



Co-funded by
the European Union

FAAI:

The Future is in Applied Artificial Intelligence

Budúcnosť je v aplikovanej umelej inteligencii

Projekt Erasmus+ 2022-1-PL01-KA220-HED-000088359

01.09.2022 – 31.08.2024

A3.3 Požiadavky na vzdelávanie umelej inteligencie: WP3





Co-funded by
the European Union

Výroba tohto dokumentu bola možná vďaka podpore projektu ERASMUS+:
The Future is in Applied Artificial Intelligence
Budúcnosť je v aplikovanej umelej inteligencii
(2022-1-PL01-KA220-HED-000088359)

Financované Európskou úniou. Vyjadrené názory a názory sú však len názormi autora (autorov) a nemusia nevyhnutne odrážať názory a názory Európskej únie alebo národnej agentúry (NA). Európska únia ani NA za ne nezodpovedajú.



Dátum

21.05.2023

Miesta vývoja výsledku

Univerzita Bielsko-Biala, Bielsko-Biala, Poľsko

Univerzita knižničných štúdií a informačných technológií, Sofia, Bulharsko

Univerzita v Niši, Srbsko

Univerzita sv. Cyrila a Metoda v Trnave na Slovensku

Univerzita v Čiernej Hore, Čierna Hora

Zhrnutie: Konzorcium The Future is in Applied Artificial Intelligence Project navrhlo prvé kurikulum aplikovanej umelej inteligencie založené na kompetenciách na úrovni vysokých škôl. Vývoj bol založený na pokročilom systémovom výskume existujúcich zdrojov súvisiacich s umelou inteligenciou a prieskume cieľových skupín učiteľov, študentov informačných technológií a zamestnávateľov, ktorý by mal zvýšiť výkonnosť implementácie vzdelávania umelej inteligencie. Bol pripravený prehľad aplikovanej umelej inteligencie formou zhlukovania kľúčových slov. Počiatočné údaje boli zhromaždené pomocou prieskumu, zhromažďovania pracovných ponúk, existujúcich kurzov umelej inteligencie, vedeckých projektov a skutočných prípadov. Syntetická analýza textových informácií zo štúdií využívala techniku slovných oblakov. Na prezentáciu kompetenčného kurzu bol použitý tenzorový prístup. Špecifické numerické požiadavky na predmet v podobe priorit vyplývajú z riešenia rozhodovacích problémov technikou analytickej hierarchie. Na základe komplexnej štúdie prieskumov, vzdelávacích skúseností, vedeckých projektov a obchodných požiadaviek, metaanalýzy najnovších referencií sme špecifikovali kritériá pre tréningový kurz vo forme tenzorovej reprezentácie kompetencií vo vzťahu k obsah a vzdelávacie moduly.

Kľúčové slová: Proces analytickej hierarchie, aplikovaná umelá inteligencia, kurikulum založené na kompetenciách, prístup založený na tenzoroch, oblaky slov

I. ÚVOD

Pre úspešnú aplikáciu umelej inteligencie (AI) v reálnom svete je potrebný komplexný prístup, vrátane robustného zberu a predspracovania údajov, efektívneho návrhu algoritmu a školenia, etických úvah, neustáleho hodnotenia a zlepšovania, interdisciplinárnej spolupráce a starostlivá integrácia do existujúcich systémov a pracovných postupov. Inovatívne školiace kurzy zohrávajú kľúčovú úlohu pri úspešnej implementácii modelov AI v reálnom svete tým, že vybavujú študentov praktickými znalosťami, praktickými skúsenosťami a schopnosťou orientovať sa v zložitých výzvach, čím umožňujú efektívny vývoj a nasadenie modelov AI a prispôsobenie sa scenárom reálneho sveta.

Všeobecné požiadavky na efektívny školiaci kurz o AI zahŕňajú komplexný učebný plán pokrývajúci základné koncepty AI, praktické cvičenia a projekty, prípadové štúdie z reálneho sveta, prístup k relevantným súborom údajov a nástrojom, skúsených inštruktorov a zameranie sa na etické otázky úvahy a priemyselné aplikácie.

Cieľom práce je vyvinúť komplexný prístup k navrhovaniu vzdelávacieho kurzu o aplikovanej umelej inteligencii (AAI), ktorý na základe systémového prieskumu obchodných požiadaviek zodpovedá princípu kompetenčného vzdelávania a inovatívnosti, pedagogiky.

PROJEKTFAAI

Danú prácu realizovalo v rámci projektu Erasmus+ 2022-1-PL01-KA220-HED-000088359 s názvom „Budúcnosť je v aplikovanej umelej inteligencii“ (The - Future is in Applied Artificial Intelligence FAAI) konzorcium vrátane Univerzity Bielsko-Biala (Poľsko), Univerzita Knížničných študijných a informačných technológií (Bulharsko), Univerzita sv. Cyrila a Metoda v Trnave (Slovensko), Univerzita v Niši (Srbsko), Univerzita Čierna Hora (Čierna Hora) a



**Co-funded by
the European Union**

spoluzakladateľmi Európskej únie. Cieľom projektu je spojiť univerzity a podniky s cieľom poskytnúť inovatívne riešenia na rozvoj odborníkov na umelú inteligenciu [1].

Pojem AAI sa vzťahuje na praktickú implementáciu a využitie techník a technológií AI na riešenie reálnych problémov a dosahovanie špecifických cieľov v rôznych oblastiach. V komunite a priemysle umelej inteligencie sa stala široko prijatou a používanou na rozlíšenie praktickej aplikácie AI od teoretického výskumu a vývoja. Tento výraz zdôrazňuje dôraz na používanie AI v praktickom prostredí a využitie jej schopností na riešenie konkrétnych výziev a dosiahnutie hmatateľných výsledkov.

Jedným z cieľov projektu je navrhnuť školiaci kurz o AAI, ktorý odráža skutočné potreby a mal by byť založený na kompetenciách. Počas celého projektu prebiehal systémový výskum, ktorý vychádzal zo štúdií existujúcich kurzov AI, vedeckých projektov, reálnych prípadov, trhu práce AI, študentov IT, lektorov a zamestnávateľov.

A. SÚVISIACE PAPERS ON AAI

Pri príprave prehľadu súvisiacich článkov sme vybrali 10 000 referencií z knižnice WoS ako výsledok dotazu „aplikovaná umelá inteligencia“. Pomocou CiteSpace [2] bol získaný súbor prác rozdelený do 12 najvýznamnejších zhlukov vzhľadom na kľúčové slová, ako je znázornené na obr.

Zoznam získaných kľúčových slov obsahuje „umelá neurónová sieť“, „umelá inteligencia“, „hlboké učenie“, „rakovina pľúc“, „vysvetliteľná umelá inteligencia“, „pacient s COVID-19“, „zariadenie internetu vecí“, „posilňovacie učenie“, „objavenie drog“, „bezdrôtová komunikácia“, „vodný roztok“, ktorý ukazuje najvýznamnejšie modely AI, ako aj aplikácie. Najcitovanejšie články v rámci všetkých zhlukov sú [3] (skupina #0) súvisiace s riešeniami umelej inteligencie pre patológie štítnej žľazy, [4] (skupiny #1, #3, #4, #5) súvisiace s podporou modelového rozhodnutia v kontext, ktorý môže človek ľahko interpretovať (vysvetliteľná AI), [5] (skupina č. 2) [6] (skupina č. 6) o technike AI/ML pre prepuknutie COVID-19, [7] (skupina č. 7) venovaná technológii AI a DL uľahčujúcej analýzu údajov systémov internetu vecí, [8] (skupina č. 8) o aplikácii posilňovacieho vzdelávania v rôznych oblastiach, [9] (skupina č. 9) o aplikácii AI na objavovanie liekov, [10] (skupina č. 10) na sieťovej komunikácii založenej na AI, [11] (klaster #11) na AI pre environmentálne štúdie.

„Výrazné“ práce v rámci tejto analýzy súvisia s osvedčenými postupmi a skutočnými prípadmi; sú uvedené nižšie:

- [12] zaviedli terminológiu „deep learning“.
- [13] sprístupnil dva najvýkonnejšie ConvNet mod-els pre ďalší výskum hlbokých vizuálnych reprezentácií v počítačovom videní
- [14] o kontrole na ľudskej úrovni prostredníctvom hlbokého posilnenia

učenia

- [15] je učebnica Deep Learning, ktorá má pomôcť študentom a odborníkom vstúpiť do oblasti strojového učenia všeobecne a hlbokého učenia zvlášť
- [14] predstavili nový trend zvažujúci učenie sa zložitých motívov pomocou veľkých súborov údajov. Uvažované hlboké umelé neurónové siete používajú viacero vrstiev na objavovanie vzorov (komplexnejších s každou vrstvou) a štruktúry veľkých súborov údajov. Prístup je možné použiť pre DNA, RNA a aplikáciu v medicíne.
- [16] preskúmali učenie pod dohľadom, učenie bez dozoru, učenie sa posilňovaním a evolučné výpočty.
- [17] predstavili ImageNet, benchmark v objektovej kategórii klasifikácia a detekcia na stovkách kategórií objektov a miliónoch obrázkov
- [18] prezentovali tréning veľkej, hlbokéj konvolučnej neurónovej siete na klasifikáciu 1,2 milióna obrázkov s vysokým rozlíšením v súťaži ImageNet LSVRC-2010 do 1000 rôznych tried.
- [19] predstavili nový prístup k počítaču Go, ktorý využíval hlboké neurónové siete tréňované novou kombináciou učenia sa pod dohľadom z ľudských expertných hier a posilňovania učenia sa z hier samohry.

II. VÝCHODISKÁ ŠTÚDIA

A. ZALOŽENÉ NA KOMPETENCIÁCH VZDELÁVANIE

Vzdelávanie založené na kompetenciách (CBE) naberalo na sile ako vzdelávací prístup, ktorý sa sústreďuje skôr na rozvoj špecifických zručností a schopností, než na samotné získavanie vedomostí. CBE si kladie za cieľ pripraviť študentov na výzvy reálneho sveta tým, že im poskytne potrebné kompetencie, aby uspeli vo vybraných odboroch. Nižšie sú uvedené niektoré kľúčové črty a prvky bežne spojené s najmodernejším vzdelávaním založeným na kompetenciách so zameraním na vzdelávanie v oblasti IT.

CBE sa spolieha na jasne definované kompetenčné rámce, ktoré načrtávajú špecifické zručnosti a znalosti, ktoré by študenti mali získať. Tieto rámce zvyčajne rozdeľujú kompetencie na merateľné výsledky vzdelávania [20].

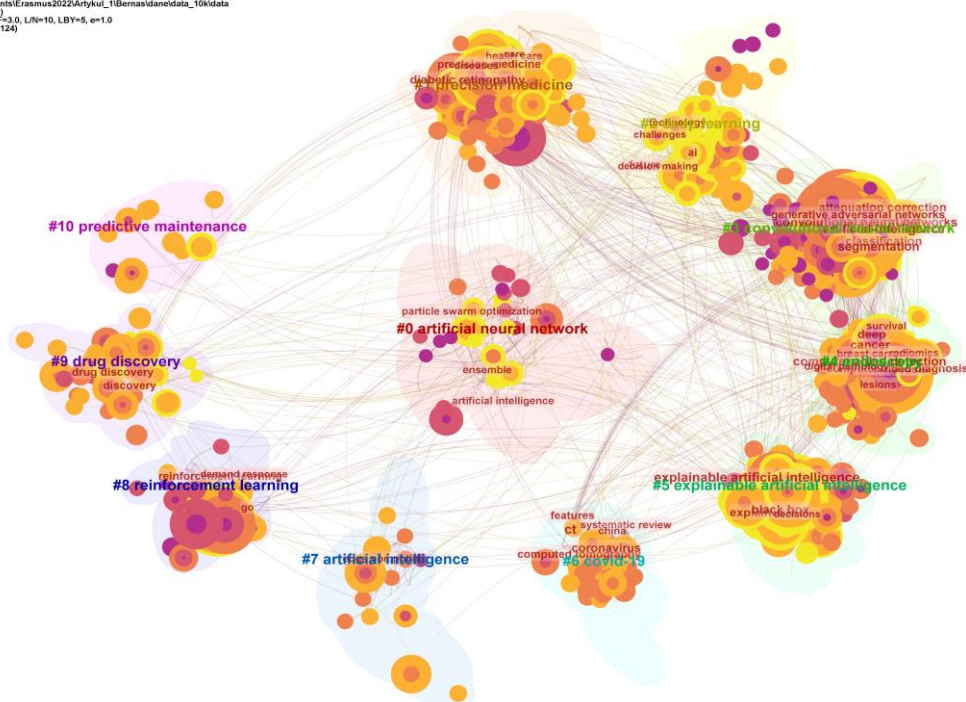
CBE často podporuje personalizované vzdelávacie skúsenosti prispôbené individuálnym potrebám a záujmom študentov. Umožňuje študentom napredovať vlastným tempom a poskytuje flexibilitu, pokiaľ ide o obsah, vzdelávacie aktivity a metódy hodnotenia [21].

V CBE sa hodnotenia zameriavajú na hodnotenie demonštračných prejavov študentov viac stratégií, než spoliehať sa len na tradičné skúšky alebo štandardizované testy. Autentické hodnotenia [22] môžu zahŕňať projekty, portfóliá, prezentácie, simulácie alebo úlohy z reálneho sveta, ktoré ukážu schopnosti študentov v kontextoch reálneho života.



Co-funded by
the European Union

CiteSpace, v. 5.2.R4 (64-bit) Advanced
July 2, 2023 at 4:06:53 PM CEST
Viz: C:\Users\AM\OneDrive\Documents\Erasmus2022\Artyku_11\Bemasidane\data_10k\data
Timespan: 2019-2023 (Slice Length=1)
Selection Criteria: g index (k=25, LRF=1.0, L/N=10, LBY=5, e=1.0)
Network: N=956, E=5541 (Density=0.0124)
Largest CC: 832 (97%)
Nodes Labeled: 1.0%Pruning: None
Modularity Q=0.62
Weighted Mean Silhouette S=0.8156
Harmonic Mean(Q, S)=0.7145



CiteSpace

OBRAZOK 1. Cluster zápletka pre WoS publikácie cez 10 posledný rokov v odpoveď do a dopyt týkajúci sa aplikovaný umelé inteligenciu

Inštruktáž v CBE je navrhnutý vzhľadom na vzdelávacie cesty na rozvoj a posilnenie identifikovaných kompetencií. Často zahŕňa aktívne a zážitkové metódy učenia, ako je projektové učenie, aktivity zamerané na riešenie problémov, spoluprácu a praktické skúsenosti [23].

Najmodernejšie CBE často využíva integráciu technológií na zlepšenie vzdelávacích skúseností. To môže zahŕňať používanie online platforiem, adaptívnych vzdelávacích systémov, vzdelávacích aplikácií, nástrojov virtuálnej reality (VR) a rozšírenej reality (AR), ktoré môžu poskytovať personalizovanú spätnú väzbu, simulácie a interaktívny obsah [24].

CBE sa zasaďuje za uznávanie a udeľovanie poverení na základe preukázaných kompetencií [25]. Môže to zahŕňať vydávanie digitálnych odznakov, certifikátov alebo dokonca titulov, ktoré zdôrazňujú špecifické zručnosti a schopnosti študentov.

CBE presahuje rámec formálneho vzdelávania a zdôrazňuje dôležitosť celoživotného vzdelávania a trvalého profesionálneho rozvoja [26]. Zameriava sa

na podporu myslenia neustáleho zlepšovania a prispôsobivosti tak, aby vyhovovala vyvíjajúcim sa požiadavkám pracovnej sily.

B. IT VZDELÁVANIE

Najmodernejšie vzdelávanie v oblasti IT zahŕňalo niekoľko kľúčových oblastí.

Zmiešané učenie kombinuje tradičnú výučbu v triede s online zdrojmi a aktivitami. Využíva technológiu na poskytovanie interaktívnejšieho a personalizovanejšieho vzdelávacieho zážitku. Tento prístup umožňuje študentom získať prístup k materiálom kurzu, spolupracovať s kolegami a zapojiť sa do praktických cvičení prostredníctvom digitálnych platforiem.

Projektové učenie sa zameriava na praktické aplikácie IT zručností. Študenti pracujú na reálnych projektoch, individuálne alebo v tímoch, pri riešení problémov, navrhovaní softvéru alebo vytváraní inovatívnych riešení. Tento prístup podporuje kritické myslenie, riešenie problémov a spoluprácu a zároveň poskytuje študentom praktické skúsenosti.

Adaptívne učenie systémy využívajú technológiu na prispôsobenie vzdelávacích skúseností na základe individuálnych potrieb a výkonu študentov. Tieto systémy analyzujú údaje o silných a slabých stránkach študentov a štýloch učenia, aby poskytli prispôbosený obsah, tempo a spätnú väzbu. Prispôobením sa požiadavkám každého študenta adaptívne učenie zvyšuje zapojenie a zlepšuje výsledky učenia.

Mnohé vzdelávacie inštitúcie si uvedomujú rastúci význam kódovacích zručností a preto vo svojich učebných osnovách IT zdôrazňujú kódovanie a výpočtové myslenie. Študenti sa učia programovacie jazyky, algoritmy, dátové štruktúry a techniky riešenia problémov. Toto zameranie ich vybaví základnými zručnosťami potrebnými pre vývoj softvéru, analýzu dát a ďalšie oblasti IT.

Vzhľadom na narastajúci význam kybernetickej bezpečnosti IT vzdelávanie často zahŕňa princípy a postupy kybernetickej bezpečnosti. Študenti sa učia o zabezpečení sietí, ochrane údajov, identifikácii zraniteľnosti a reakcii na kybernetické hrozby. Inštitúcie môžu ponúkať špecializované kurzy alebo študijné programy v oblasti kybernetickej bezpečnosti, aby uspokojili dopyt po kvalifikovaných odborníkoch v tejto oblasti.

Šírenie údajov v rôznych odvetviach viedlo k zvýšenému dôrazu na vzdelávanie v oblasti vedy o údajoch a analýzy. Študenti sa učia štatistickú analýzu, vizualizáciu údajov, strojové učenie a techniky dolovania údajov. Vzdelávacie programy často zahŕňajú praktické skúsenosti s nástrojmi na analýzu údajov a programovacími jazykmi bežne používanými v tejto oblasti, ako sú Python alebo R.

Najmodernejšie vzdelávanie v oblasti IT kladie dôraz aj na etické a sociálne dôsledky technológií. Študenti skúmajú témy ako súkromie, bezpečnosť, digitálna etika, algoritmické skreslenie a vplyv technológií na spoločnosť. Toto zameranie povzbudzuje študentov, aby zvažovali širšie dôsledky svojej práce a rozvíjali zodpovedné a inkluzívne prístupy k IT. Mnohé vzdelávacie inštitúcie nadväzujú partnerstvá s lídrami v odvetví a ponúkajú stáže alebo kooperatívne vzdelávacie programy. Tieto spolupráce poskytujú študentom príležitosti získať praktické skúsenosti, pracovať na skutočných projektoch a rozvíjať profesionálne siete. Takáto angažovanosť priemyslu pomáha preklenúť priepasť medzi akademickou obcou a



Co-funded by
the European Union

priemyslom, čím zabezpečuje, že absolventi sú na to lepšie pripravení pracovnej sily.

C. DEFINÍCIA OFAAI

AAI sa vzťahuje na využitie techník a technológií AI na riešenie reálnych problémov a riešenie praktických výziev v rôznych doménach s cieľom rozšíriť ľudské schopnosti, zlepšiť rozhodovacie procesy a automatizovať zložité procesy.

Aplikovaná umelá inteligencia zahŕňa širokú škálu oblastí vrátane, ale nie výlučne, zdravotnej starostlivosti, financií, dopravy (napr. autonómne vozidlá), výroby, kybernetickej bezpečnosti a služieb zákazníkom, ako sú personalizované systémy odporúčaní. Špičkové aplikácie využívajú techniky, ako je strojové učenie, hlboké neurónové siete, spracovanie prirodzeného jazyka na pochopenie a generovanie jazyka, počítačové videnie na analýzu obrazu a videa a robotika na automatizáciu fyzických úloh. Expertné systémy sú tiež stále dôležité pre vedomostne náročnú podporu rozhodovania.

V aplikovanej AI sa dôraz kladie na vývoj praktických riešení, ktoré možno integrovať do existujúcich systémov alebo pracovných postupov na dosiahnutie hmatateľných výsledkov. To často zahŕňa zhromažďovanie a predbežné spracovanie údajov, analýzu a interpretáciu komplexných súborov údajov, extrahovanie zmysluplných vzorov a poznatkov, tréning modelov AI pomocou vhodných algoritmov, overovanie a doladovanie modelov a ich nasadenie v scenároch reálneho sveta. Prostredníctvom iteratívneho učenia a zdokonaľovania sa modely AI neustále zlepšujú, aby sa dosiahla vyššia presnosť, robustnosť a prispôbivosť.

Okrem toho aplikovaná AI zohľadňuje etické, právne a spoločenské dôsledky a zabezpečuje, že nasadené systémy sú transparentné, spravodlivé, bezpečné a zodpovedné.

D. ROZSAH PROBLÉMOV A OBLASTÍ AAI

Rozsah problémov s umelou inteligenciou je široký a rôznorodý. Umelá inteligencia môže byť aplikovaná na širokú škálu domén a môže riešiť rôzne typy problémov. Niektoré oblasti, v ktorých možno využiť AI, sú nasledovné: automatizácia, podpora rozhodovania,

TABLE1. Rozsah problémov AI podľa klesajúceho poradia významnosti

Scope	Percentage
healthcare	17,60%
ecology	9,74%
cybersecurity	8,99%
manufacturing	7,49%
data processing	5,24%
robotics	4,87%
smart grid	3,75%
finance	3,75%
energetics	3,75%
recommendation systems	3,00%
agriculture	3,00%
photo and video	2,62%
face and body recognition	2,25%
culture	2,25%
chatbots	2,25%
business intelligence	2,25%
automotive	2,25%
voice recognition	1,87%
video processing	1,87%
geolocation	1,87%
education	1,87%
road traffic	1,50%
object detection	1,50%
transport	1,12%
search and recommendation	1,12%
library	0,75%
aviation and ocean transport	0,75%
social network analytics	0,37%
military	0,37%

Spracovanie prirodzeného jazyka, analýza obrazu a videa, zdravotníctvo, robotika a autonómne systémy, hry a zábava, kybernetická bezpečnosť, inteligentné mestá a monitorovanie životného prostredia. Tieto príklady predstavujú len zlomok rozsahu problémov AI. Umelá inteligencia neustále napreduje a nachádza uplatnenie v rôznych odvetviach a sektoroch, čím vytvára nové príležitosti na riešenie zložitých výziev a zlepšuje efektivitu a rozhodovacie procesy. Pri navrhovaní kurzu AI založeného na kompetenciách by sa mala brať do úvahy celá škála skutočných prípadov AI.

V rámci projektu FAAI bolo študovaných 267 reálnych prípadov založených na riešeniach AAI. V tabuľke 1 sú uvedené oblasti úloh spolu s ich významom.

E. AAI VEDECKÉ PROJEKTY

Súčasťou výskumu v rámci programu FAAI Erasmus+ bol aj dotazník o vedeckých projektoch v aplikovanej AI. Otázky boli zamerané na prieskum potrieb a očakávaní vedeckých projektov na pomoc pri príprave špecialistov v oblasti aplikovanej AI. Zozbierali sa a analyzovali dotazníky o 63 projektoch zozbieraných partnerskými organizáciami z 5 krajín. Koordinátori projektu boli z 19 krajín, 34 z univerzít, 6 z akadémií vied a 24 z iných organizácií alebo spoločností. Keďže sa dotazníky primárne zameriavali na prebiehajúce projekty, získané výsledky možno považovať za aktuálne a aktuálne. Väčšina projektov



Co-funded by
the European Union

má 1-6 účastníkov; jeden projekt má však 50 účastníkov.

Medzi najzaujímavejšie výsledky patrí zistenie,

že viac ako polovica projektov sa týkala modulov učenia hlbokých neurónových sietí a väčšina úloh strojového učenia, ktoré sa vyriešili, bolo spracovanie obrazu, klasifikácia, regresia, zhukovanie a spracovanie prirodzeného jazyka. Z počtu 63 dotazníkov sa 55 týkalo nasledujúcich úloh ML. V projektoch sa nespomínala reprezentácia a zdôvodňovanie znalostí, stratégie plánovania a vyhľadávania, expertné systémy a fuzzy logika. Väčšina prípadov používa otvorené softvérové knižnice. Medzi použitými AI knižnicami dominovali TensorFlow, Keras, scikit-learn a CUDA. Programovacími jazykmi boli Python a C++.

F. AI VZDELÁVANIE

Vzdelávanie AI rýchlo nabera na význame v dnešnom, technológiami poháňanom svete. Celý prehľad výučby a učenia AI za posledných 20 rokov je uvedený v [27]. Keďže AI stále nachádza svoje uplatnenie v rôznych odvetviach a aspektoch nášho života, rastie potreba jednotlivcov, ktorí dobre rozumejú konceptom a technikám AAI. Umelú inteligenciu a automatizáciu si pravdepodobne osvojí ešte viac spoločností, aby sa zvýšila efektívnosť a produktivita. Tieto technológie možno použiť na automatizáciu opakujúcich sa úloh, spracovanie veľkého množstva údajov a vytváranie presnejších predpovedí. Preto je potrebný dobrý a jednotný prístup k vzdelávaniu AI.

Na úrovni strednej školy v [28] vypracovali a vyhodnotili učebné osnovy AI.

V [29] dokázali, že osvedčené postupy vo výučbe AIa vzdelávanie vo vysokoškolskom vzdelávaní tvoria kľúčové faktory, ako je sebadôvera, úzkosť z matematiky a rozdiely vo vzdelaní študentov.

Paradigmy učenia sa založené na kompetenciách, ktoré sú obzvlášť účinné pri rozvíjaní praktických zručností a príprave jednotlivcov na aplikácie AI v reálnom svete, však nepatria do úvahy. Kurzy AI by sa mali zameriavať na nadobudnutie špecifických kompetencií a ponúkať praktické školenia s problémami v reálnom svete, čo študentom umožní rozvíjať potrebné zručnosti a znalosti, aby sa stali úspešnými odborníkmi na AI.

Pre študenta je nevyhnutné vybrať si vzdelávacie kurzy, ktoré zodpovedajú jeho špecifickým potrebám a cieľom, pričom zohľadňujú najnovšie inovácie v tejto oblasti. Naopak, pri tvorbe osnov kurzu je tiež potrebné definovať jasné a konkrétne ciele kurzu a sledovať najnovšie pokroky v tejto oblasti.

III. MATERIÁLY A METÓDY

Ponúkli sme prístup k rozvoju vzdelávacieho kurzu AAI s využitím výsledkov rôznych prieskumov, štandardov kompetencií a tém, spracovania údajov a rozhodovania na základe multikriteriálnej optimalizácie (pozri Obr. 2 pre všeobecný pohľad). Zahŕňa nasledujúce kroky.

Začnite stanovením celkových cieľov školiaceho kurzu. Identifikujeme požadované výsledky, kompetencie a oblasti vedomostí, ktoré je potrebné pokryť.

Vykonávame prieskumy a hodnotenia, aby sme zhromaždili údaje o potrebách a preferenciách cieľového publika. To môže zahŕňať prieskumy existujúcich vedomostí, medzier v zručnostiach, preferencií učenia a požadovaných tém.

Identifikujeme štandardy alebo štandardy pre kompetencie, ktoré by účastníci mali dosiahnuť po ukončení školenia. Tieto štandardy pochádzajú z [30] a pomôžu definovať požadované znalosti, zručnosti a schopnosti v AAI.

Na základe údajov z prieskumu a štandardov kompetencií určíme konkrétne témy, ktoré je potrebné prebrať v kurze AAI. Zvažujeme relevantnosť, dôležitosť a prioritu každej témy.

Multisource Data Analytics Toolbox zahŕňa spracovanie a analýzu údajov z prieskumov a štúdií s cieľom získať zmysluplné poznatky. To môže zahŕňať štatistickú analýzu, vizualizáciu údajov a techniky sumarizácie (ako sú oblaky slov, grafy CiteSpace, AHP) na identifikáciu vzorcov, trendov a vzťahov medzi odpoveďami na prieskum a údajmi z viacerých zdrojov.

Na základe zistených tém, kompetencií a výsledkov prieskumu určíme jednotlivé vzdelávacie moduly, ktoré sa venujú špecifickým aspektom vzdelávacieho kurzu. Každý modul by mal mať jasné vzdelávacie ciele a obsah, ktorý je v súlade s požadovanými výstupmi.

Vytvárame krížové matice, ktoré ilustrujú vzťahy medzi témami, kompetenciami a vzdelávacími modulmi. Táto matica pomáha vizualizovať, ako každý modul prispieva k rozvoju špecifických kompetencií a ako sú rôzne témy prepojené s modulmi a medzi sebou navzájom.

Kombinujeme jednotlivé vzdelávacie moduly a krížové matice na vytvorenie 3D reprezentácie tenzora. Tento tenzor zachytáva vzájomné závislosti medzi témami, kompetenciami a vzdelávacími modulmi štruktúrovaným a organizovaným spôsobom.

Používame techniky multikriteriálnej optimalizácie na prijímanie informovaných rozhodnutí na základe zhromaždených údajov. Zohľadnenie viacerých faktorov, ako je dôležitosť každej témy a preferencie cieľového publika, optimalizuje dizajn a poskytovanie školiaceho kurzu AAI.

Integrujeme akékoľvek špecifické požiadavky, ktoré vyplynú z rozhodovacieho procesu. To môže zahŕňať úpravy obsahu, metód poskytovania, stratégií hodnotenia alebo poradia modulov na základe výsledkov optimalizácie.

A. MATERIÁLY

Práca je založená na sérii údajov zozbieraných ako výsledok projektu FAAI štúdie dobrej praxe v oblasti AAI. Konkrétne sme analyzovali

- 74 ponúk z trhu práce;
- 63 vedeckých projektov v oblasti AI;
- 92 existujúcich kurzov odbornej prípravy AI;
- 27 riešení osvedčených postupov;
- 279 skutočných prípadov riešení AI;
- vyplnené prieskumy (80 akademikov, 1054 študentov IT, 38



zamestnávateľov)

¹Metóda AHP je opísaná ďalej

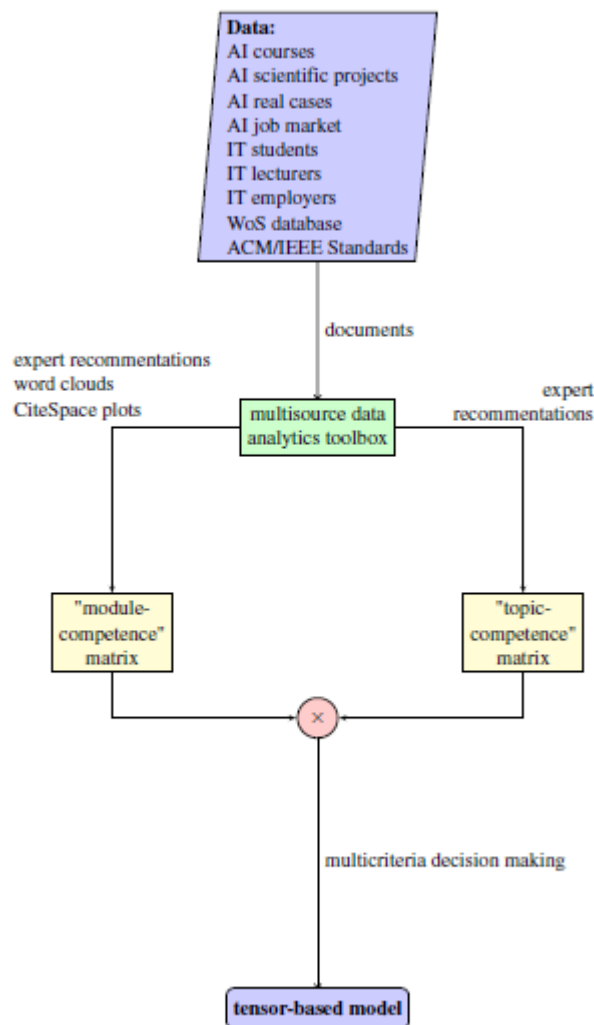


FIGURE 2. Flowchart for determining AAI course requirements

B. SLOVNÉ OBLAKY

Oblaky slov, označované aj ako diagramy slov alebo oblaky značiek, sú podmanivé vizualizácie údajov, ktoré zobrazujú najvýznamnejšie slová alebo frázy v grafickom formáte. Táto inovatívna technika vizuálne zvyrazňuje relatívnu frekvenciu slov

daného textu [31], výsledkom čoho je esteticky príjemné a ľahko zrozumiteľné zobrazenie.

Koncept slovných oblakov sa objavil na začiatku 90. rokov 20. storočia, sprevádzaný prvými prípadmi vizualizácie frekvencií slov. Dostupnosť nástrojov na počítačovú analýzu textu a webových aplikácií ďalej popularizovala ich využitie. V súčasnosti mnoho online platforiem a softvéru umožňuje používateľom bez námahy generovať oblaky slov z textových údajov. Vytváranie oblakov slov sa riadi priamočiarym postupom [32]. Na začiatku sa text skúma, aby sa extrahovali jedinečné slová alebo frázy, a určuje sa frekvencia ich výskytu. Veľkosť alebo nápadnosť slova v slovnom oblaku je úmerná jeho frekvencii v texte. Slová s väčšou dôležitosťou sa zvyčajne zobrazujú väčším písmom alebo sú umiestnené bližšie k stredu, zatiaľ čo menej relevantné slová sú menšie alebo umiestnené smerom k okraju. Oblaky slov nachádzajú rozsiahle uplatnenie v rôznych doménach [32], [33]. V obchodnej sfére uľahčujú analýzu sentimentu, identifikáciu trendov a skúmanie kľúčových slov v rámci spätnej väzby od zákazníkov alebo popisov produktov. V oblasti vzdelávania slúžia ako nástroje na vizualizáciu kľúčových pojmov alebo tém, napomáhajú k pochopeniu a uchovaniu vedomostí. Okrem toho sa využívajú v sociálnom výskume, analýze obsahu a dolovaní názorov, pričom ponúkajú cenné poznatky o rozsiahlych zbierkach textových údajov.

C. KLUSTEROVÁ ANALÝZA KĹÚČOVÝCH SLOV

Na vykonanie zhlukovej analýzy referencií z Web of Science (WoS) pomocou softvéru CiteSpace [2] exportujeme 10 000 referenčných údajov z WoS vo formáte obyčajného textu. CiteSpace spracuje údaje a vytvorí citačnú sieť. Po vytvorení citačnej siete ponúka CiteSpace rôzne možnosti vizualizácie a analýzy. Preskúmali sme rôzne nastavenia a parametre, aby sme vytvorili zmysluplné klastre týkajúce sa kľúčových slov. Zodpovedajúce označenie nám umožňuje označiť popredných autorov a inštitúcie. Je možné určiť aj trhacie práce.

D. AHP

Metóda AHP sa používa na riešenie problémov rozhodovania, ktoré zahŕňajú viacero kritérií a alternatív. Je obzvlášť účinný, keď čelíte zložitým rozhodnutiam, kde je potrebné zvážiť subjektívne úsudky a kompromisy medzi hierarchicky štruktúrovanými kritériami [34]. V danej práci bude metóda AHP aplikovaná v kontexte navrhovania vzdelávacieho kurzu AAI na uprednostňovanie a rozhodovanie o rôznych aspektoch

kurzu, konkrétne ciele učenia, obsah kurzu, metódy hodnotenia, vyučovacie stratégie, pridelovanie zdrojov, integrácia technológií, hodnotenie a spätná väzba. Vykonaním párových porovnaní môžeme posúdiť relatívnu dôležitosť alebo preferenciu každého kritéria a alternatívy. Môžeme napríklad porovnávať relevantnosť obsahu proti požiadavkám trhu práce. Venujte pozornosť tomu, že je možné vziať do úvahy niekoľko osôb s rozhodovacou právomocou, napr.

študenti, zamestnávateľia atď. Výpočet priority alebo váhy každého kritéria a alternatívy na základe párových porovnávacích hodnôt zahŕňa použitie matematických výpočtov, ako je normalizácia porovnávacích hodnôt a výpočet

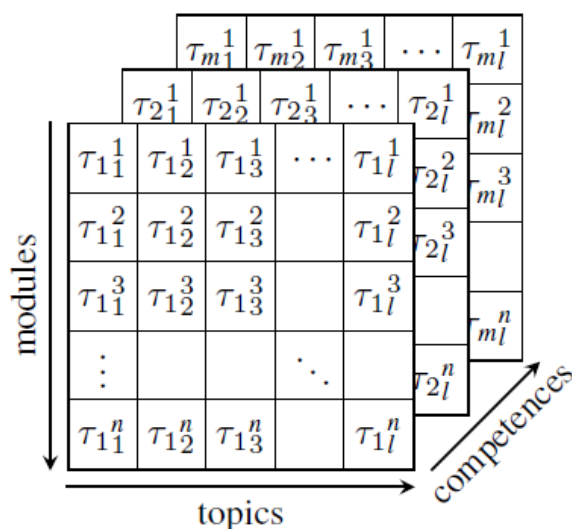


Co-funded by
the European Union

vlastnej hodnoty a vlastného vektora. Výsledkom je súbor prioritných hodnôt, ktoré označujú relatívnu dôležitosť každého kritéria a alternatívy.

Na základe vypočítaných priorit robíme informované rozhodnutia o návrhu školiaceho kurzu. Priority nám v tom pomáhajú

identifikovať najkritickejšie kritériá a najvhodnejšie alternatívy na základe ich relatívnej dôležitosti. To nám umožňuje zamerať sa na aspekty, ktoré majú väčší vplyv na dosiahnutie požadovaných kompetencií.



OBRÁZOK 3. Tenzor mapovanie a vzťah "kompetenčný-téma-modul"

Aplikovaním metódy AHP na tieto aspekty dizajnu kurzov môžu pedagógovia a tvorcovia učebných osnov prijímať informované rozhodnutia, ktoré podporujú efektívne vyučovanie a učenie, sú v súlade so vzdelávacími cieľmi a spĺňajú potreby študentov.

E. TENZOR PRÍSTUP PRE VZŤAHY

Táto metóda predstavuje trojrozmerný tenzor (obr. 3) zložený z témy a kompetencie pomocou zobrazenia založeného na tenzoroch,

čo je spôsob, ako reprezentovať každý modul. Zostrojíte 3D tenzor s binárnymi prvkami τ pomocou vektorov $C \in \mathbb{R}_m, T \in \mathbb{R}_l, aM \in \mathbb{R}_n$ ako smery (obr. 3), spolu s dvoma maticami A_{MC}, A_{CT} ukazujúci booleovské vzťahy medzi vektormi $M a C a C a T$, môžeme použiť nasledujúce výrazy:

$$A_{MC} = \begin{bmatrix} A_{MC}[1,1] & A_{MC}[1,2] & \dots & A_{MC}[1,m] \\ A_{MC}[2,1] & A_{MC}[2,2] & \dots & A_{MC}[2,m] \\ \vdots & \vdots & \ddots & \vdots \\ A_{MC}[n,1] & A_{MC}[n,2] & \dots & A_{MC}[n,m] \end{bmatrix}$$

$$A_{CT} = \begin{bmatrix} A_{CT}[1,1] & A_{CT}[1,2] & \dots & A_{CT}[1,l] \\ A_{CT}[2,1] & A_{CT}[2,2] & \dots & A_{CT}[2,l] \\ \vdots & \vdots & \ddots & \vdots \\ A_{CT}[m,1] & A_{CT}[m,2] & \dots & A_{CT}[m,l] \end{bmatrix}$$

$$T = [\tau_{ij}^k]_{i=1, \dots, m; j=1, \dots, l; k=1, \dots, n}, \quad \text{where } \tau_{ij}^k := A_{MC}[k, i] \cdot A_{CT}[i, j]$$

kde: je logický operátor AND. Tensor T možno skonštruovať aj pomocou Kroneckera produkt (\otimes) z dvoch matic.

IV. VÝSLEDKY

A. ŠTÚDIE TRHU PRÁCE

AAI je veľmi dôležitá oblasť, pokiaľ ide o trh práce. Vidíme, že možností je veľa. V tejto oblasti je možné použiť AI. Umelá inteligencia je dôležitá technológia, ktorá pomáha podnikom zvyšovať efektivitu, znižovať náklady a robiť lepšie rozhodnutia. Vidíme, že vylepšenia AI sú spojené aj s vytváraním nových príležitostí a tvorením

TABLE 2. Positions offered.

Position	Percentage
Data Engineer	25.68%
Data Scientist	22.97%
Data Analyst	10.81%
AI Engineer	10.81%
Other positions	29.73%

TABLE 3. Machine learning problem

Type	Percentage
Classic ML	77.03%
Deep ML	63.51%
SciML	28.38%
Other	5.41%

nové pracovné miesta pre priemysel. Tieto sú obzvlášť dôležité v oblasti vedy o údajoch, strojového učenia a robotiky.

1) Ponúkané pozície na trhu práce

Čo sa týka pozícií na trhu práce v oblasti AAI, ponúkajú sa rôzne dominantné pozície. Tieto pozície sú distribuované po celej EÚ, čo znamená, že AAI



Co-funded by
the European Union

pole je rozšírené po celom svete. Na základe prieskumu trhu práce uvedeného v tabuľke 2, najdominantnejšie pozície ponúkané na trhu sú pozície Data Engineer a Data Scientist s 25,68 % a 22,97 %. Zatiaľ čo dátoví inžinieri sa špecializujú na navrhovanie, budovanie a údržbu infraštruktúry systémov potrebných na spracovanie dát, dátoví vedci sú zodpovední za získavanie poznatkov a poznatkov z dát. Analytici údajov a umelí inžinieri zdieľajú rovnaké percento 10,81 %. To ukazuje, že významná časť pozícií si vyžaduje zameranie sa na interpretáciu a analýzu údajov, so silnými vizualizačnými schopnosťami. Spolu so silnou schopnosťou vyvíjať a nasadzovať systémy a algoritmy AI.

Medzi inými pozíciami neexistuje žiadna špecifická pozícia, ktorá by sa vyskytovala dominantnejšie ako ostatné. Líši sa od vývojových inžinierov po softvérových inžinierov alebo pozície webového vývojára.

2) Problém strojového učenia

Jednou z najdôležitejších informácií relevantných pre trh práce je určitý druh problému strojového učenia

je potrebné vyriešiť. To môže poukazovať na to, ktoré kompetencie môžu byť pre prácu v AAI najdôležitejšie. The

výsledky sú uvedené v tabuľke 3. Na základe výsledkov je zrejmé, že najväčšia časť problémov strojového učenia sa sústreďuje na klasické problémy ML a problémy hlbokého ML. To znamená, že tradičné techniky strojového učenia, ktoré zahŕňajú algoritmy, ako sú rozhodovacie stromy, podporné vektorové stroje a náhodné lesy, sú potrebné, aby boli kompetentné v aplikovanej AI.

Druhým najdôležitejším súborom riešených problémov ML sú problémy Deep ML. Deep ML si za posledných niekoľko rokov získal významnú popularitu a má

TABLE 4. Models being developed

Model	Percentage
Multilayer neural networks - MLP	67.57%
Rules (Classification, Associating)	55.41%
Decision tree	50%
Convolutional neural networks - CNN	45.95%
Recurrent neural networks - RNN	36.49%
Random forest	35.14%
Encoder-decoder networks	13.51%
U-NET	10.81%
GRU	4.05%
LSTM	2.7%

stať sa jedným z najpoužívanejších ML v oblastiach ako počítačové videnie alebo spracovanie prirodzeného jazyka.

Výsledky tiež ukazujú, že je potrebné získať vedecké poznatky z oblasti a začleniť ich do strojového učenia proces. Preto možno konštatovať, že aplikovaná AI má významné uplatnenie v modeloch, ktoré sú orientované na fyzikálne modely, simulácie alebo diferenciálne rovnice [35].

3) Modelky bytievyvinuté

Ako inžinier strojového učenia je jednou z najdôležitejších úloh vyvinúť model, ktorý sa použije v algoritme pre problém v reálnom svete. Vyvíjajú sa rôzne možné modely a ich rozdelenie je uvedené v tabuľke 4.

Tabuľka 4 predstavuje rozdelenie rôznych modelov vyvinutých na trhu práce. MLP ako dopredné neurónové siete s viacerými vrstvami sa široko používajú na úlohy, ako je klasifikácia, regresia a rozpoznávanie vzorov, kvôli ich schopnosti zachytiť zložité vzorce z údajov [36].

Výsledky ukazujú, že jednou z najdôležitejších kompetencií pri práci v aplikovanej AI je vytváranie logických pravidiel na základe podmienok preddefinovaných z reálneho problému. Tieto techniky možno použiť na vytváranie predpovedí a objavovanie korelácií medzi údajmi s rôznym úspechom.

Ukazuje sa, že neurónové siete predstavujú najväčšiu časť modelov vyvíjaných na trhu práce. Konvolučné aj rekurentné neurónové siete môžu byť použité pre mnoho domén, ako je spracovanie obrázkov alebo vizuálnych údajov.

Celkovo údaje ukazujú dominanciu MLP a prístupov založených na pravidlách v kontexte vyvíjaných modelov. Významné podiely majú rozhodovacie stromy a konvolučné a rekurentné neurónové siete. Stojí za zmienku prítomnosť špecifických architektur, ako sú siete kodér-dekodér, U-NET, GRU a LSTM, s menším percentom, čo naznačuje ich význam v určitých špecializovaných aplikáciách v oblasti strojového učenia.

4) Stroj Učenie úlohy do by'vyriešené/

Na trhu práce aplikovanej AI existujú rôzne stroje učebné úlohy, ktoré sa podniky snažia vyriešiť pomocou techník AI. Tieto úlohy sa rozprestierajú v rôznych doménach a odvetviach a vyžadujú si niekoľko zručností v oblasti strojového učenia, aby ste ich mohli efektívne riešiť.

TABLE 5. Machine learning tasks to be solved

Task	Percentage
Classification	68.92%
Regression	58.11%
Clusterization	35.14%
Image classification	28.38%
Image captioning	22.97%
Natural language processing	22.97%
Image segmentation	22.97%
Speech recognition	12.16%

Tabuľka 5 zobrazuje rozdelenie úloh strojového učenia, ktoré je potrebné vyriešiť. Údaje celkovo poukazujú na prevahu klasifikačných a regresných úloh, ktoré sú základnými úlohami strojového učenia, a ich uplatnenie je široké. Naznačuje tiež dôležitosť zručností v oblasti spracovania obrazu a prirodzeného jazyka, ako aj rozpoznávania reči. Klasterizácia, segmentácia obrázkov a popisky demonštrujú špecifické výzvy a aplikácie na trhu práce. Okrem toho rozdelenie úloh odhaľuje význam spracovania obrazu, spracovania prirodzeného



Co-funded by
the European Union

jazyka a rozpoznávania reči ako dôležitých techník, ktoré treba poznať a naučené v kurzoch AI.

Pochopenie distribúcie úloh strojového učenia je cenné pre podniky, ktoré sa snažia aplikovať techniky AI na riešenie problémov v rôznych oblastiach. Vďaka týmto poznatkom im podniky, ktoré používajú techniky AI v rôznych doménach, umožňujú určiť priority a zamerať svoje úsilie na základe významu rôznych úloh.

A. ŠTÚDIE ZAMESTNÁVATEĽOV

Prieskum zhromaždil odpovede od 38 spoločností, aby preskúmal ich potreby a očakávania týkajúce sa školenia špecialistov na aplikovanú AI. Najviac respondentov (86,84 %) zastupuje súkromné organizácie, pričom len 13,16 % uviedlo svoju príslušnosť k verejným organizáciám. Z hľadiska veľkosti organizácie viac ako polovica respondentov (52,63 %) klasifikuje svoje spoločnosti ako malé, približne 26,32 % respondentov svoje spoločnosti kategorizuje ako stredne veľké a 21,05 % respondentov zaraďuje svoje spoločnosti medzi veľké, čo naznačuje, že majú viac ako 250 zamestnancov. Najväčší podiel opýtaných (36,84 %) pracuje v segmente IT služieb. Medzi ďalšie významné segmenty patria iné produktové startupy (15,79 %) a rôzne kategórie (15,79 %). Zastúpené sú aj outsourcing IT, predaj výpočtovej techniky, vývoj hybridného softvéru, out-personing IT, offshore programovanie a herné technológie. Niektoré spoločnosti sú produktové startupy pôsobiace v oblastiach, ako sú administratívne činnosti a MES, vývoj softvéru a outsourcing IT, výskum a technológie (oblasť IT), služby IT, financovanie IT a výskum a vzdelávanie.

Primárne oblasti činnosti deklarované organizáciami sa líšia, pričom hlavnými sú výroba a vývoj (47,37 %), dizajn (39,47 %), poradenstvo (44,74 %), služby zákazníkom (42,11 %) a výskum (39,47 %). domén. Aplikácie a riešenia týchto spoločností pokrývajú rôzne sektory vrátane vzdelávania, verejných služieb, predaja, marketingu, financií, bezpečnosti, zdravotníctva, dopravy a ďalších. Čo sa týka využívania AI v obchodných aktivitách, väčšina organizácií (86,64 %) uvádza, že v súčasnosti využíva AI, zatiaľ čo malá časť (13,16 %) uvádza, že má v úmysle tak urobiť aj v budúcnosti.

Pokiaľ ide o pracovné pozície súvisiace s AI, Data Engineer má najvyššie percento pracovných ponúk (58,33 %), nasleduje Data Analyst (55,56 %) a Data Scientist (44,44 %). Ostatné pozície ako technický náborový pracovník, bezpečnostný inžinier a databázový manažér majú nižšie percentá pracovných ponúk. Čo sa týka požiadaviek na prax, 41,67 % pracovných pozícií nevyžaduje žiadnu prax v AI. Väčšina pozícií vyžaduje prax v rozsahu od krátkej praxe do jedného roka (25 %) až po 1 až 3 roky (27,78 %). Len malé percento pracovných pozícií vyžaduje prax nad 5 rokov (5,56 %). Prieskum tiež skúmal všeobecné kompetencie potrebné pre úlohy súvisiace s AI. Najvyššie percento (60 %) sa pripisuje schopnosti rozpoznáť problémy súvisiace s algoritmickou a dátovou

zaujatosťou, súkromím a integritou dát. Medzi ďalšie vysoko hodnotené kompetencie patrí popis hlavných oblastí AI a jej aplikácií, rozpoznanie užitočnosti metód strojového učenia a identifikácia vhodných výkonnostných metrík na hodnotenie algoritmov strojového učenia. Kompetencie, ako je reprezentácia informácií v logike a pravdepodobnostných formalizmoch a diskusia o účinkoch rozhodnutí vyplývajúcich zo záverov strojového učenia, majú nižšie percentá. Pokiaľ ide o dispozície vyžadované od zamestnancov AI a dátovej vedy, respondenti zdôrazňujú dôležitosť rešpektovania histórie a obmedzení AI, adaptability pri návrhu algoritmov, etického a zodpovedného využívania strojového učenia a dôkladnosti a etiky pri prezentovaní výsledkov. Medzi ďalšie dôležité dispozície patrí výber a hodnotenie algoritmov, presné a etické hodnotiace prístupy, pozornosť venovaná detailom v technikách učenia bez dozoru a zvažovanie kontextovo špecifických výziev. Prieskum skúmal typy problémov strojového učenia, ktoré firmy riešia. Väčšina spoločností (68,57 %) používa klasické a hlboké techniky strojového učenia, zatiaľ čo menšie percento používa metódy SciML (8,57 %). Pokiaľ ide o vyvinuté alebo študované modely, najviac sa spomínajú rozhodovacie stromy a viacvrstvové perceptróny (MLP), za nimi nasledujú pravidlá, konvolučné neurónové siete (CNN) a rekurentné neurónové siete (RNN). V spoločnostiach prevláda používanie neurónových sietí, tradičného aj hlbokého učenia. Medzi najbežnejšie úlohy AI a ML, ktoré spoločnosti riešia alebo študujú, patrí klasifikácia, regresia, klasifikácia obrázkov, zhlukovanie a spracovanie prirodzeného jazyka. Úlohy ako popisovanie obrázkov, rozpoznanie reči a segmentácia obrázkov majú nižšie percentá odpovedí. Python je najčastejšie požadovaný programovací jazyk (85,71 %), za ním nasleduje C++ (45,71 %), Java (42,86 %), R (37,14 %) a C# (22,86 %). Ostatné jazyky ako JavaScript a Matlab sa vyžadujú menej často. Čo sa týka AI knižníc (frameworks), najčastejšie sa používa TensorFlow (78,79 %), nasleduje Keras (48,48 %) a scikit-learn (42,42 %). Iné rámce, ako napríklad PyTorch, Používajú sa aj sady nástrojov Apache TVM, AMD HIP, OpenAI a Matlab, ale v menšej miere. Najpoužívanejším ekosystémom je Anaconda (54,55 %), nasledovaná Apache Hadoop (39,39 %), Matlab (39,39 %) a R Studio (33,33 %). Pre akademických/analytických zamestnancov sú vysoko hodnotené kompetencie, ako je realizácia štúdií uskutočniteľnosti, inovácia a modifikácia metód a aplikácia moderných metód psychológie a pedagogiky. Kompetencie súvisiace so simuláciami, štatistickým overovaním a ochranou autorských práv sú hodnotené relatívne nižšie. Medzi požadované mäkké zručnosti patrí kritické myslenie, komunikácia, práca s nástrojmi a technológiami, plánovanie a organizovanie a základy podnikania. Spolupráca, zameranie sa na zákazníka, dynamická rekvalifikácia a profesionálny networking sú tiež cenené, ale v menšej miere. Podľa výsledkov prieskumu spoločnosti oceňujú dodatočné kompetencie vrátane schopnosti vybrať si vhodné dátové štruktúry a algoritmy, ako aj vizualizovať výsledky analýzy AI. Spoločnosti navyše uprednostňujú kompetencie súvisiace s implementáciou riešení založených na cloud computingu. Na druhej strane kompetencie, ako je analýza hrozieb pre aplikácie v reálnom čase, vývoj a prevádzka ukladania údajov vo veľkom meradle a používanie širokej škály platforiem na analýzu veľkých dát, sa považujú za menej dôležité. Spoločnosti tiež požadujú, aby zamestnanci mali schopnosť implementovať úlohy na úrovni jednotky aj na úrovni všeobecných/univerzálnych problémov, čím preukazujú svoju



Co-funded by
the European Union

všestrannosť a schopnosti riešiť problémy.

Výsledky prieskumu poskytujú cenné poznatky o názoroch a úrovni spokojnosti zamestnávateľov, pokiaľ ide o špecialistov, ktorí ukončili vzdelanie v odbore AI a IT. Zamestnávatelia vyjadrujú obavy z nedostatku AI špecialistov na trhu práce a nedostatku praktických skúseností absolventov. Praktické využitie skúseností so strojovým učením sa považuje za oblasť, ktorá si vyžaduje zlepšenie. Niektorí zamestnávatelia navyše uvádzajú vysoké platové očakávania od špecialistov na AI, čo sťažuje hľadanie vhodných kandidátov na miestnej úrovni. Čo sa týka IT špecialistov, názory sú zmiešané. Zatiaľ čo niektorí zamestnávatelia oceňujú ich dobré zázemie a technické znalosti, iným chýbajú praktické zručnosti. Spolupráca a kreativita sú identifikované ako základné zručnosti pre IT špecialistov a zdá sa, že je k dispozícii adekvátna zásoba mladých talentov. Situácia sa však stáva náročnejšou pri hľadaní špecialistov na strednej alebo vyššej úrovni. Potreba špecialistov na AI je témou diskusií medzi zamestnávateľmi, pričom niektorí tvrdia, že nie sú potrební, zatiaľ čo iní pozorujú značnú medzeru na trhu práce. Spokojnosť zamestnávateľov s úrovňou prípravy magisterských absolventov v oblasti AI je celkovo mierna, pričom väčšina vyjadruje miernu spokojnosť. To naznačuje, že sú potrebné zlepšenia na lepšie zosúladenie zručností absolventov s očakávaniami zamestnávateľov. Zatiaľ čo ponuka AI špecialistov na trhu práce uspokojuje väčšinu spoločností, značná časť nie je uspokojená, čo naznačuje potrebu kvalifikovanejších odborníkov. Spoločnosti majú vo všeobecnosti pozitívne názory na zvyšovanie kvalifikácie svojich súčasných zamestnancov prostredníctvom magisterského štúdia AI, čo naznačuje ochotu investovať do vzdelávania a odbornej prípravy. Pokiaľ ide o kompetencie absolventov vysokých škôl v oblasti AI, spoločnosti to vnímajú neutrálne až pozitívne. Absolventi sa vo všeobecnosti považujú za ľudí s vysokými teoretickými znalosťami, ale názory na praktické využitie týchto vedomostí sa rôznia. Základné znalosti v oblasti podnikového manažmentu, ekonómie a práva sú považované za dobré, rovnako ako pochopenie najnovších medzinárodných štandardov. Osobné atribúty ako inovácia, pracovná etika, osobné ambície a sebahodnotenie dostávajú zmiešané reakcie. Tieto zistenia prieskumu zdôrazňujú potrebu zlepšiť praktické zručnosti a skúsenosti absolventov AI, zosúladiť vzdelávacie programy s požiadavkami odvetvia a preklenúť priepasť medzi teoretickými vedomosťami a ich praktickou aplikáciou. Zamestnávatelia chcú najat' kvalifikovaných špecialistov na AI a sú ochotní investovať do vzdelávania a školenia svojich súčasných zamestnancov. Výsledky tiež zdôrazňujú dôležitosť spolupráce medzi vzdelávacími inštitúciami a zainteresovanými stranami v odvetví s cieľom zabezpečiť pripravenosť absolventov na dynamický trh práce AI.

Výsledky prieskumu poskytujú pohľad na názory zamestnávateľov na projektové aktivity súvisiace s výskumom AI a ich ochotu zúčastniť sa. Vytvorenie webovej stránky na prezentáciu výsledkov výskumu AI miestnou univerzitou považuje

väčšina spoločností za stredne dôležité, pričom 20 % je neutrálnych a menšie percento to považuje za veľmi dôležité. Žiadna zo spoločností nehodnotí nápad ako nedôležitý. To naznačuje všeobecný záujem o prezentovanie výsledkov výskumu AI prostredníctvom vyhradenej webovej stránky. Čo sa týka komunikácie a angažovanosti, značný počet spoločností, 63,89 %, vyjadrilo svoje želanie dostávať newsletter o napredovaní projektu.

Pozoruhodná menšina, 36,11 %, však neprejavuje záujem o takéto informačné bulletiny. Na aktívnu participáciu na rozvoji projektu prostredníctvom školení a prípadových použití 44,74 % firiem reaguje kladne, zatiaľ čo 55,26 % klesá. To naznačuje, že značná časť zamestnávateľov je otvorená zapojeniu sa do aktivít projektu. Čo sa týka prezentácie výsledkov projektu, väčšina firiem (60,53 %) prejavila záujem o pozvanie na multiplikačné podujatie. To dokazuje, že spoločnosti chcú zostať informované o výsledkoch projektu a mať aktuálne informácie o najnovšom vývoji v oblasti AI a Data Science. Zatiaľ čo je všeobecný záujem o webovú stránku prezentujúcu výsledky výskumu AI a získavanie aktuálnych informácií o pokroku, ochota aktívne sa podieľať na vývoji projektu a zúčastniť sa na multiplikačnom podujatí je zmiešanějšía. Pochopenie a prispôbenie sa preferenciám a potrebám zamestnávateľov je kľúčové pre úspešnú implementáciu a šírenie projektu FAAI.

B. ŠTÚDIUM ŠTUDENTOV

Dotazník pre študentov IT, magistrov a absolventov informačných systémov a technológií vyplnilo celkovo 1052 osôb, čo prejavilo veľký záujem o témy AAI v rámci študentskej populácie. Prvá skupina troch otázok v prieskume (otázky 1-3) bola všeobecná s cieľom zistiť základné informácie o skúmaných –

ich národnosť, vek a status študenta. Ako sa očakávalo, študenti väčšinou pochádzali z účastníckych krajín projektu: Poľsko 13,88 %, Srbsko 15,11 %, Bulharsko 34,98 %,

Čierna Hora 19,68 % a Slovensko 10,55 %. Je tam aj 61 osôb (5,8 %) inej národnosti. Respondenti sú vo veľkomväčšina mladších ako 24 rokov - 72,34 % a stále študenti 89,45 % (64,83 % I. stupeň štúdia a 24,62 % II. stupeň štúdia). Len 11,55 % sú absolventi.

Nasledujúci súbor desiatich otázok (otázky 4-13) bol určený len pre študentov. Najprv mali uviesť, na aký stupeň vzdelania sa učia. Najviac respondentov je z bakalárskeho štúdia 72,81 % alebo magisterského štúdia 22,15 % (71,96 % v prvých dvoch rokoch štúdia) so špecializáciou na niektoré variácie v oblasti IT (Informačné technológie 28,69 %, Informatika 25,82 %). Na otázku, či poznajú nejaké kurzy aplikovanej umelej inteligencie ponúkané na ich univerzite, študenti vo veľkej väčšine zvolili odpovede Nie (54,03 %) a Áno, viem len pár (39,25 %), zatiaľ čo odpoveď Áno, viem a len 6,72 % veľa z nich. Aktivity, ktoré študenti najviac preferujú na rozšírenie vedomostí v AAI, sú Projekty (59,22 %), Prednášky (44,49 %) alebo Laboratóriá (38,21 %). Vytvorenie webovej stránky na prezentáciu výsledkov výskumu AAI realizovaného zamestnancami miestnej univerzity je dôležité alebo veľmi dôležité pre takmer 82 % respondentov. Ďalšou významnou otázkou bolo, či sú študenti oboznámení s problematikou AAI, kde len 9,7 % odpovedalo Nie, nepočul som o tom a nemám o takýto



Co-funded by
the European Union

prístup záujem. Na konci tejto časti otázok sa študenti pýtali, či by sa chceli zúčastniť kurzov AAI a veľká väčšina (90,02 %) odpovedala neutrálne alebo kladne (neutrálne – 35,36 %, skôr súhlasím – 29,47 %, súhlasím – 25,19 %).

Tretia skupina otázok s názvom Participácia na školení aplikovanej umelej inteligencie pozostáva len z dvoch otázok (14 a 15) týkajúcich sa kontextu AAI a predchádzajúcich kurzov v oblasti AAI. Len 212 respondentov (20,15 %) sa už zúčastnilo vyučovania na základe AAI. Väčšina študentov prejavila záujem zbierať dáta z rôznych zdrojov (web, sociálne siete atď.) (44,3 %) alebo robiť AAI analytiku/strojové učenie (47,34 %).

Ďalší súbor otázok sa týkal pracovných skúseností (otázky 16 – 19). Takmer polovica opýtaných v súčasnosti pracuje 519/1052 (49,33 %), čo znamená, že veľká časť z nich študuje aj pracuje. Zvyšné otázky v tejto časti majú za cieľ zhromaždiť informácie o dĺžke a povahe zamestnania respondentov. Z 519 pracovníkov ich 347 pracuje v súkromnom sektore, 157 vo verejnom sektore a 11 pracuje v neziskových organizáciách. Podľa očakávania (respondenti sú väčšinou mladší ako 24 rokov), opýtaní majú väčšinou menej ako 3 roky praxe (356 z 519 zamestnaných) a pracujú v IT priemysle (311 z 519).

Títo pracovníci v IT priemysle odpovedali na skupinu otázok (20-23). Otázky boli formulované tak, aby lepšie vystihovali pracovnú pozíciu, požiadavky a skúsenosti IT pracovníkov. Prieskum ukázal, že väčšina IT pracovníkov pracuje ako vývojári softvéru (17,4 %), v podpore (4,75 %), ako správcovia (3,61 %) a v oblasti výstavby a služieb sietí (3,33 %). Viac ako polovica IT pracovníkov uviedla, že na vymenovanie do ich pozície je potrebný bakalársky diplom. Z celkového počtu 1052 respondentov len 136 malo nejaké skúsenosti s prácou v oblasti aplikovanej umelej inteligencie a využívajú ich pri svojej práci.

Možno najdôležitejší súbor otázok pre realizáciu projektu FAAI súvisel s dôležitými kompetenciami potrebnými pre aplikovanú umelú inteligenciu (otázky 24-29). Zo zoznamu viac ako 30 možností mali respondenti možnosť vybrať si, ktoré mäkké zručnosti považujú za najdôležitejšie pre zamestnanie v organizácii, v ktorej pracujú. Len málo zručností vyniká v tom zmysle, že veľká väčšina pracovníkov ich považuje za dôležitejšie ako ostatní: Schopnosť pracovať v tíme (66,73 %), Schopnosť plánovať a riadiť si čas (62,55 %), Schopnosť komunikovať za sekundu (cudzí) jazyk (60,27 %). Populárne boli aj tieto zručnosti: Schopnosť identifikovať, navrhovať a riešiť problémy (55,8 %), Schopnosť učiť sa a držať krok s učením (51,14 %), Schopnosť aplikovať vedomosti v praktických situáciách (50,38 %), Schopnosť vytvárať nové nápady (kreativita) (48,95 %). Ostatné kompetencie boli vyberané menej často a tieto kompetencie boli uznané ako najmenej dôležité: Záväzok k ochrane životného prostredia (11,88 %), Schopnosť preukázať povedomie o rovnosti príležitostí a rodových otázkach (12,36 %), Schopnosť prevziať iniciatívu a podporovať podnikateľského ducha a intelektuálnu zvedavosť (13,5 %).

Na otázku, ktoré kompetencie by mal mať špecialista na AAI, respondenti

väčšinou zvolili odpovede: používanie vhodných tréningových a testovacích metodológií pri nasadzovaní algoritmov strojového učenia, rozpoznanie šírky a užitočnosti metód strojového učenia, výber vhodných (tried) metód strojového učenia špecifické problémy, Porovnávanie a porovnávanie metód strojového učenia. Najcenejšia súvisiaca kompetencia, ktorú by mal mať špecialista na AAI a ktorú by sa mal vyučovať počas školení AAI, je Efektívne využívať rôzne techniky analýzy údajov (strojové učenie, dolovanie údajov, preskriptívna a prediktívna analýza). Najpopulárnejšie nástroje AAI, ktoré sa používajú na podporu teoretických prednášok, sú: Platformy aplikovanej umelej inteligencie (Hadoop, Spark, Data Lakes), aplikovaná umelá inteligencia a distribuované počítačové nástroje (Spark, MapReduce, Hadoop, Mahout, Lucene, NLTK , Pregel) a Google Colab. Najmenej populárne sú: ekosystém Anaconda, R Studio a Mathcad.

C. ŠTÚDIUM AKADEMIKOV

Hodnotenie vzdelávania v oblasti aplikovanej umelej inteligencie: Prieskum perspektív akademikov Táto výskumná štúdia vykonala rozsiahly prieskum na vyhodnotenie súčasného stavu vzdelávania v oblasti aplikovanej umelej inteligencie (AI) medzi akademikmi. Prieskum, ktorý sa uskutočnil v rámci programu FFAI Erasmus+, zozbieral a analyzoval dotazníky od 80 lektorov z piatich krajín. Zistenia poskytujú cenné poznatky o vyučovacích postupoch, kompetenciách a oblastiach na zlepšenie v aplikovanom vzdelávaní AI.

Výsledky ukázali, že značný počet respondentov boli začiatníci v oblasti aplikovanej AI, zatiaľ čo väčšina respondentov tvrdila, že majú zručnosti na strednej úrovni. Pokročilú úroveň uviedlo 23,75 % účastníkov, pričom len 7,50 % sa považovalo za expertov. Prieskum preto predstavuje skôr komplexný prehľad než úzky odborný pohľad.

Jedným z pozoruhodných zistení bolo, že viac ako polovica učiteľov bola samouk v umelej inteligencii, nasledovaná tými, ktorí absolvovali hodiny AI počas vysokoškolského štúdia. Len necelá pätina absolvovala špecializované kurzy AI. Čo sa týka preferovaných aktivít na rozšírenie vedomostí, najobľúbenejšou voľbou boli tematické kurzy, zatiaľ čo účasť na konferenciách bola polovičná. Komerčné projekty, open-source projekty, zapojenie sa do verejných vedeckých skupín a spoznávanie výsledkov výskumu realizovaného na univerzitách získali podobnú mieru podpory (okolo 50 percent).

Štúdia poukázala na to, že značnému počtu učiteľov chýbali skúsenosti s výučbou AI a mali obmedzenú publikačnú a výskumnú účasť v aplikovaní AI (takmer štyridsať percent nikdy nepublikovalo článok o aplikovanej AI a iba polovica sa zúčastnila na aplikovanom výskume AI). To zdôrazňuje potrebu zapojiť viac kolegov do projektov AI, vzhľadom na ich evidentný záujem. Viac ako 50 % učiteľov však malo aspoň jeden rok pedagogickej praxe a takmer jedna pätina mala viac ako päťročnú pedagogickú prax, čo z nich urobilo odborníkov. Len 15 % učiteľov vyjadrilo nezáujem o výučbu AI.

Je zaujímavé, že väčšina učiteľov sa nezúčastnila na komerčných projektoch AI, ale vyjadrila pozitívny sklon k zapojeniu externých expertov na AI z priemyslu (niekoľko súhlasí 37,50 %, súhlasí 42,50 %, nikto nebol proti expertom z priemyslu). Medzi respondentmi panoval silný konsenzus, pokiaľ ide o dôležitosť zahrnutia aplikovaných kompetencií AI do učebných osnov, ako sú



Co-funded by
the European Union

hlavné oblasti AI vrátane kontextu aplikácií, rozpoznávanie dychu a užitočnosti metód strojového učenia (ML) a ich praktická implementácia. Zahŕňa potrebu porovnať metódy ML a vybrať vhodnú spolu s jej školením a testovaním. Pokročilé témy, ako je nadmerná montáž, prekliatie rozmerov, metriky výkonu, algoritmus a skreslenie údajov, sa však považovali za menej kritické.

Význam diskusie o potenciálnych dôsledkoch rozhodovania vyplývajúceho zo strojového učenia (ML) získal od respondentov relatívne obmedzenú pozornosť, čo naznačuje, že sa to nepovažuje za veľmi dôležité. Podobné výsledky boli pozorované v súvislosti s etickými úvahami týkajúcimi sa systémov AI. Je pravdepodobné, že učiteľia vnímali získavanie komplexných vedomostí o samotných metódach ako prvoradú pozornosť študentov, pretože debata o používaní a etike by bola zbytočná bez solidného pochopenia fungovania týchto metód. Okrem toho význam logiky a pravdepodobnostného formalizmu spolu s ich uvažovaním sa tiež považoval za relatívne menej významný.

Na podporu vzdelávania v oblasti AI respondenti zdôraznili význam význam zariadenia webovej stránky s miestnym univerzitným výskumom o aplikovanej AI a vytvorením open source projektov venovaných riešeniu problémov AI. Zdôraznili tiež dôležitosť ústnych prezentácií, študentských vedeckých skupín, ako aj webinárov, ale podpora spolupráce s odborníkmi zo spoločností AI sa považuje za najdôležitejšiu pre lepšie pochopenie záležitostí aplikovanej AI. Pre študentov sú požiadavky trhu práce považované za dôležité, ale na získanie kritických praktických znalostí AI je potrebná spolupráca so spoločnosťami AI.

Z odporúčaní učiteľa je možné vybrať nasledujúce rady pre učebné osnovy:

- Zamerajte sa viac na bezplatné verzie.
- Najprv vyberte správny výpočtový jazyk a knižnice
- Pozornosť na počítačové videnie, vysvetliteľná AI, ľudská Interakcia AI
- Pridajte viac aktivít pomocou príkladov
- Riešenie skutočných prípadov AI na hodinách

Skutočnosť, že ani vysokoškolské, ani špecializované kurzy nie sú významným zdrojom zručností ani medzi pedagógmi, svedčí o potrebe skvalitňovania tak univerzitných, ako aj špecializovaných kurzov. Štúdia odhalila potrebu zlepšiť univerzitné kurzy a špecializované školiace programy pre aplikovanú AI. Väčšina učiteľov vyjadrila želanie zúčastniť sa sponzorovaných kurzov AI, aby si rozšírili svoje vedomosti. Zatiaľ čo väčšina učiteľov príležitostne skúmala najnovšie trendy AI, takmer pätina priznala, že má len základné znalosti. Na otázku o oboznámení sa s najnovšími trendmi, technikami, riešeniami aplikovanej umelej inteligencie väčšina ľudí odpovedala, že príležitostne skúmajú oblasť a. Dotazníky neprekvapivo odhaľujú, že je potrebné, aby učiteľia zlepšili svoje zručnosti vo vyučovaní a propagácii aplikovanej AI. Identifikovali sa prekážky zvyšovania aplikovaného vzdelávania AI, vrátane problémov so študijným programom, formálnych prekážok

boli ďalej analyzované s cieľom získať cenné poznatky a hlbšie pochopiť ich charakteristiky, ciele a výsledky. Obrázok 5 predstavuje analýzu cieľov projektu pomocou slovného cloudu, zatiaľ čo obrázok 6 zobrazuje vizualizáciu výsledkov projektu pomocou slovného cloudu, pričom poskytuje prehľad o primárnych zámeroch a zámeroch, ako aj o významných výstupoch a úspechoch analyzovaných projektov. Rozdiel v počte analyzovaných výsledkov so 63 výsledkami v porovnaní s 52 možno pripísať skutočnosti, že niektoré projekty stále prebiehajú, a preto ešte neprinesli konečné výsledky.

Dva oblaky slov zobrazujú základné zameranie na vytvorenie „projektu“, ktorý zahŕňa vývoj „systému“ pomocou „metód učenia“, čo vedie k vytvoreniu „modelu“ ako životaschopného riešenia. Z hľadiska aplikačných oblastí je evidentná dominancia „video“ riešení. Z technologického hľadiska sú „behaviorálne“, „hlbkové“ a „neurálne“ aplikácie najobľúbenejšie. Ďalej preferencia spočíva v dosahovaní „efektívnych“ a „významných“ výsledkov. Nakoniec bol analyzovaný cieľ reálnej prípadovej štúdie AAI, ktorá zahŕňala výskum na 276 príkladoch. Zistenia sú prezentované na obrázku 7.

Podobne ako pri analýze zodpovedností za pracovné ponuky, slovo cloud image odhaľuje, že kľúčovým zameraním je požiadavka na „systémy“ postavené na „údajoch“, kde sa „model“ generuje prostredníctvom „stroja“ a „umelého“ inteligencie „učenie“. Okrem toho sa kladie dôraz na využitie „energie“, zatiaľ čo riešenia založené na „obrazku“ sú na poprednom mieste. Uprednostňujú sa „hlbkové“ riešenia a často sa spomínajú oblasti použitia „siet“, „medicína“, „obchod“ a „údržba“.

OBRÁZOK 7. ReálnyCiele prípadovej štúdie Word Cloud*E. PROBLÉMY ROZHODOVANIA NA ZÁKLADE AHPANALÝZA*

Výsledky prieskumu, ktoré boli prezentované v sekciách II-D, II-E, II-F, IV-A, IV-B, IV-C, IV-D boli použité ako

štatistiky na určenie atribútov alternatív v rámci série problémov rozhodovania, ktoré budú popísané v nasledujúcich podkapitolách. Zohľadní sa viacero osôb s rozhodovacou právomocou pochádzajúce z rôznych prieskumov (trh práce, akademici, študenti, zamestnávateľia, osvedčené postupy).

Na priradenie hodnôt reprezentujúcich relatívnu dôležitosť alebo preferenciu sme použili škálu AHP (1 až 5). Párové porovnania alternatív sa uskutočnili pomocou výpočtu buď párových preferencií alebo pomocou párových funkcií, ako sú:

```
pairwiseFunction:funkcia(a1, a2) min(5,  
max(1/5, a1$atribút/a2$atribút))
```

Tu sú a1, a2 alternatívy, ktoré sa majú porovnávať vzhľadom na atribút.

1) Priority kompetencií z pohľadu AI MLV danom rozhodovacom probléme je na obrázku 8 uvedený model rozhodovacieho procesu. Problém sa týka 12 kompetencií súvisiacich s AI a ML. Tvorcovia rozhodnutí zahŕňajú zástupcov trhu práce, akademikov, študentov a zamestnávateľov.

Obrázky 9-13 zobrazujú priority pre špecifické skupiny kritérií z pohľadu príslušných rozhodovacích orgánov. Tieto čísla predstavujú relatívnu dôležitosť, ktorú každá skupina pripisuje rôznym kompetenciám. Priority sa určujú prostredníctvom párového porovnávacieho procesu, kde osoby s rozhodovacou právomocou porovnávajú každú kompetenciu s ostatnými na základe ich významnosti.

2) Programovacie jazyky vo vzťahu k dedikovanému serveru a cloudové riešenie
Výber programovacieho jazyka je pri štúdiu AI skutočne dôležitý, pretože môže výrazne ovplyvniť schopnosť efektívneho vývoja systémov AI. Kritériá pri výbere jazyka zahŕňajú podporované knižnice a rámce, živú komunitu a zdroje, flexibilný a expresívny kód, výkon a efektívnosť, integráciu a nasadenie a trendy v odvetví.

Tu, v kontexte určovania priorít programovacieho jazyka pre kurz AI, sa AHP využilo na začlenenie názorov rozhodujúcich činiteľov, akými sú trh práce, zamestnávateľia a riešenia dobrej praxe (pozri model na obr. 14).

Priority získané od každého s rozhodovacou právomocou sú agregované, aby sa vytvoril komplexný súbor priorít pre programovacie jazyky v kurzoch AI (pozri obr. 15-18). Dosiahlo sa to výpočtom vážených priemerov prioritných vektorov rozhodovacích orgánov.

3) Modely umelej inteligencie v rámci Klasický ML a hlboký ML

Z hľadiska klasického ML by sa tvorcovia rozhodnutí mali zamerať na štúdium dobre zavedených algoritmov strojového učenia, ako sú lineárna regresia,



**Co-funded by
the European Union**

rozhodovacie stromy a podporné vektorové stroje, ktoré sú široko používané a testované na trhu práce, ktoré uprednostňujú zamestnávateľov a považujú sa za osvedčené postupy v oblasti AI. Z pohľadu Deep ML by osoby s rozhodovacou právomocou mali uprednostňovať štúdium hlbokých neurónových sietí, konvulučných neurónových sietí a rekurentných neurónových sietí, pretože tieto modely preukázali pozoruhodný výkon v rôznych aplikáciách AI, sú veľmi žiadané na trhu práce. od zamestnávateľov a odzrkadľujú aktuálne osvedčené postupy v oblasti AI.

Pri pokuse riešiť daný rozhodovací problém numericky je na obrázku 19 znázornený vývojový diagram rozhodovacieho procesu. Problém sa týka 10 modelov súvisiacich s klasikou a DL. Medzi tých, ktorí rozhodujú, patria zástupcovia trhu práce, zamestnávatelia a riešenia osvedčených postupov.

Obrázky 20-23 zobrazujú priority pre špecifické skupiny kritérií z pohľadu príslušných rozhodovacích orgánov. Tieto čísla predstavujú relatívnu dôležitosť, ktorú každá skupina pripisuje rôznym modelom AI. Priority sú určené prostredníctvom párového porovnávacieho procesu, kde osoby s rozhodovacou právomocou porovnávajú každú kompetenciu s ostatnými na základe ich významnosti.

F. TENZOROVÝ KURZREPREZENTÁCIA

Na základe predchádzajúcich štúdií sme určili vektory C (Tabuľka 6), T (Tabuľka 7), M (Tabuľka 8). Okrem toho sú matice AMC a ATC uvedené v tabuľke 10 a tabuľke 9. Vynásobením zodpovedajúcich záznamov dostaneme tenzor t_{ijk} .

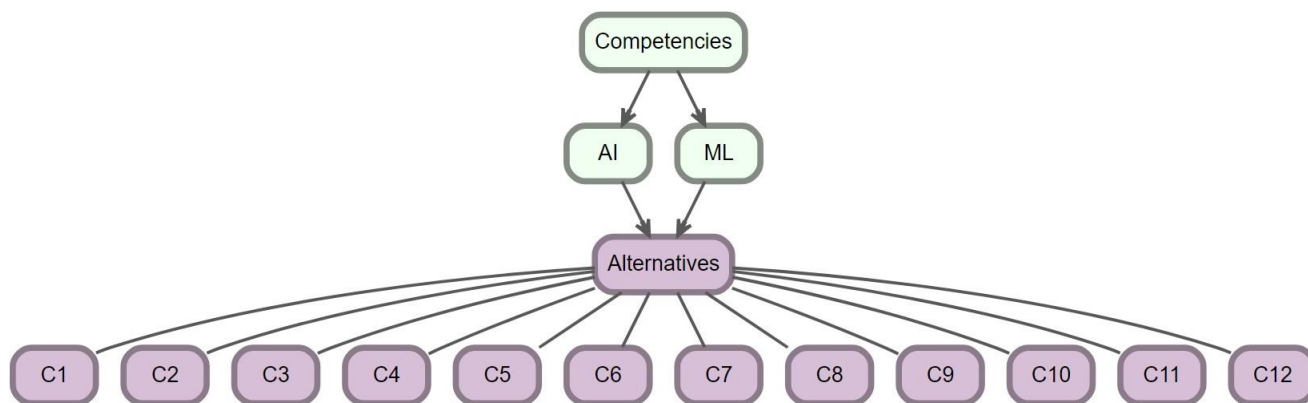
Generovanie abstrahovaných modelov modulov je teraz možné vďaka rozkladu tenzorov. Každý tenzor sa skladá z troch vzťahov alebo vzťahov „kompetencia-téma-modul“. Každý tenzor je potom vlastnosť, ktorá sa skladá z váženého súčtu tenzorov poradia jedna získaných vynásobením trojfaktorových vektorov.

Takýto prístup nám umožnil získať sériu matíc pre vzťahy „modul-téma“ podľa rôznych kompetencií. Obrázok 3 zobrazuje tenzor, ktorého komponenty sú: témy, moduly a kompetencie. Formovanie želanej kompetencie je možné dosiahnuť realizáciou oboch špecifických tém a modulov.

Tabuľka 9 zobrazuje krížovú maticu „kompetencie v oblasti tém“ pre 12 kľúčových kompetencií vo vysokoškolskom vzdelávaní AI, ktoré možno získať realizáciou vybraných z 12 tém uvedených v tabuľke

7. Tak napríklad kompetenciu s názvom: „Rozpoznať dych a užitočnosť metód strojového učenia“ možno dosiahnuť realizáciou nasledujúcich tém: Expertné systémy založené na pravidlách; Strojové učenie I; Strojové učenie II; Základy hlbokéj neutrálnej siete; Hlboká neutrálna sieť – pokročilé témy; Hlboké posilňovanie učenia; Spracovanie prirodzeného jazyka; Robotické.

S cieľom posilniť kvalitu vzdelávania a zároveň zabezpečiť vysoký štandard vzdelávania navrhujeme posilniť túto kompetenciu implementáciou špecifických modulov.



OBRÁZOK 8. Model pre rozhodovanie o kompetenciách ovplyvnených AI a ML

	Weight	C1	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C2	Inconsistency
Competencies	100.0%	23.0%	7.0%	7.0%	7.0%	7.0%	7.0%	7.0%	7.0%	7.0%	7.0%	7.0%	7.0%	0.0%
ML	78.3%	18.0%	5.5%	5.5%	5.5%	5.5%	5.5%	5.5%	5.5%	5.5%	5.5%	5.5%	5.5%	0.0%
AI	21.7%	5.0%	1.5%	1.5%	1.5%	1.5%	1.5%	1.5%	1.5%	1.5%	1.5%	1.5%	1.5%	0.0%

OBRÁZOK 9. Priority pre kompetencie ovplyvnené AI a ML: celkový výsledok

	Weight	C1	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C2	Inconsistency
Competencies	100.0%	45.0%	5.0%	5.0%	5.0%	5.0%	5.0%	5.0%	5.0%	5.0%	5.0%	5.0%	5.0%	0.0%
ML	83.3%	37.5%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	0.0%
AI	16.7%	7.5%	0.8%	0.8%	0.8%	0.8%	0.8%	0.8%	0.8%	0.8%	0.8%	0.8%	0.8%	0.0%

OBRÁZOK 10. Priority pre kompetencie ovplyvnené AI a ML: trh práce ako rozhodovateľ

	Weight	C1	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C2	Inconsistency
Competencies	100.0%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	0.0%
AI	50.0%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	0.0%
ML	50.0%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	4.2%	0.0%

OBRÁZOK 11. Priority pre kompetencie ovplyvnené AI a ML: akademici ako tí, ktorí rozhodujú



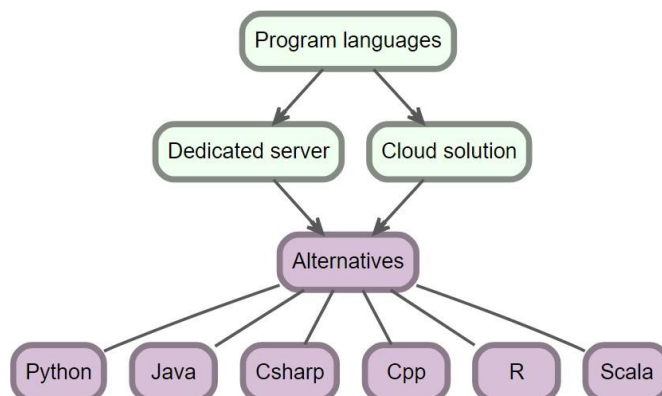
Co-funded by
the European Union

	Weight	C1	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C2	Inconsistency
Competencies	100.0%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	0.0%
ML	75.0%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.2%	0.0%
AI	25.0%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	0.0%

OBRÁZOK 12. Priority pre kompetencie ovplyvnené AI a ML: študenti ako tí, ktorí rozhodujú

	Weight	C1	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C2	Inconsistency
Competencies	100.0%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	0.0%
ML	87.5%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	7.3%	0.0%
AI	12.5%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	1.0%	0.0%

OBRÁZOK 13. Priority pre kompetencie ovplyvnené AI a ML: zamestnávateľia ako osoba s rozhodovacou právomocou



OBRÁZOK 14. Model pre rozhodovanie o programovacích jazykoch v porovnaní s dedikovanými servermi alebo cloudovými riešeniami

TABLE6. Kompetencie z AI a ML, ktoré má pokrývať navrhovaný kurz aplikovanej AI

denotačná kompetencia

C₁ Opište hlavné oblasti AI, ako aj kontexty, v ktorých možno metódy AI použiť.

C₂ Reprezentovať informácie v logickom formalizme a aplikovať relevantné metódy uvažovania.

C₃ Reprezentovať informácie v pravdepodobnostnom formalizme a aplikovať relevantné metódy uvažovania.

- C₄ Uvedomte si širokú škálu etických úvah týkajúcich sa systémov AI, ako aj mechanizmov na zmiernenie problémov.
- C₅ Rozpoznať šírku a užitočnosť metód strojového učenia
- C₆ Porovnajte a porovnajte metódy strojového učenia.
- C₇ Vyberte vhodné (triedy) metód strojového učenia pre konkrétne problémy.
- C₈ Pri nasadzovaní algoritmov strojového učenia používajte vhodné školiace a testovacie metodiky.
- C₉ Vysvetlite metódy na zmiernenie účinkov nadmerného prispôsobenia a priebehu dimenzionality v kontexte algoritmov strojového učenia.
- C₁₀ Identifikujte vhodnú metriku výkonu na vyhodnotenie algoritmov/nástrojov strojového učenia pre daný problém.
- C₁₁ Rozpoznať problémy súvisiace so skreslením algoritmov a údajov, ako aj so súkromím a integritou údajov.
- C₁₂ Diskutujte o možných účinkoch – pozitívnych aj negatívnych – rozhodnutí vyplývajúcich zo záverov strojového učenia.

TABLE7. Témy z AI a ML, ktoré má pokryť navrhovaný kurz aplikovaná AI

denotát	tému
T ₁	Umelá inteligencia – modely založené na histórii a logike
T ₂	Reprezentácia znalostí a uvažovanie (na základe pravdepodobnosti)
T ₃	AI-plánovanie a stratégie vyhľadávania
T ₄	Fuzzy logika, fuzzy riadiace systémy
T ₅	Expertné systémy založené na pravidlách
T ₆	Strojové učenie I (prehľad a učenie pod dohľadom)
T ₇	Strojové učenie II (učenie bez dozoru)
T ₈	Hlboké neurónové siete – základy
T ₉	Hlboké neurónové siete – pokročilé témy
T ₁₀	Hlboké posilňovanie učenia
T ₁₁	Spracovanie prirodzeného jazyka
T ₁₂	robotické

TABUĽKA 8. Moduly navrhovaného kurzu o AAI

M ₁	Basic principles of the application of AI in science and in modern business solutions
M ₂	Embeddable modules from IBM, Microsoft, Google, AWS, etc.
M ₃	Conducting research related to the practical application of artificial intelligence
M ₄	Building software applications using AI
M ₅	Implementation of external AI modules in software applications
M ₆	AI-based solutions for Ecology
M ₇	AI-based solutions for Agriculture
M ₈	AI-based solutions for HealthCare
M ₉	AI-based solutions for Smart City
M ₁₀	AI-based solutions for Industry
M ₁₁	AI-based solutions in Robotics
M ₁₂	Application of other AI modules

TABLE 9. Krížová matica pre a vzťah "kompetenčná téma" pre AAIkurz



Co-funded by
the European Union

	T ₁	T ₂	T ₃	T ₄	T ₅	T ₆	T ₇	T ₈	T ₉	T ₁₀	T ₁₁	T ₁₂
C ₁	1	0	0	0	0	0	0	0	0	0	0	0
C ₂	1	1	0	0	0	0	0	0	0	0	0	0
C ₃	0	1	0	0	0	0	0	1	0	0	0	0
C ₄	1	1	1	1	1	1	1	0	1	1	1	1
C ₅	0	0	0	0	0	1	1	1	1	1	1	1
C ₆	0	0	0	0	0	1	1	1	1	1	1	1
C ₇	0	0	0	0	0	1	1	1	1	0	1	1
C ₈	0	0	0	0	0	1	1	1	1	1	0	0
C ₉	0	0	0	0	0	1	1	0	1	1	0	0
C ₁₀	0	0	0	0	0	1	1	1	1	0	0	0
C ₁₁	1	1	1	1	1	1	1	0	1	1	1	1
C ₁₂	0	0	0	0	0	1	1	0	1	1	1	1

Tabuľka 10 zobrazuje krížovú maticu "modul - kompetencia". Z toho vidno, že vzdelávanie želaných kompetencií bolo posilnené realizáciou určitých modulov. Napríklad vzdelávanie predtým vybranej kompetencie „Rozpoznať dych a užitočnosť metód strojového učenia“ bolo posilnené realizáciou nasledujúcich modulov: M1 (Základné princípy aplikácie AI vo vede a v moderných podnikových riešeniach.) a M3 (Vedenie výskumu súvisiaceho s aplikáciou princípov umelej inteligencie). Každú kompetenciu je teda možné získať absolvovaním špecifických tém a modulov. kompetencie. Tieto tabuľky obsahujú hodnotu „1“

TABLE10.Krížová matica pre vzťah "kompetenčný modul".implementované v navrhnutom kurze AAI

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
C ₁	1	1	1	0	1	0	0	0	0	0	0	1
C ₂	0	1	0	0	1	0	0	0	0	0	0	1
C ₃	0	1	0	0	1	0	0	0	0	0	0	1
C ₄	0	1	1	0	1	0	0	0	0	0	0	1
C ₅	1	0	1	0	0	0	0	0	0	0	0	0
C ₆	0	1	0	1	1	1	1	1	1	1	1	1
C ₇	1	0	1	0	0	1	1	1	1	1	1	0
C ₈	1	0	0	1	0	1	1	1	1	1	1	0
C ₉	0	0	0	1	0	1	1	1	1	1	1	0
C ₁₀	0	0	0	1	0	1	1	1	1	1	1	0
C ₁₁	0	0	0	0	0	1	1	1	1	1	1	0
C ₁₂	0	0	0	0	0	1	1	1	1	1	1	0

	Weight	Python	Java	Csharp	Cpp	R	Scala	Inconsistency
Program languages	100.0%	40.7%	18.6%	11.1%	11.1%	9.6%	9.0%	0.0%
Cloud solution	51.8%	22.2%	11.4%	7.1%	2.7%	2.7%	5.6%	4.4%
Dedicated server	48.2%	18.5%	7.2%	4.0%	8.3%	6.9%	3.3%	2.8%

OBRÁZOK 15. Priority pre program jazykoch príbuzný do oddaný server alebo oblak Riešenie: Celkomrozhodnutie

	Weight	Python	Java	Csharp	Cpp	R	Scala	Inconsistency
Program languages	100.0%	44.5%	12.0%	14.2%	10.5%	11.3%	7.4%	0.0%
Dedicated server	50.0%	20.7%	4.4%	5.2%	8.0%	8.8%	2.8%	0.6%
Cloud solution	50.0%	23.8%	7.6%	9.0%	2.5%	2.5%	4.6%	4.4%

OBRÁZOK 16. Priority pre program jazykoch príbuzný do oddaný server alebo oblak Riešenie: rozhodnutie od hľadisko z prúcturhu

	Weight	Python	Java	Csharp	Cpp	R	Scala	Inconsistency
Program languages	100.0%	34.7%	21.8%	16.1%	12.0%	10.8%	4.5%	0.0%
Dedicated server	50.0%	15.8%	8.9%	5.9%	9.4%	8.1%	1.9%	1.7%
Cloud solution	50.0%	18.9%	12.9%	10.2%	2.6%	2.6%	2.6%	2.9%

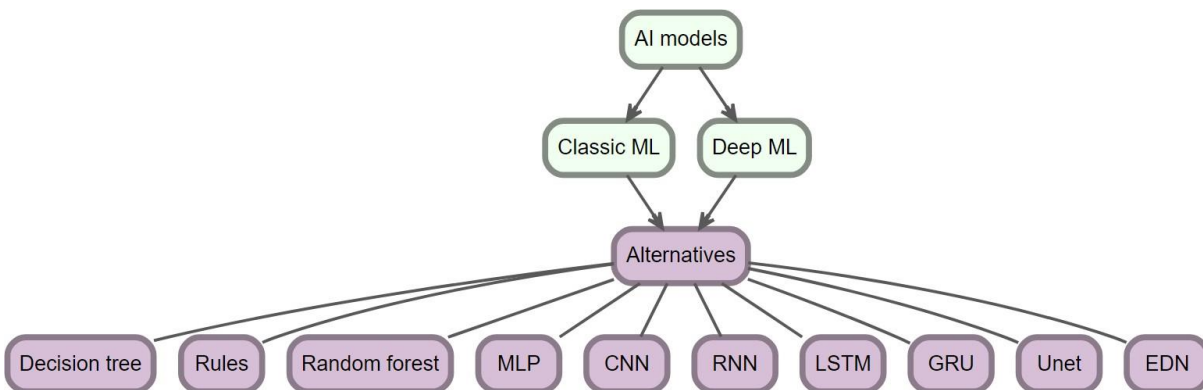
OBRÁZOK 17. Priority pre program jazykoch príbuzný do oddaný server alebo oblak Riešenie: rozhodnutie od hľadisko z zamestnávatelia

	Weight	Python	Java	Csharp	Cpp	R	Scala	Inconsistency
Program languages	100.0%	42.3%	21.0%	4.8%	10.8%	7.6%	13.5%	0.0%
Cloud solution	54.5%	23.6%	13.2%	3.0%	3.0%	3.0%	8.9%	4.0%
Dedicated server	45.5%	18.7%	7.8%	1.8%	7.8%	4.7%	4.7%	2.8%

OBRÁZOK 18. Priority pre program jazykoch príbuzný do oddaný server alebo oblak Riešenie: rozhodnutie od hľadisko z dobre prax vAAI



Co-funded by the European Union



OBRÁZOK 19. Model pre rozhodovanie o modeli AI v porovnaní s klasickým alebo hlbokým ML

	Weight	CNN	RNN	MLP	Decision tree	Random forest	Rules	EDN	Unet	LSTM	GRU	Inconsistency
AI models	100.0%	18.2%	13.9%	11.2%	11.0%	10.4%	8.1%	8.0%	6.8%	6.4%	6.0%	0.0%
Deep ML	59.7%	16.6%	12.2%	2.6%	2.6%	2.6%	2.6%	6.3%	5.2%	4.7%	4.4%	1.4%
Classic ML	40.3%	1.7%	1.7%	8.6%	8.4%	7.8%	5.5%	1.7%	1.7%	1.7%	1.7%	0.3%

OBRÁZOK 20. Model pre rozhodovanie o modeli AI v porovnaní s klasickým alebo hlbokým ML: úplné rozhodnutie

	Weight	CNN	RNN	MLP	Decision tree	Random forest	Rules	EDN	Unet	LSTM	GRU	Inconsistency
AI models	100.0%	13.9%	12.7%	13.4%	12.1%	11.0%	12.5%	8.1%	7.0%	4.4%	5.0%	0.0%
Classic ML	54.8%	2.1%	2.1%	11.7%	10.4%	9.3%	10.8%	2.1%	2.1%	2.1%	2.1%	0.3%
Deep ML	45.2%	11.8%	10.6%	1.7%	1.7%	1.7%	1.7%	6.0%	4.9%	2.3%	2.9%	1.2%

OBRÁZOK 21. Model pre rozhodovanie o modeli AI vo vzťahu ku klasickému alebo hlbokému ML: rozhodnutie na základe požiadaviek trhu práce

	Weight	CNN	RNN	MLP	Decision tree	Random forest	Rules	EDN	Unet	LSTM	GRU	Inconsistency
AI models	100.0%	13.1%	10.5%	11.3%	11.7%	10.2%	11.3%	9.2%	7.1%	8.7%	7.1%	0.0%
Classic ML	50.0%	1.9%	1.9%	9.8%	10.2%	8.7%	9.8%	1.9%	1.9%	1.9%	1.9%	0.2%
Deep ML	50.0%	11.2%	8.6%	1.5%	1.5%	1.5%	1.5%	7.3%	5.2%	6.8%	5.2%	1.4%

OBRÁZOK 22. Model pre rozhodovanie o modeli AI v porovnaní s klasickým alebo hlbokým ML: zamestnávateľ ako osoba s rozhodovacou právomocou

	Weight	CNN	RNN	MLP	Decision tree	Random forest	Rules	EDN	Unet	LSTM	GRU	Inconsistency
AI models	100.0%	26.7%	17.2%	9.5%	9.5%	9.5%	5.5%	5.5%	5.5%	5.5%	5.5%	0.0%
Deep ML	77.8%	25.7%	16.2%	4.5%	4.5%	4.5%	4.5%	4.5%	4.5%	4.5%	4.5%	0.6%
Classic ML	22.2%	1.0%	1.0%	5.1%	5.1%	5.1%	1.0%	1.0%	1.0%	1.0%	1.0%	0.0%

OBRÁZOK 23. Model pre rozhodovanie o modeli AI vo vzťahu ku klasickému alebo hlbokému ML: rozhodnutie z hľadiska požiadaviek dobrej praxe

kedy bude vzdelávanie danej kompetencie možné realizáciou zvoleného modulu aj zvolenej témy,

a "0", keď realizácia danej témy nie je vhodná na realizáciu určitého vybraného modulu. Tabuľky

13 - 24 sú tu uvedené matice vytvorené vynásobením tém vektorom modulov, napríklad pre tabuľku

13: Kompetencie: Bude možné opísať hlavné oblasti AI a kontexty, v ktorých sa dajú metódy AI aplikovať.

dokončením témy 1 (T_1 - História umelej inteligencie a modely založené na logike) a moduly (M_1 - Základné

princípy aplikácie umelej inteligencie vo vede a moderných podnikových riešeniach; M_2 - vstavané moduly IBM,

Microsoft, Google, AWS atď.; M_3 - Vedenie výskumu súvisiaceho s praktickou aplikáciou umelej inteligencie;

M_{12} - Aplikácia iných modulov AI). Analogickú interpretáciu možno urobiť analýzou zostávajúcich tabuliek.

IV. DISKUSIA

A. POŽIADAVKY TRHU PRÁCCCE

Trh práce s aplikovanou AI je dynamický a vyvíja sa. Od rôznych programovacích zručností až po znalosť návrhových vzorov alebo špecifické požiadavky na vzdelanie. Nasledujúce kapitoly ukazujú distribúciu a informácie o nevyhnutných požiadavkách, ktoré musí mať jednotlivec, aby bol kompetentný v oblasti AAI.

1) Požadované programovacie jazyky

Znalosť programovacích zručností je spojená so špecifickým programovacím jazykom potrebným v aplikovaných technikách AI. Tabuľka 11 poskytuje informácie o tom, ktoré programovacie jazyky sú v aplikovanej AI najpotrebnejšie.



Co-funded by
the European Union

TABLE 11. Required programming languages

Language	Percentage
Python	79.73%
R	28.38%
C++	25.68%
C#	14.86%
Java	12.16%

Ako sa dalo očakávať, Python je programovací jazyk, ktorý je najviac potrebný v oblasti aplikovanej AI. To ukazuje, že väčšina kurzov by sa mala zamerať na poskytovanie podrobného učebného plánu programovacieho jazyka Python a knižníc, ktoré sú vhodné pre túto oblasť. Toto percento vyplýva z jednoduchosti Pythonu a obrovského ekosystému, ktorý je možné použiť pre rôzne domény.

Ostatné programovacie jazyky sú na celkom sim-ilar scale, s programovacím jazykom R zvoleným na 28,38 %, čo nám ukazuje, že významná časť kompetencií je orientovaná na štatistické výpočty a analýzu a vizualizáciu vďaka rozsiahlej zbierke štatistických knižníc a balíkov.

Výsledky tiež ukazujú, že ďalšie požadované programovacie jazyky sú Java, C# a C++.

2) Vzdelávacie Požiadavky

Tabuľka 12 ukazuje údaje o tom, aké požiadavky na vzdelanie je potrebné mať, aby ste mohli pracovať v AAI.

Vzdelávacie požiadavky v aplikovanej AI zvyčajne zahŕňajú pevné základy v matematike, konkrétnejšie v štatistike a štatistickej analýze a informatike. Údaje ukazujú, že bakalársky titul z informatiky je často

TABUĽKA 12.Vzdelávacie požiadavky

Titul	Percento
Bakalársky titul - odbor súvisiaci s informatikou	33,78 %
Magisterské štúdium - odbor súvisiaci s informatikou	29,73 %
Žiadna úroveň vzdelania, iba zručnosti	27,03 %
Iné	9,46 %

minimálna požiadavka, sprevádzaná magisterským titulom, oba tituly v odboroch

súvisiacich s počítačovou vedou.

Hoci doktorandské štúdium v týchto odboroch poskytuje hlbšie znalosti a špecializáciu, štúdium ukazuje, že doktorandské štúdium vo všeobecnosti nie je nevyhnutnou úrovňou vzdelania. Oveľa dôležitejšie je mať zručnosti, čo znamená, že študenti aj kurzy by si mali vynútiť neustále vzdelávanie a certifikácie a mali by zostať v obraze v oblasti AAI.

3) Požadovaný Kompetencie

Jedným z najdôležitejších súborov znalostí na trhu práce je zameranie sa na potrebné kompetencie potrebné pre aplikovanú AI. Kompetencia sa vo všeobecnosti vzťahuje na vedomosti, zručnosti a schopnosti, ktoré odborník musí mať, aby mohol pracovať v oblasti aplikovanej AI.

Štúdia ukazujú, že výber vhodných tried metód strojového učenia a ich aplikácia na špecifické problémy je najdominantnejšou požadovanou kompetenciou so skóre 59,46 %. Je to očakávané vzhľadom na skutočnosť, že jednou z najdôležitejších úloh je zistiť čo najlepšie spracovanie daných údajov. To ukazuje, že odborníci musia mať komplexné pochopenie hlavných oblastí AI a kontextov, na ktoré sa dá použiť.

So skóre 48,65 % a 41,89 % sú porovnávanie metód strojového učenia a reprezentácia informácií v logickom formalizme ďalšie dve najdôležitejšie kompetencie. Môžeme konštatovať, že porovnávanie metód ML je priamo spojené s výberom vhodnej metódy pre konkrétny problém, takže nie je prekvapujúce, že táto kompetencia je veľmi potrebná. Schopnosť reprezentovať informácie pomocou logických alebo pravdepodobnostných formalizmov a aplikovať príslušné metódy umožňuje odborníkovi efektívne modelovať poznatky a manipulovať s nimi.

Kompetencie, ktoré majú významný vplyv, sú používanie vhodných tréningových a testovacích metodológií pri nasadzovaní algoritmov strojového učenia spolu s rozpoznaním šírky a užitočnosti metód strojového učenia vo veku okolo 40 rokov.

Poznanie požadovaných kompetencií v oblasti aplikovanej AI je veľmi dôležité štúdium. Poskytuje mnoho užitočných informácií, ktoré môžu byť orientované na rozvoj učebných osnov, rozvoj zručností alebo prípravu na kariéru. V oblasti tvorby kurikula pochopenie požadovaných kompetencií pomáha inštitúciám navrhovať a rozvíjať aktuálne programy. Zosúladenie kompetencií s učebnými osnovami je nevyhnutným krokom k úspechu vo vybranom odbore.

B. POŽIADAVKY ODZAMESTNÁVATEĽOV

Zistenia prieskumu, ktorý skúma potreby a očakávania zamestnávateľov v oblasti aplikovanej AI, poukazujú na niekoľko dôležitých záverov týkajúcich sa požadovaných tvrdých zručností, mäkkých zručností a vysokoškolského vzdelania v oblasti aplikovanej AI, strojového učenia (ML), Data Science a Big Data. Pokiaľ ide o tvrdé zručnosti, kompetencia, ktorú zamestnávatelia najviac oceňujú, je schopnosť rozpoznať problémy súvisiace s algoritmickou a dátovou zaujatosťou, ako aj so súkromím a integritou údajov. Okrem toho spoločnosti zdôrazňujú dôležitosť kompetencií, ako je popis hlavných oblastí AI, identifikácia výkonnostných metrik



Co-funded by
the European Union

na hodnotenie algoritmov ML a uznanie šírky a užitočnosti metód ML. Na splnenie týchto požiadaviek by sa spoločnosti mali zamerať na poskytovanie príležitostí na školenie a rozvoj na zlepšenie zručností a schopností jednotlivcov, ktorí vykazujú slabšie kompetencie. Pre zamestnancov umelej inteligencie a dátovej vedy je kľúčové, aby rešpektovali históriu v odbore a chápali výhody a obmedzenia logických a pravdepodobnostných reprezentácií znalostí. Mali by tiež preukázať odhodlanie aplikovať strojové učenie ako súčasť cieľovo orientovaného procesu pre klientov a byť dôslední pri porovnávaní naučených modelov. Výber a hodnotenie algoritmov sa považujú za kľúčové pre zabezpečenie kvality naučených modelov a zásadné sú etické hodnotiace prístupy s vysokou spoľahlivosťou. Pozornosť na detaily je zdôraznená v technikách učenia bez dozoru na skúmanie údajov, ich porozumenie, sumarizáciu a vizualizáciu. Pokiaľ ide o používanie modelov ML, spoločnosti vo veľkej miere využívajú klasické techniky ML a hlboké ML. Zatiaľ čo tradičné modely ML, ako sú rozhodovacie stromy a viacvrstvové perceptróny (MLP), sa bežne používajú a študujú, modely hlbokého učenia, ako sú konvulčné neurónové siete (CNN) a rekurentné neurónové siete (RNN), sú veľmi populárnou voľbou. Prieskum tiež odhaľuje najbežnejšie úlohy AI a ML v rámci spoločností, pričom klasifikácia a regresia sú najvyššie. Klasifikácia obrázkov, zhukovanie a popisovanie obrázkov sú tiež prevládajúce, zatiaľ čo úlohy, ako je rozpoznávanie rečí a segmentácia obrázkov, majú značnú mieru odozvy. Pokiaľ ide o programovacie jazyky, Python je najžiadanejším jazykom pre prácu s AI a ML, po ktorom nasleduje C++. Java, R a C# majú tiež význam v tejto oblasti. TensorFlow je najpoužívanejší rámec AI, po ňom nasledujú Keras a scikit-learn. Ostatné rámce ako PyTorch, Apache TVM, AMD HIP, OpenAI a sady nástrojov Matlab sa používajú v menšej miere. Anaconda, Apache Hadoop a Matlab sú populárne ekosystémy, čo naznačuje zameranie na komplexné nástroje ML, veľké súbory údajov a zložité algoritmy. Zamestnávateľia uprednostňujú kompetencie súvisiace s inováciami, adaptáciami, štúdiami uskutočniteľnosti a modernými metódami psychológie a pedagogiky pre akademických/analytických zamestnancov. Kritické myslenie, komunikácia a znalosť nástrojov a technológií sú vysoko cenené mäkké zručnosti. Za nevyhnutné sa považuje aj plánovanie a organizovanie, základy podnikania a schopnosti spolupráce. Zamestnávateľia navyše zdôrazňujú dôležitosť kompetencií, ako je výber vhodných dátových štruktúr a algoritmov, vizualizácia analýzy AI a implementácia riešení založených na cloud computingu. Zistenia ukazujú, že technické zručnosti v oblasti AI a vedy o údajoch sú kľúčové, ale nie dostatočné na úspech v tejto oblasti. Zamestnávateľia oceňujú dodatočné kompetencie, vrátane zručností pri riešení problémov, praktických skúseností, softvérovej architektúry, prezentačných zručností, kritického myslenia, prispôbivosti av niektorých prípadoch znalostí špecifických pre danú oblasť. Za nevyhnutnú považujeme efektívnu komunikáciu so zákazníkmi aj v rámci interných tímov. Prieskum naznačuje, že kompetencie požadované spoločnosťami v oblasti AI a Data Science sú rôznorodé, čo odráža interdisciplinárny charakter tejto oblasti.

Zatiaľ čo teoretické znalosti špecialistov na AI sú vo všeobecnosti dobré, praktické zručnosti si často vyžadujú zlepšenie. Pochopenie obchodných požiadaviek, odhad praktických aspektov rozvoja a schopnosť pracovať na problémoch rôzneho rozsahu sú kľúčové kompetencie. Zamestnávateľia majú zmiešané názory na kvalitu absolventov IT, oceňujú však ich technickú zdatnosť a solídne zázemie. Praktické zručnosti a kreativita sa považujú za rozhodujúce, zatiaľ čo zručnosti spolupráce sú nevyhnutné pre tímovú prácu. Zatiaľ čo trh práce pre juniorských IT špecialistov sa považuje za dostatočný, nájst' odborníkov na strednej alebo vyššej úrovni môže byť náročné. Názory na potrebu špecialistov na AI sú rozdielne, niektorí zamestnávateľia udávajú výraznú medzeru na trhu práce. Väčšina spoločností je stredne spokojná s úrovňou prípravy magisterských absolventov v oblasti AI, čo naznačuje priestor na zlepšenie. Spoločnosti majú vo všeobecnosti pozitívny názor na zvyšovanie kvalifikácie svojich súčasných zamestnancov tým, že im umožňujú študovať AI na magisterskej úrovni. Na záver prieskum poskytuje cenné poznatky o potrebách a očakávaníach zamestnávateľov v oblasti aplikovanej AI. Zdôrazňuje dôležitosť širokého spektra kompetencií vrátane tvrdých zručností, mäkkých zručností a interdisciplinárnych znalostí. Neustále vzdelávanie, praktické skúsenosti, efektívna komunikácia a schopnosť riešiť problémy sú kľúčom k úspechu v tejto rýchlo sa rozvíjajúcej oblasti. a v niektorých prípadoch znalosti špecifické pre danú oblasť. Za nevyhnutnú považujeme efektívnu komunikáciu so zákazníkmi aj v rámci interných tímov. Prieskum naznačuje, že kompetencie požadované spoločnosťami v oblasti AI a Data Science sú rôznorodé, čo odráža interdisciplinárny charakter tejto oblasti. Zatiaľ čo teoretické znalosti špecialistov na AI sú vo všeobecnosti dobré, praktické zručnosti si často vyžadujú zlepšenie. Pochopenie obchodných požiadaviek, odhad praktických aspektov rozvoja a schopnosť pracovať na problémoch rôzneho rozsahu sú kľúčové kompetencie. Zamestnávateľia majú zmiešané názory na kvalitu absolventov IT, oceňujú však ich technickú zdatnosť a solídne zázemie. Praktické zručnosti a kreativita sa považujú za rozhodujúce, zatiaľ čo zručnosti spolupráce sú nevyhnutné pre tímovú prácu. Zatiaľ čo trh práce pre juniorských IT špecialistov sa považuje za dostatočný, nájst' odborníkov na strednej alebo vyššej úrovni môže byť náročné. Názory na potrebu špecialistov na AI sú rozdielne, niektorí zamestnávateľia udávajú výraznú medzeru na trhu práce. Väčšina spoločností je stredne spokojná s úrovňou prípravy magisterských absolventov v oblasti AI, čo naznačuje priestor na zlepšenie. Spoločnosti majú vo všeobecnosti pozitívny názor na zvyšovanie kvalifikácie svojich súčasných zamestnancov tým, že im umožňujú študovať AI na magisterskej úrovni. Na záver prieskum poskytuje cenné poznatky o potrebách a očakávaníach zamestnávateľov v oblasti aplikovanej AI. Zdôrazňuje dôležitosť širokého spektra kompetencií vrátane tvrdých zručností, mäkkých zručností a interdisciplinárnych znalostí. Neustále vzdelávanie, praktické skúsenosti, efektívna komunikácia a schopnosť riešiť problémy sú kľúčom k úspechu v tejto rýchlo sa rozvíjajúcej oblasti. a v niektorých prípadoch znalosti špecifické pre danú oblasť. Za nevyhnutnú považujeme efektívnu komunikáciu so zákazníkmi aj v rámci interných tímov. Prieskum naznačuje, že kompetencie požadované spoločnosťami v oblasti AI a Data Science sú rôznorodé, čo odráža interdisciplinárny charakter tejto oblasti. Zatiaľ čo teoretické znalosti špecialistov na AI sú vo všeobecnosti dobré, praktické zručnosti si často vyžadujú zlepšenie. Pochopenie obchodných požiadaviek, odhad



Co-funded by
the European Union

praktických aspektov rozvoja a schopnosť pracovať na problémoch rôzneho rozsahu sú kľúčové kompetencie. Zamestnávateľia majú zmiešané názory na kvalitu absolventov IT, oceňujú však ich technickú zdatnosť a solídne zázemie. Praktické zručnosti a kreativita sa považujú za rozhodujúce, zatiaľ čo zručnosti spolupráce sú nevyhnutné pre tímovú prácu. Zatiaľ čo trh práce pre juniorských IT špecialistov sa považuje za dostatočný, nájst' odborníkov na strednej alebo vyššej úrovni môže byť náročné. Názory na potrebu špecialistov na AI sú rozdielne, niektorí zamestnávateľia udávajú výraznú medzeru na trhu práce. Väčšina spoločností je stredne spokojná s úrovňou prípravy magisterských absolventov v oblasti AI, čo naznačuje priestor na zlepšenie. Spoločnosti majú vo všeobecnosti pozitívny názor na zvyšovanie kvalifikácie svojich súčasných zamestnancov tým, že im umožňujú študovať AI na magisterskej úrovni. Na záver prieskum poskytuje cenné poznatky o potrebách a očakávaníach zamestnávateľov v oblasti aplikovanej AI. Zdôrazňuje dôležitosť širokého spektra kompetencií vrátane tvrdých zručností, mäkkých zručností a interdisciplinárnych znalostí. Neustále vzdelávanie, praktické skúsenosti, efektívna komunikácia a schopnosť riešiť problémy sú kľúčom k úspechu v tejto rýchlo sa rozvíjajúcej oblasti. Spoločnosti majú vo všeobecnosti pozitívny názor na zvyšovanie kvalifikácie svojich súčasných zamestnancov tým, že im umožňujú študovať AI na magisterskej úrovni. Na záver prieskum poskytuje cenné poznatky o potrebách a očakávaníach zamestnávateľov v oblasti aplikovanej AI. Zdôrazňuje dôležitosť širokého spektra kompetencií vrátane tvrdých zručností, mäkkých zručností a interdisciplinárnych znalostí. Neustále vzdelávanie, praktické skúsenosti, efektívna komunikácia a schopnosť riešiť problémy sú kľúčom k úspechu v tejto rýchlo sa rozvíjajúcej oblasti.

Celkovo prieskum objasnil požiadavky zamestnávateľov týkajúce sa zručností a kompetencií v oblasti aplikovanej AI a Data Science. Zistenia môžu pomôcť zlepšiť školiace a vzdelávacie programy tak, aby vyhovovali potrebám zamestnávateľov v oblasti aplikovanej AI.

C. POŽIADAVKY OD ŠTUDENTOV

Veľký ohlas študentov, magisterov a absolventov informačných systémov a technológií (više 1000 účastníkov online prieskumu), prevažne z krajín partnerov, svedčí o obrovskom záujme týchto cieľových skupín o aplikovanú umelú inteligenciu. Mladí študenti si myslia, že obsah AAI bude dôležitý pre ich ďalšiu kariéru a demonštrujú jasnú potrebu adekvátnych kurzov.

Väčšina študentov sa zaujímalá o prieskum o AAI, no nepoznali žiadny relevantný kurz na svojej univerzite, čo dokazuje dobrý základ projektu FAAI a rastúcu potrebu kurzov zaoberajúcich sa AAI. Je jasne uvedené, že rozvojový kurz by sa mal silne opierať o praktickú implementáciu s laboratórnymi prácami, študentskými projektmi a stážami. Vysoké školy by sa mali zamerať na implementáciu obsahu AAI do študijných programov buď inováciou existujúcich kurzov, alebo zavedením úplne nových kurzov. Zdokonaľovanie materiálových komponentov (vybavenie, laboratória) je sekundárnym, ale aj dôležitým faktorom. Ďalšou prioritou partnerských univerzít by malo byť vytvorenie webovej stránky na prezentáciu výskumu v rámci AAI. Je to efektívny spôsob šírenia zistení a zapojenia študentov a iných cieľových skupín do tém AAI. Skutočnosť, že takmer všetci študenti IT prejavili záujem alebo boli neutrálni voči štúdiu kurzu AAI, je v súlade s predpokladom projektu, že v európskom regióne existuje nedostatok AAI a iných digitálnych zručností. Preto zdôrazňuje potrebu nových iniciatív na primerané začlenenie týchto zručností do učebných osnov, rozvoja učiteľov, postupov hodnotenia a obsahu vzdelávania.

Navrhnuté kurzy AAI musia byť výrazne orientované na vývojárov softvéru, pretože tvoria veľkú väčšinu cieľovej skupiny pre rozvoj digitálnych kompetencií a zručností v oblasti aplikovanej umelej inteligencie. Zamestnávateľa v IT sektore väčšinou požadujú od svojich zamestnancov bakalárske vzdelanie, takže najlogickejšia voľba umiestniť kurzy AAI na bakalárske štúdium alebo v rámci niektorých špecializačných programov. Na druhej strane musíme mať na pamäti, že tieto kurzy si zvyčajne vyžadujú už nadobudnuté znalosti z danej oblasti, zatiaľ čo základnejšie kurzy si zrejme želá cieľová populácia.

Rozvoj mäkkých zručností sa v dnešnom pracovnom prostredí stáva čoraz dôležitejším. Mladí ľudia uznávajú ich dôležitosť rovnako ako ich zamestnávateľa. Akékoľvek navrhnuté školenie by sa malo zamerať aj na rozvoj mäkkých zručností, najmä tých, ktoré sa týkajú tímovej práce, komunikácie a riadenia času. Pri tvorbe kurzu treba vysoko oceňovať aj kreativitu, riešenie problémov, schopnosť učiť sa a aplikovať získané vedomosti. Najcennejšie kompetencie pre špecialistu na AAI sú: používanie vhodných tréningových a testovacích metodológií pri nasadzovaní algoritmov strojového učenia, rozpoznanie šírky a užitočnosti metód strojového učenia, výber vhodných (tried) metód strojového učenia pre špecifické problémy a porovnávanie a kontrastné metódy strojového učenia.

Školenia FAAI a usmernenia pre ich navrhovanie musia tiež zohľadňovať žiaduce budúce povolania pre respondentov (v súlade so zoznamom európskeho rámca kompetencií IT) a musia byť prispôsobené špecificky najpopulárnejším, ako je vývoj softvéru, projektový manažér, Systémový správca a správca databázy.

D. POŽIADAVKY TOAKADEMICI

Rozhodujúcu úlohu pri vybavovaní zohráva kompetentnosť pedagógov so zručnosťami a znalosťami potrebnými na efektívne vyučovanie a propagáciu AAI. Keďže sa táto oblasť rýchlo vyvíja, je nevyhnutné identifikovať a uprednostňovať kompetencie, ktoré sú potrebné na to, aby pedagógovia boli v obraze a poskytovali študentom hodnotné pokyny. Kľúčové kompetencie, ktoré by mali byť



Co-funded by
the European Union

Medzi akademikmi zdôrazňované v súvislosti s AAI patria nasledujúce.

Je nevyhnutné, aby pedagógovia začlenili etické hľadiská do učebných osnov, keďže AI sa čoraz viac integruje do rôznych oblastí. Pedagógovia musia študentov vybaviť schopnosťou kriticky zhodnotiť etické dôsledky a potenciálne dôsledky rozhodovania AI. To zahŕňa podporu diskusií o zaujatosti, spravodlivosti, transparentnosti, zodpovednosti a širších sociálnych a etických rozmeroch technológií AI.

Akademici by mali dobre rozumieť základným technickým konceptom a metodológiám v aplikovanej AI. To zahŕňa znalosti algoritmov strojového učenia, štatistického modelovania, predbežného spracovania a analýzy údajov, programovacích jazykov a bežne používaných knižníc pri vývoji AI. Okrem toho je rozhodujúca odbornosť v oblastiach, ako je počítačové videnie, spracovanie prirodzeného jazyka a hlboké učenie, pretože sú základnými zložkami aplikovanej AI.

Umelá inteligencia je multidisciplinárna oblasť, ktorá sa prelína s rôznymi oblasťami, ako sú počítačové vedy, matematika, kognitívna veda a etika. Akademici by mali byť povzbudzovaní, aby prijali interdisciplinárny prístup k vzdelávaniu AI, čím by sa preklenula priepasť medzi technickými znalosťami a ich aplikáciou v reálnych kontextoch. Zahŕňa to podporu spolupráce a začlenenie rôznych perspektív z iných disciplín, čo študentom umožňuje holisticky riešiť zložité výzvy AI. Rozvíjanie kritického myslenia a zručností študentov pri riešení problémov je v aplikovanom vzdelávaní AI nevyhnutné. Akademici by mali kladť dôraz na schopnosť analyzovať a hodnotiť modely a algoritmy AI, identifikovať obmedzenia a potenciálne predsudky a navrhovať inovatívne riešenia na riešenie problémov súvisiacich s AI. Vychovávaním analytických a logických schopností študentov im pedagógovia umožňujú stať sa efektívnymi odborníkmi na AI a výskumníkmi.

Efektívna komunikácia a schopnosti spolupráce sú pre pedagógov v oblasti aplikovanej AI nevyhnutné. Akademici by mali byť schopní formulovať komplexné koncepty umelej inteligencie jasným a prístupným spôsobom, čím by podporovali zapojenie a porozumenie medzi študentmi s rôznou úrovňou technického zázemia. Okrem toho podpora spolupráce v rámci akademickej komunity a mimo nej, napríklad prostredníctvom priemyselných partnerstiev, podporuje zdieľanie znalostí, vytváranie sietí a vystavenie aplikáciám AI v reálnom svete.

Vzhľadom na rýchly pokrok v technológiách umelej inteligencie by akademici mali byť adaptabilní a mali by sa zaviazat' k celoživotnému vzdelávaniu. Mali by zostať informovaní o najnovšom vývoji, nových trendoch a osvedčených postupoch v tejto oblasti. To zahŕňa zapojenie sa do nepretržitého profesionálneho rozvoja, účasť na konferenciách a workshopoch, účasť v komunitách AI a hľadanie poradenstva od odborníkov z odvetvia. Prijatím rastového myslenia môžu akademici efektívne pripraviť študentov na neustále sa vyvíjajúce prostredie aplikovanej AI.

Akademici majú zodpovednosť podporovať etické vedenie a slúžiť ako vzory pre



Co-funded by
the European Union

Dôležitosť „systémov“ založených na „údajoch“ a vytváranie „modelov“ prostredníctvom „stroja“ a „umelej“ „inteligencie“ a „učenia“ prevládali vo všetkých oblakoch slov. Okrem toho sa kládol dôraz na „energetické“ využitie a „hĺbkové“ riešenia. Bežne sa spomínali aplikačné oblasti ako „siet“, „medicína“, „obchod“ a „údržba“. Pri analýze slova cloud je zrejmé, že ideálny systém, ktorý sa má vytvoriť, by mal mať rozlišovacie znaky.

charakteristiky ako „výkon“, „kvalita“ a „presnosť“. Okrem toho je nevyhnutné, aby určité riešenia zlepšili existujúce. Napokon, „manažment“ a „monitorovanie“ sú tiež dôležité kľúčové slová z analyzovaného systému. Mal by byť teda prezentovaný životný cyklus vytvoreného riešenia. Zistenia prezentovali pohľady na hlavné zodpovednosti a povinnosti na pracovných pozíciách, ciele a výsledky projektu a ciele reálnej prípadovej štúdie.

F. AHP ANALÝZA TENZOROVÝCH VZŤAHOV"MODUL KOMPETENCIE-OBSAHU"

Ako sa ukázalo, AHP sa môže použiť na navrhovanie školiacich kurzov vo vzdelávaní založenom na kompetenciách tým, že pomáha pri určovaní priorít a prijímaní rozhodnutí týkajúcich sa rôznych aspektov kurzu. Aplikácia AHP v tomto kontexte nám pomohla urobiť nasledovné. Pri definovaní cieľa si stanovíme konečný cieľ tréningového kurzu. Toto môže byť špecifické pre vývoj kompetencie v AAI.

Identifikácia kritérií, ktoré prispievajú k dosiahnutiu Vo vzdelávaní založenom na kompetenciách by tieto kritériá mohli zahŕňať faktory, ako je relevantnosť obsahu pre požadované kompetencie, jasnosť a efektívnosť vyučovacích metód, stratégie hodnotenia používané na meranie dosiahnutia kompetencií, súlad s priemyslom. štandardy alebo pracovné požiadavky.

Pomocou generovania alternatív určujeme rôzne alternatívy alebo možnosti pre návrh vzdelávacieho kurzu na AAI. Tieto alternatívy môžu zahŕňať rôzne inštruktážne prístupy, vyučovacie metodológie, metódy hodnotenia, postupnosť tém, trvanie kurzu alebo začlenenie praktických cvičení alebo reálnych prípadov.

Aplikovaním AHP v dizajne tréningového kurzu AAI môžeme systematicky vyhodnocovať a uprednostňovať rôzne faktory, zvažovať viaceré perspektívy a robiť informovanejšie rozhodnutia, ktoré sú v súlade s cieľmi a požiadavkami CBE.

1) Priority z kompetencie bod z vyhládka z AIML

Metódu analytického hierarchického procesu (AHP) možno použiť na určenie priorít medzi kompetenciami súvisiacimi s AI a ML v kontexte trhu práce, akademikov, študentov a zamestnávateľov ako tých, ktorí rozhodujú. AHP je štruktúrovaný prístup, ktorý pomáha tvorcom rozhodnutí porovnávať a uprednostňovať rôzne kritériá na základe ich relatívnej dôležitosti.

Pomocou metódy AHP môžu rozhodovatelia systematicky vyhodnocovať a priradovať váhy kompetenciám. Výsledky na obrázkoch 9-13 možno potom použiť

na usmernenie rozhodovacích procesov súvisiacich s kompetenciami AI a ML, ako je tvorba učebných osnov, rozhodnutia o prijímaní zamestnancov alebo vzdelávacie programy, pričom sa zohľadnia perspektívy zástupcov trhu práce, akademikov, študentov, a zamestnávateľov.

2) Programovanie jazykochna výcvikový kurz AAI

Rôzne programovacie jazyky majú rôznu podporu pre knižnice a rámce AI, ako napríklad Python s Tensor-Flow a PyTorch, ktoré výrazne zjednodušujú vývoj AI. Jazyky ako Python a R majú živé komunity AI, ktoré ponúkajú bohaté zdroje na učenie a odstraňovanie problémov. Niektoré jazyky ponúkajú flexibilitu a výraznosť, napríklad jednoduchosť a čitateľnosť Pythonu, zatiaľ čo iné, ako napríklad Lisp alebo Haskell, majú vstavanú podporu pre funkčné programovanie, čo je výhodné pre určité techniky AI. Výber programovacieho jazyka môže závisieť od požiadaviek na výkon, pričom jazyky ako C++ alebo Java ponúkajú lepší výkon ako interpretované jazyky. Potreby integrácie a nasadenia môžu tiež ovplyvniť výber jazyka, ako napríklad používanie JavaScriptu pre webové aplikácie. Vďaka popularite Pythonu v komunite AI je široko používaný v priemysle, akademickej obci a výskume.

Je dôležité poznamenať, že špecifické priority programovacích jazykov súvisiacich s kurzami AI sa môžu líšiť v závislosti od kontextu, technologického pokroku a vyvíjajúcich sa potrieb trhu práce a zamestnávateľov (pozri obr. 15-18). Najaktuálnejšie a najkomplexnejšie výsledky by sa preto získali z nedávnych štúdií alebo prieskumov vykonaných odborníkmi na AI, výskumnými inštitúciami alebo priemyselnými organizáciami, ktoré sa špecializujú na AI a programovacie jazyky. Kritériá, ktoré sú dôležité na posúdenie vhodnosti programovacích jazykov na školenia AI, môžu zahŕňať faktory, ako je výkon, škálovateľnosť, podpora komunity, knižnice a rámce, jednoduchosť použitia, ekosystém, prijatie v odvetví a kompatibilita so serverovými a cloudovými riešeniami. .

3) Modely AI v rámci Classic ML a DeepML

Z hľadiska klasického ML by tvorcovia rozhodnutí mali uprednostniť štúdium základných modelov, ako je lineárna regresia, logistická regresia a rozhodovacie stromy, pretože tieto sú na trhu práce široko používané, vyhľadávané zamestnávateľmi a predstavujú dobrú prax v AI. Z hľadiska Deep ML by sa tvorcovia rozhodnutí mali zamerať na štúdium hlbokých neurónových sietí, konvolučných neurónových sietí (CNN) a rekurentných neurónových sietí (RNN), keďže tieto modely získali významné postavenie na trhu práce a sú vysoko cenené zamestnávateľmi a považujú sa za nevyhnutné na udržanie kroku so súčasnými osvedčenými postupmi v oblasti AI.

G. TENZOROVÝ KURZ REPREZENTÁCIA

Analýzou tabuľky obsahujúcej medzimatecovú tému – kompetenciu je možné vidieť, že kompetencia vytvorená implementáciou najväčšieho počtu tém je kompetencia C4. Na jej vypracovanie je potrebné realizovať takmer všetky témy (T1-T12) okrem témy T8.

Vzhľadom na medzimatecové moduly – kompetencie je možné vidieť, že



Co-funded by
the European Union

posilnenie kompetencie C6 by sa malo uskutočniť realizáciou takmer všetkých modulov (M1-M12) okrem M1 a M3.

Na základe analýzy uvedenej v tabuľkách 13-24 je zrejmé, že moduly a témy majú významný vzťah. Zistenia naznačujú nasledovné súvislosti medzi kompetenciami a vzdelávacími komponentmi (témami):

- Kompetencia C1 sa môže rozvíjať implementáciou T1 spolu s modulmi M1, M2, M3 a M12.
- Na pestovanie kompetencie C2 sa odporúča implementovať T1 v spojení s modulmi M2, M5 a M12.
- Pre vzdelávanie kompetencie C3 je vhodné absolvovať T1, T5, T12 a využiť moduly M2 a M8.
- Kompetenciu C4 je možné efektívne vyučovať realizáciou T2, T3, T4, T12 a väčšiny modulov, okrem M8.
- Na získanie kompetencie C5 je potrebné zapojiť sa T₁, T3 a využívajú moduly M6 až M12.
- Rozvoj kompetencie C6 si vyžaduje implementáciu T2, T4 až T12, ako aj využitie modulov M6 až M12.
- Kompetenciu C7 je možné efektívne trénovať realizáciou T1, T3, T6 až T11 a využitím modulov M6 až M12.
- Pre vzdelávanie kompetencie C8 sa odporúča absolvovať T1, T3, T4, T6 až T11 a využiť moduly M6 až M12.
- Kompetenciu C9 možno získať podnikom T4, T6 cez T11 a s využitím modulov M6 až M12.
- Na rozvoj kompetencie C10 sa odporúča vykonať T₄, T6 až T11 a využívajú moduly M6 až M12.
- Rozvoj kompetencie C11 si vyžaduje implementáciu T6 až T11 a využitie väčšiny modulov, okrem M8.
- Pre vzdelávanie kompetencie C12 sa odporúča implementovať T6 až T11 a využiť moduly M6, M7 a M9 až M12.

V. ZÁVER

Štúdia úspešne vyvinula komplexný prístup k navrhovaniu školiaceho kurzu o AAI v kontexte vyššieho vzdelávania. Tento prístup je založený na pedagogických prístupoch založených na dôkazoch a riadi sa princípmi vzdelávania založeného na kompetenciách a inovatívnej pedagogiky.

Výskum vykonal dôkladnú revíziu AAI prostredníctvom zoskupovania kľúčových slov, pričom zahŕňal údaje z prieskumov, pracovných ponúk, existujúcich kurzov AI školení, vedeckých projektov a skutočných prípadov. Analýza textových informácií pomocou oblakov slov poskytla cenné poznatky.

Štúdia použila na prezentáciu tenzorového prístupu AAI kurz založený na kompetenciách, ktorý zabezpečuje holistické zastúpenie kompetencií vo vzťahu k obsahu kurzu a vzdelávacím modulom. Tento prístup umožňuje štruktúrované a komplexné pochopenie požadovaných zručností a vedomostí v AAI.



Co-funded by
the European Union

TABLE14.Křížová matice pre vzťah "téma-modul" podľa kompetencia C2

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
T ₁	0	1	0	0	1	0	0	0	0	0	0	1
T ₂	0	1	0	0	1	0	0	0	0	0	0	1
T ₃	0	0	0	0	0	0	0	0	0	0	0	0
T ₄	0	0	0	0	0	0	0	0	0	0	0	0
T ₅	0	0	0	0	0	0	0	0	0	0	0	0
T ₆	0	0	0	0	0	0	0	0	0	0	0	0
T ₇	0	0	0	0	0	0	0	0	0	0	0	0
T ₈	0	0	0	0	0	0	0	0	0	0	0	0
T ₉	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₀	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₂	0	0	0	0	0	0	0	0	0	0	0	0

TABLE15.Křížová matice pre vzťah "téma-modul" podľa kompetencia C3

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
T ₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₂	0	1	0	0	0	0	0	1	0	0	0	0
T ₃	0	0	0	0	0	0	0	0	0	0	0	0
T ₄	0	0	0	0	0	0	0	0	0	0	0	0
T ₅	0	1	0	0	0	0	0	1	0	0	0	0
T ₆	0	0	0	0	0	0	0	0	0	0	0	0
T ₇	0	0	0	0	0	0	0	0	0	0	0	0
T ₈	0	0	0	0	0	0	0	0	0	0	0	0
T ₉	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₀	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₂	0	1	0	0	0	0	0	1	0	0	0	0

TABLE16.Křížová matice pre vzťah "téma-modul" podľa kompetencia C4

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
T ₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₂	1	1	1	1	1	1	1	0	1	1	1	1
T ₃	1	1	1	1	1	1	1	0	1	1	1	1
T ₄	1	1	1	1	1	1	1	0	1	1	1	1
T ₅	0	0	0	0	0	0	0	0	0	0	0	0
T ₆	0	0	0	0	0	0	0	0	0	0	0	0
T ₇	0	0	0	0	0	0	0	0	0	0	0	0
T ₈	0	0	0	0	0	0	0	0	0	0	0	0
T ₉	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₀	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₁₂	1	1	1	1	1	1	1	0	1	1	1	1



Co-funded by
the European Union

TABLE20. Krížová matica pre vzťah "téma-modul" podľa kompetencia C8

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
T ₁	0	0	0	0	0	1	1	1	1	1	0	0
T ₂	0	0	0	0	0	0	0	0	0	0	0	0
T ₃	0	0	0	0	0	1	1	1	1	0	1	1
T ₄	0	0	0	0	0	1	1	1	1	1	0	0
T ₅	0	0	0	0	0	0	0	0	0	0	0	0
T ₆	0	0	0	0	0	1	1	1	1	1	0	0
T ₇	0	0	0	0	0	1	1	1	1	1	0	0
T ₈	0	0	0	0	0	1	1	1	1	1	0	0
T ₉	0	0	0	0	0	1	1	1	1	1	0	0
T ₁₀	0	0	0	0	0	1	1	1	1	1	0	0
T ₁₁	0	0	0	0	0	1	1	1	1	1	0	0
T ₁₂	0	0	0	0	0	0	0	0	0	0	0	0

TABLE21. Krížová matica pre vzťah "téma-modul" podľa kompetencia C9

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
T ₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₂	0	0	0	0	0	0	0	0	0	0	0	0
T ₃	0	0	0	0	0	0	0	0	0	0	0	0
T ₄	0	0	0	0	0	1	1	1	1	0	0	0
T ₅	0	0	0	0	0	0	0	0	0	0	0	0
T ₆	0	0	0	0	0	1	1	1	1	0	0	0
T ₇	0	0	0	0	0	1	1	1	1	0	0	0
T ₈	0	0	0	0	0	1	1	1	1	0	0	0
T ₉	0	0	0	0	0	1	1	1	1	0	0	0
T ₁₀	0	0	0	0	0	1	1	1	1	0	0	0
T ₁₁	0	0	0	0	0	1	1	1	1	0	0	0
T ₁₂	0	0	0	0	0	0	0	0	0	0	0	0

TABLE22. Krížová matica pre vzťah "téma-modul" podľa kompetencia C10

	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	M ₁₁	M ₁₂
T ₁	0	0	0	0	0	0	0	0	0	0	0	0
T ₂	0	0	0	0	0	1	1	1	1	1	1	1
T ₃	0	0	0	0	0	0	0	0	0	0	0	0
T ₄	0	0	0	0	0	1	1	1	1	1	1	1
T ₅	0	0	0	0	0	1	1	1	1	1	1	1
T ₆	0	0	0	0	0	1	1	1	1	1	1	1
T ₇	0	0	0	0	0	1	1	1	1	1	1	1
T ₈	0	0	0	0	0	1	1	1	1	1	1	1
T ₉	0	0	0	0	0	1	1	1	1	1	1	1
T ₁₀	0	0	0	0	0	1	1	1	1	1	1	1
T ₁₁	0	0	0	0	0	1	1	1	1	1	1	1
T ₁₂	0	0	0	0	0	1	1	1	1	1	1	1



Co-funded by
the European Union

LITERATÚRA

- [1] Faai job hub – budúcnosť je v aplikovanej umelej inteligencii 2022-1-pl01- ka220-hed-000088359. <https://faai.ath.edu.pl/>. (Vstupné dňa 07.04.2023).
- [2] Chaomei Chen, Fidelia Ibekwe-SanJuan a Jianhua Hou. Štruktúra a dynamika zhlukov kocitácie: Analýza kocitácie z viacerých perspektív. *Journal of the American Society for Information Science and Technology*, 61(7):1386–1409, marec 2010.
- [3] Fabiano Bini, Andrada Pica, Laura Azzimonti, Alessandro Giusti, Lorenzo Ruinelli, Franco Marinozzi a Pierpaolo Trimboli. Umelá inteligencia v oblasti štítnej žľazy - komplexný prehľad. *Rakoviny*, 13 (19): 4740, september 2021.
- [4] Farzad V. Farahani, Krzysztof Fiok, Behshad Lahijanian, Waldemar Karwowski a Pamela K. Douglas. Vysvetliteľná AI: Prehľad aplikácií na údaje o neurozobrazovaní. *Frontiers in Neuroscience*, 16. december 2022.
- [5] Onur Dogan, Sanju Tiwari, MA Jabbar a Shankru Guggari. Systematický prehľad prístupov AI/ML proti prepuknutiu COVID-19. *Complex & Intelligent Systems*, 7(5):2655–2678, júl 2021.
- [6] Vijay Kumar, Dilbag Singh, Manjit Kaur a Robertas Damaševičius. Prehľad súčasného stavu výskumu aplikácie technik umelej inteligencie pre COVID-19. *PeerJ Computer Science*, 7:e564, máj 2021.
- [7] Zhuoqing Chang, Shubo Liu, Xingxing Xiong, Zhaohui Cai a Guoqing Tu. Prieskum nedávnych pokrokov v umelej inteligencii vecí poháňanej edge-computingom. *IEEE Internet of Things Journal*, 8(18):13849–13875, september 2021.
- [8] Muddasar Naeem, Syed Tahir Hussain Rizvi a Antonio Coronato. Jemný úvod do posilňovacieho vzdelávania a jeho aplikácie v rôznych oblastiach. *IEEE Access*, 8:209320–209344, 2020.
- [9] Rohan Gupta, Devesh Srivastava, Mehar Sahu, Swati Tiwari, Rashmi K. Ambasta a Pravir Kumar. Umelá inteligencia k hlbokému učeniu: prístup strojovej inteligencie na objavovanie drog. *Molekulárna diverzita*, 25(3):1315–1360, apríl 2021.
- [10] Jingyi Zhao a Guifang Fu. Systém verejnej služby rodinnej zdravotnej výchovy založený na umelej inteligencii. *Hranice v psychológii*, 13. máj 2022.
- [11] Bui Hoang Bac, Hoang Nguyen, Nguyen Thi Thanh Thao, Vo Thi Hanh, Le Thi Duyen, Nguyen Tien Dung, Nguyen Khac Du a Nguyen Huu Hiep. Odhad účinnosti absorpcie ťažkých kovov vo vodnom roztoku pomocou hallositu nanorúrkového typu zo zvetraných pegmatitov a novej viacvrstvovej neuronovej siete perceptrónov založenej na optimalizácii Harris hawks. *Engineering with Computers*, 38(S5):4257–4272, júl 2021.
- [12] Yann LeCun, Yoshua Bengio a Geoffrey Hinton. Hlboké učenie. *Nature*, 521(7553):436–444, máj 2015.
- [13] Karen Simonyan a Andrew Zisserman. Veľmi hlboké konvolučné siete na rozpoznávanie obrázkov vo veľkom meradle, 2014.
- [14] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dharshan Kumaran, Daan Wierstra, Shane Legg a Demis Hassabis. Kontrola na ľudskej úrovni prostredníctvom hlbokého učenia. *Nature*, 518(7540):529–533, február 2015.
- [15] Ian Goodfellow, Yoshua Bengio a Aaron Courville. *Hlboké učenie*. Tlač MIT, 2016.
- [16] Jürgen Schmidhuber. Hlboké učenie v neuronových sieťach: prehľad. *Neurálne siete*, 61:85–117, január 2015.
- [17] Olga Russakovsky, Jia Deng, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, Alexander C. Berg a Li Fei-Fei. Rozsiahla výzva na vizuálne rozpoznávanie ImageNet. *International Journal of Computer Vision*, 115(3):211–252, apríl 2015.
- [18] Alex Krizhevsky, Ilya Sutskever a Geoffrey E. Hinton. Klasifikácia ImageNet s hlbokými konvolučnými neuronovými sieťami. *Communications of the ACM*, 60(6):84–90, máj 2017.
- [19] David Silver, Aja Huang, Chris J. Maddison, Arthur Guez, Laurent Sifre, George van den Driessche, Julian Schrittwieser, Ioannis Antonoglou, Veda Panneershelvam, Marc Lanctot, Sander Dieleman, Dominik Grewe, John Nham, Nal Kalchbrenner, Ilya Sutskever, Timothy Lillicrap, Madeleine Leach, Koray Kavukcuoglu, Thore Graepel a Demis Hassabis. Zvládnutie hry go s hlbokými neuronovými sieťami a prehľadávaním stromov. *Nature*, 529(7587):484–489, január 2016.
- [20] Joelle Elmaleh a Venky Shankararaman. Zlepšenie učenia sa študentov v úvodnom kurze programovania pomocou prevrátenej triedy a rámca kompetencií. V roku 2017 IEEE Global

- Engineering Education Conference (EDUCON), strany 49–55, 2017.
- [21] Manus Ross, Corey A. Graves, John W. Campbell a Jung H. Kim. Používanie podporných vektorových strojov na klasifikáciu pozornosti študentov pri vývoji personalizovaných vzdelávacích systémov. V roku 2013 12. medzinárodná konferencia o strojovom učení a aplikáciách, zväzok 1, strany 325 – 328, 2013.
- [22] Shah Neyamat Ullah. Príklady autentických hodnotení v inžinierskom vzdelávaní. V roku 2020 IEEE Global Engineering Education Conference (EDUCON), strany 894–897, 2020.
- [23] Jose Louie Mark Z. Ano, Geoffrey A. Solano, John Arthur P. Hernan a Ronalyn Grace Francisco. Warp: Inštruktážna platforma orientovaná na pracovný tok pre vzdelávanie založené na kompetenciách. V roku 2019 10. medzinárodná konferencia o informáciách, inteligencii, systémoch a aplikáciách (IISA), strany 1–4, 2019.
- [24] Arman Raj, Vandana Sharma, Seema Rani, Tanya Singh, Ankit Kumar Shanu a Ahmed Alkhayat. Demýtizovanie a analýza metaverza k vzdelávaniu 4.0. V roku 2023 3. medzinárodná konferencia o inovatívnych postupoch v technológii a manažmente (ICIPTM), strany 1–6, 2023.
- [25] Propagácia na základe kompetencií učenie | overovateľ.
<https://sertifier.com/blog/promoting-competency-based-learning/>. (Vstupné dňa 30.06.2023).
- [26] Michael Schumm, Saskia Joseph, Irmgard Schroll-Decker, Michael Niemetz a Jürgen Mottok. Požadované kompetencie v softvérovom inžinierstve: Párové programovanie ako nástroj na uľahčenie celoživotného vzdelávania. V roku 2012 15. medzinárodná konferencia o interaktívnom kolaboratívnom vzdelávaní (ICL), strany 1–5, 2012.
- [27] Davy Tsz Kit Ng, Min Lee, Roy Jun Yi Tan, Xiao Hu, J. Stephen Downie a Samuel Kai Wah Chu. Prehľad výučby a učenia AI od roku 2000 do roku 2020. Vzdelávanie a informačné technológie, 28(7):8445–8501, decembra 2022.
- [28] Thomas KF Chiu, Helen Meng, Ching-Sing Chai, Irwin King, Savio Wong a Yeung Yam. Tvorba a hodnotenie kurikula pre umelú inteligenciu (AI). IEEE Transactions on Education, 65(1):30–39, február 2022.
- [29] Becky Allen, Andrew Stephen McGough a Marie Devlin. Smerom k rámcu pre výučbu umelej inteligencie pre vysokoškolské publikum. ACM Transactions on Computing Education, 22(2):1–29, november 2021.
- [30] Výpočtové kompetencie pre vysokoškolské študijné programy vedy o údajoch. <https://www.acm.org/binaries/content/assets/education/curricula-opporucania/dstf.cdsc2021.pdf>. (Accessed on 07/05/2023).
- [31] Matthew L. Jockers. Analýza textu s R pre študentov literatúry. Springer International Publishing, 2014.
- [32] Cristian Felix, Steven Franconeri a Enrico Bertini. Rozoberanie slovných oblakov: Empirické skúmanie priestoru návrhu pre súhry kľúčových slov. IEEE Transactions on Visualization and Computer Graphics, 24(1):657–666, január 2018.
- [33] Stamatios Giannoulakis a Nicolas Tsapatsoulis. Identifikácia témy prostredníctvom ľudskej interpretácie oblakov slov: Prípady instagramových hashtagov. V IFIP Advances in Information and Communication Technology, strany 283–294. Springer International Publishing, 2021.
- [34] Shafer H. Zyoud a Daniela Fuchs-Hanusch. Bibliometrický prieskum o technikách ahp a topsis. Expertné systémy s aplikáciami, 78:158–181, 2017.
- [35] M. Raissi, P. Perdikaris a GE Karniadakis. Fyzikálne informované neuronové siete: Rámec hlbokého učenia na riešenie dopredných a inverzných problémov zahŕňajúcich nelineárne parciálne diferenciálne rovnice. Journal of Computational Physics, 378:686–707, február 2019.
- [36] Geoffrey Hinton, Li Deng, Dong Yu, George Dahl, Abdel rahman Mohamed, Navdeep Jaitly, Andrew Senior, Vincent Vanhoucke, Patrick Nguyen, Tara Sainath a Brian Kingsbury. Hlboké neuronové siete pre akustické modelovanie pri rozpoznávaní reči: Zdieľané názory štyroch výskumných skupín. IEEE Signal Processing Magazine, 29(6):82–97, november 2012.