka mreža: e-Škole: razvoj sustava digitalno zrelih škola (II. faza), Zagreb, 2019.
- [18] Hrvatska akademska istraživačka mreža: Europski okvir digitalnih kompetencija za obrazovatelje: DigCompEdu, Zagreb, 2017.
- [19] Z. Balaž, *Razrada i prilagodba Operativnog plana i programa rada 2019*, Strojarska tehnička škola Fausta Vrančića u Zagrebu za nastavne predmete: PLC-ovi i mikroupravljači, Mikro i nano mehatronika, Industrijska automatizacija, Električne instalacije i Mikroupravljači, rujan – listopad 2019.
- [20] Z. Balaž: *Inteligentni sustavi u praksi, ONLINE vježbe*, Rukopis udžbenika za ELO TVZ, Zagreb, predan na recenziju travanj 2020.
- [21] Z. Balaž: *Inteligentni sustavi u praksi, Kognitivna kibernetika za online učenje*, Rukopis udžbenika za ELO TVZ, Zagreb, predan na recenziju lipanj 2020.
- [22] J. P. Brans, et al, *Multiple criteria decision analysis*, State of the Art Surveys: PROMETHEE methods, chapter V, Springer Science + Business Media, New York, 2005.
- [23] I. Majdandžić: *PROMETHEE metoda u obradi inteligentnih sustava od pametnog do kognitivnog grada*, Diplomski rad, ELO TVZ, Zagreb, 2020.
- [24] Z. Balaž, K. Meštrović, *Inteligentni i ekspertni sustavi u elektroenergetici*, TVZ, Zagreb 2015.
- [25] Z. Balaž, K. Meštrović: *Politehnička kognitivna kibernetika*, TVZ, Zagreb, 2018.
- [26] Z. Balaž, A. Jelić: *Promethee metode i alati kognitivne kibernetike za edukacije budućnosti*, Rad predan za časopis Suvremene teme, Sveučilište VERN, 25. lipnja 2021.
- [27] D. v. Uslar, *Psychologie und Welt*, Verlag W. Kohlhammer, Stuttgart, Berlin, Köln, 1972.
- [28] D. Kahneman, *Misliti, brzo i sporo*, Zagreb, Mozaik knjiga, 2013.
- [29] R. Lachmann, *Phantasia Memoria Rhetorica*, Zagreb, Matica Hrvatska, 2002.
- [30] Z. Balaž, *Integration of Cognitive Cybernetics into Intelligent Human Systems?*, working materijal for scientific article prepared for the 1st International Conference on Intelligent Human System Integration, , Dubai, 7th – 9th of January 2018.
- [31] Z. Balaž, *The Captology of Intelligent Systems*, istraživačka studija ELO TVZ, Zagreb, HS Offenburg, 2013. – 2017.
- [32] Z. Balaž, *Dizajn i multimedija između kaptologije i simulakruma*, Međunarodni znanstveni skup – Tiskarstvo i dizajn, Zagreb, 2017.
- [33] Z. Balaž, *The Brain lost in the space of persuasive no-placelessness*, Public lecture, 16th Brain week in Croatia, 15th of March 2017.
- [34] Z. Balaž, *Cognitive Cybernetics – a Future Society 5.0*, International Symposium P&P, Zagreb, 2017.
- [35] Z. Balaž, M. Haun, *Cognitive Cybernetics – A Future that is Started*, 34th International Symposium on New Technologies, Šibenik, 2017.
- [36] Ministarstvo znanosti i obrazovanja, *Odluka o donošenju kurikuluma za međupredmetnu temu Uporaba informacijske i komunikacijske tehnologije za osnovne i srednje škole u Republici Hrvatskoj*, Narodne novine 07/19, 2019.
- [37] Hrvatski sabor, *Strategija obrazovanja, znanosti i tehnologije*, Narodne novine 124/14, 2014.

- [38] M. Milinović, *Kognitivna rješenja inteligentnih sustava i PROMETHEE metoda za nove edukacijske programe*, Diplomski rad, ELO TVZ, Zagreb, 2021.
- [39] E. J. Hom, *What is STEM education?* <https://www.livescience.com/43296-what-is-stem-education.html> [09.06.2021.]
- [40] I. Leder, Što je STEM i zašto je to uopće bitno? <https://www.stemlittleexplorers.com/hr/sto-je-stem-zasto-je-uopce-bitno> [09.06.2021.]
- [41] Wikipedia, Science, technology, engineering, and mathematics, https://en.wikipedia.org/wiki/Science,_technology,_engineering,_and_mathematics [09.06.2021.]
- [42] Ministarstvo regionalnog razvoja i fondova EU, Jačanje STEM vještina u osnovnim školama i razvoj regionalnih znanstvenih centara za osnovnoškolski odgoj i obrazovanje u STEM području, Zagreb, 2021. <https://eeagrants.hr/jacanje-stem-vjestina-u-osnovnim-skolama-i-razvoj-regionalnih-znanstvenih-centara-za-osnovnoskolski-odgoj-i-obrazovanje-u-stem-podrucju/>, [10.06.2021.]
- [43] H. Herceg, *Opis "PROMETHEE" metode, njezina primjena u višekriterijalnom odlučivanju uz pomoć aplikacije "Decision Lab"*, Završni rad, FSB, Zagreb, 2011.
- [44] VPSolutions, *Visual PROMETHEE 1.4*, Manual, 2013. <http://www.promethee-gaia.net/assets/vpmanual.pdf>, [11.06.2021.]
- [45] Z. Balaž, K. Meštrović, *Učenje i poučavanje iz umjetne inteligencije*, TVZ – Tehničko veleučilište u Zagrebu, Polytechnic & Design, Vol. 2, No 1, pp 9-14, Zagreb, 2014.
- [46] M. Sokele, et al., The Importance of Synchronous Online Learning for Student Success in Exams, 44. međunarodni simpozij - MIPRO, Opatija, 27.09.- 01.10. 2021
- [47] Z. Balaž, *Cyberpsihologija – Umjetna inteligencija danas i u budućnosti*, Pozvano predavanje na Skupu SPiRi, FF Rijeka, travnja. 2019.
- [48] R. Torre: *Ima li života prije smrti? - iskustva prvog lica*, Znanje, Zagreb, 2018
- [49] J. Huizinga, *O podrijetlu kulture i igri*, Zagreb, Naprijed, 1992.
- [50] Ž. Paić, *Sfere egzistencije: Tri studje o Kierkegaardu*, Matica Hrvatska, Zagreb, 2017.
- [51] Ž. Paić, *Politika identiteta, Kultura kao nova ideologija*, Antibarbarus, Zagreb, 2005.
- [52] W. Glasser, *Teorija izbora – Nova psihologija osobne slobode*, Alinea, Zagreb, 2000.
- [53] K. Wilber, *Teorija svega: integralna vizija za biznis, politiku, znanost i duhovnost*, Gorin, Rijeka 2004.
- [54] K. Wilber, *Kratka povijest svega*, Gorin, Rijeka, 2005.
- [55] H. M. McLuhan, *Razumijevanje medija – Mediji kao čovjekovi proizvođači*, Golden Marketing, Zagreb, 2008.
- [56] Z. Balaž, S. Desin, *Kognitivna kibernetika i globalitarizam*, EIS 2019 - 38. Međunarodni elektroinženjerski simpozij - Dani Josipa Lončara, Crikvenica, 2019.
- [57] Z. Balaž, *Cognitive Cybernetics vs. Captology*, ASTESJ, Advances in Science, Technology and Engineering Systems Journal, vol. 2, No. 1. pp. 107-118, November 2017.
- [58] Z. Balaž, K. Wawrzynek, *Cognitive Cybernetics in the Foresight of Globalitarianism*, Advances in Science, Technology and Engineering Systems Journal, vol. 5, No. 6, pp. 718–723, November 2020.

Zdenko Balaž, Marjan Marino Ninčević i Marijan Milinović