



Co-funded by
the European Union

FAAI:

Budúcnosť je v aplikovanej umelej inteligencii
Projekt Erasmus+ 2022-1-PL01-KA220-HED-000088359

The Future is in Applied Artificial Intelligence
Erasmus+ project 2022-1-PL01-KA220-HED-000088359

01.09.2022 – 31.08.2024

Rámec kompetencií: WP3





Co-funded by
the European Union

Výroba tohto dokumentu bola možná vďaka podpore projektu ERASMUS+:
Budúcnosť je v aplikovanej umelej inteligencii (2022-1-PL01-KA220-HED-000088359)
The Future is in Applied Artificial Intelligence
Erasmus+ project 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: Tento výsledok načrtáva vzdelávaciu iniciatívu zameranú na rozvoj kompetenčného rámca v oblasti AAI. Tento prístup zahŕňa analýzu a začlenenie rôznych kompetenčných štandardov, ako sú ACM a IEEE. Obsah rámca má za cieľ zahrnúť oblasti znalostí, špecifikovať rozsah, kompetencie a subdomény. Subdomény sú ďalej podrobne opísané zahrnutím zodpovedajúcich vedomostí, zručností a dispozícií. Tento komplexný prístup sa snaží vytvoriť pevný základ pre rozvoj kompetencií v rýchlo sa rozvíjajúcej oblasti AAI.


Kľúčové slová: aplikovaná umelá inteligencia, osvedčené postupy, školenia, FAAI

I. OBSAH

ja	Obsah	3
II.	Základné požiadavky na znalosti	4
III.	Kompetencie a vzdelávanie založené na kompetenciách	8
A.	kompetencie	8
B.	Vzdelávanie založené na kompetenciách	8
C.	Vývoj rámca kompetencií AI	9
1)	Existujúce rámce kompetencií	9
2)	Cieľové skupiny FAAI	10
3)	Rámec kompetencií FAAI	11
IV.	Moduly kurzu FAAI	11
A.	Moduly V1	11
B.	Moduly V2	11
V.	Kompetencie Cross Matrix Module	13
VI.	Cross Matrix „Modul-Competence“	15
VII.	Štruktúra hlavného modulu	16
VIII.	Príklady vzdelávacích aktivít	17
IX.	Záver	20
X.	Referencie	21

II. ZÁKLADNÉ POŽIADAVKY NA ZNALOSTI

Kombinácia plánu v návrhu s AI časťou „Výpočtové kompetencie...“

<ul style="list-style-type: none">• Strojové učenie• Neurálne siete• robotické• Expertné systémy• Fuzzy logika• Prirodzený jazyk spracovanie  <p>Zmenili ich poradie v navrhovanom učebnom pláne v porovnaní s návrhom</p>	<p>Umela inteligencia</p> <ul style="list-style-type: none">• Všeobecné• Reprezentácia znalostí a uvažovanie – založené na logike• Reprezentácia znalostí a zdôvodnenie – na základe pravdepodobnosti• Stratégie plánovania a vyhľadávania <p>Strojové učenie</p> <ul style="list-style-type: none">• Všeobecné• Učenie pod dohľadom• Učenie bez dozoru• Zmiešané metódy• Hlboké učenie
--	--

Učebné osnovy v 12 témach

Téma 1. Umelá inteligencia 01

(len široký prehľad)

Vedomosti T1:

- História AI
- Realita AI (čo to je, čo robí) verzus vnímanie
- Hlavné podoblasti AI: reprezentácia znalostí, logické a pravdepodobnostné uvažovanie, plánovanie, vnímanie, spracovanie prirodzeného jazyka, učenie, robotika (fyzická aj virtuálna)

Reprezentácia vedomostí a uvažovanie AI (modely založené na logike) T2:

- Predikátová logika a príklady použitia
- Automatizované uvažovanie: reťazenie dopredu, reťazenie dozadu
- Uvažovanie integrované do rozsiahlych systémov (napr. Watson) (pravdepodobné cvičenie – použitie nejakého webového logického inferenčného modelu na odvodenie záverov z predpokladov)

Téma 2. Umelá inteligencia 02

Reprezentácia vedomostí a uvažovanie AI (modely založené na pravdepodobnosti) T1:

- Základné pojmy: náhodné premenné, axiómy pravdepodobnosti, nezávislosť, podmienená pravdepodobnosť, hraničná pravdepodobnosť
- Kauzálne modely T2:
- Bayesovské siete
- Markovove rozhodovacie procesy (MDP)

(pravdepodobné cvičenie – použitie softvéru ako WinBUGS, BNFinder v Pythone alebo bnlearn v R na vybudovanie jednoduchšej Bayesovskej siete a vypočítanie odpovedí na relevantné otázky pre sieť)



Téma 3. Umelá inteligencia 03

Znalosť plánovania AI a stratégií vyhľadávania

T2:

- Reprezentácia stavového priestoru možných riešení problému
- Do šírky a do hĺbky (tj neinformované) hľadanie stavového priestoru
- Heuristické (tj informované) vyhľadávanie stavového priestoru (napr. A* vyhľadávanie)
- Ukladanie, spracovanie údajov.
- Nutnosť škálovania projektu

(pravdepodobné cvičenie – Navrhnete heuristiku pre malý problém.

Použijete prístup informovaného vyhľadávania na malý problém, možno najkratšiu cestu s obmedzeniami.)

Téma 4. Fuzzy logika (len krátko)

Čo je to fuzzy logika a prečo je užitočná?

Fuzzy množiny, funkcie príslušnosti, fuzzy pravidlá a fuzzy inferencia Architektúra fuzzy riadiaceho systému (Mamdani, Takagi-Sugeno) Návrh fuzzy regulátorov

Metódy fuzzy inferencie (napr. max-min, súčin-súčet) Techniky defuzzifikácie

Reálne aplikácie fuzzy riadiacich systémov (napr. regulácia teploty, kontrola rýchlosti)

Porovnanie fuzzy riadenia s tradičnými metódami riadenia

(pravdepodobné cvičenie – jednoduchý systém na sledovanie zdravotného stavu, kamera s automatickým zaostrovaním alebo robotický manipulátor, pravdepodobne v matlabe?)

Téma 5. Expertné systémy (len krátko)

Základy automatizovaného uvažovania a deduktívnych systémov. Expertné systémy založené na pravidlách rozšírené o váženie pravidiel, faktory istoty a fuzzy logiku a siete Bayesovských presvedčení. Aplikácie v syntéze technických systémov, diagnostike a riadení procesov.

(pravdepodobné cvičenie – praktické skúsenosti s prevládajúcimi shellmi expertných systémov, napr. Prover9/Mace4, CLIPS, FuzzyCLIPS, Matlab, HuginLite.)

Téma 6. Strojové učenie 01a (prehľad)

Vedomosti T1:

- Hlavné úlohy strojového učenia vrátane riadených, bez dozoru, posilnenie a hlboké učenie
- Rozdiel medzi symbolickým a numerickým učením
- Význam robustného hodnotenia, kvalita dát, potreba regularizácie.

Téma 6. Strojové učenie 01b Riadené učenie

Vedomosti T1:

- Hlavné úlohy učenia pod dohľadom: regresia a klasifikácia
- Kompromis medzi zaujatosťou a odchýlkou; Occamova britva pre jednoduché modely.

- Potreba oddelenia tréningových, testovacích a validačných údajov. Definujte chybu tréningu a chybu testovania.
- Spoločné metriky hodnotenia pre klasifikačné úlohy (napr. presnosť, senzitivita, špecifickosť, presnosť, vybavovanie,...) a regresné úlohy (napr. stredná štvorcová chyba,...)
- Klasifikačné a regresné algoritmy (napr. lineárna regresia/klasifikácia, logistická regresia, najbližší sused, Naive Bayes, algoritmy učenia rozhodovacieho stromu).
- Súbory (napr. modely vo vreciach, vylepšené modely, náhodné lesy). (pravdepodobné cvičenie – Vykonajte aspoň klasifikačný a regresný algoritmus na množine údajov.)

Téma 7. Strojové učenie 02 učenie bez dozoru

Vedomosti T1:

- Hlavné úlohy učenia bez dozoru vrátane zhľukovania a redukcie rozmerov.
- Prípady použitia pre obe úlohy (napr. prieskum/sumarizácia/vizualizácia údajov, výber funkcií, kompresia údajov, odšumovanie údajov, učenie prototypov, systémy odporúčaní, modelovanie tém).
- k-means, hierarchické zhľukovanie, metódy založené na hustote ako napr. Gaussove modely zmesí (GMM).
- Kompromisy klastrovania založeného na konektivitě a klastrovania založeného na centroidoch.
- Analýza hlavných komponentov (PCA).
- (pravdepodobné cvičenie – aplikujte aspoň jeden algoritmus zhľukovania a jeden algoritmus redukcie dimenzií na súbor údajov a napr. rozpoznávanie tváre pomocou PCA.)

Téma 8. Neurónové siete 01

Vedomosti T2:

- Ako sa viacvrstvové neurónové siete (vrátane nehlbkových sietí) učia a kódujú funkcie vyššej úrovne zo vstupných funkcií.
- Spoločné architektúry hlbokého učenia, ako sú hlbkové dopredné siete, konvolučné neurónové siete (CNN), rekurentné neurónové siete (RNN) a LSTM; účel a vlastnosti každého z nich.
- Praktické výzvy spoločných prístupov hlbokého učenia, napr. výber architektúry hlbokého učenia, dostatok údajov/možnosť preplnenia, dĺžka času učenia, interpretovateľnosť.
- Príklady metód regularizácie pre architektúry hlbokého učenia, ako je skoré zastavenie, zdieľanie parametrov a výpadok.
- Príklady metód na zmiernenie iných výziev hlbokého učenia, ako sú nástroje, ktoré pracujú s GPU alebo na distribuovaných systémoch.
- (pravdepodobné cvičenie – Použite súpravu nástrojov na hlboké učenie (Keras, resp. PyTorch, Tensorflow) na štúdium výstupu naučeného modelu z dátového súboru..)

Téma 9. Neurónové siete 02

- Výber vhodných nástrojov, ktoré sa prispôbia veľkosti údajov – konkrétne spracovanie veľkých údajov vyžaduje nástroje Deep Learning, ktoré fungujú paralelne.
- Buďte si vedomí dostupných najmodernejších nástrojov hlbokého učenia.
- Aspoň jeden bežne používaný algoritmus na učenie v kontexte hlbokých sietí, napr. ako sa spätné šírenie používa v hlbokkej doprednej sieti alebo ako sa spätné šírenie používa na učenie sa funkcií vyššieho rádu v konvolučnej sieti; ako sa spätné šírenie v čase používa v rekurentných sieťach.



- Konvolúcia a jej užitočnosť, napr. detekcia zvislých hrán v obraze.
- združovanie; príklady funkcií, ako je max pooling a prípady použitia.
- Výzva dlhodobých vs krátkodobých závislostí v rekurentných nervových sieťach; aspoň jedno riešenie, ako napríklad LSTM. (pravdepodobné cvičenie – Použite súpravu nástrojov na hlboké učenie pre súbor údajov vrátanesiet, ako je klasifikácia obrázkov, detekcia objektov v obrázkoch v skutočnom prípade použitia.)

Téma 10. Hlboké posilňovanie učenia

Definícia posilňovacieho učenia, odmien, agentov, prostredí, aplikácií (napr. agentov na hranie hier, robotiky)

Markovove rozhodovacie procesy (MDP), Markovova vlastnosť, stavové prechody, odmeny, hodnotové funkcie (stavová hodnota a akčná hodnota)

Bellmanove rovnice a podmienky optimality

Model-based RL: Učenie sa modelu prostredia (prechod stavu a funkcie odmeňovania), dynamické programovanie (hodnota, opakovanie politiky)

RL bez modelu: učenie s časovým rozdielom (TD), algoritmus Q-learning, algoritmus SARSA

Politický RL: Reprezentácia a parametrizácia, gradientové metódy (REINFORCE, herec-kritický)

Deep Reinforcement Learning, Deep Q-networks (DQN), gradient politiky s hlbokými neurónovými sieťami, herecký kritik s hlbokými neurónovými sieťami, kompromis medzi prieskumom a využívaním

(pravdepodobné cvičenie – učenie pre jednoduchého simulovaného robota, lokalizácia robota)

Téma 11. Spracovanie prirodzeného jazyka

Spracovanie textu a lingvistická analýza, techniky predspracovania textu, nástroje lingvistickej analýzy, značkovanie a syntaktická analýza

Dialógové systémy a konverzačné agenti, porozumenie prirodzenému jazyku (NLU), generovanie prirodzeného jazyka (NLG), metriky hodnotenia chatbotov

Hlboké učenie pre NLP, rekurentné a konvolučné neurónové siete, modely založené na pozornosti, architektúra transformátora

Pokročilé témy NLP: Rozpoznávanie pomenovaných entít (NER), Analýza sentimentu,

Modelovanie tém, sumarizácia textu

Etické hľadiská v NLP, zaujatosť a spravodlivosť v NLP, obavy o súkromie a bezpečnosť, zodpovedné postupy AI

(pravdepodobné cvičenie – hra s naozaj malým predchodcom ChatGPT resp pomocou pokročilejších inteligentných chatbotov.)

Téma 12. Robotika

3D videnie v robotike 3D súradnicové rámce,

surové vybočenie, kvaternióny,

základy SLAM (simultánna lokalizácia a mapovanie), pravdepodobnostná robotika (Rozšírený Kalmanov filter, Particle filter) Vnímanie objektov pre manipuláciu robota

Neurónové vyžarovacie polia pre vnímanie

Odhad polohy a detekcia polohy robota

Etické úvahy

(pravdepodobné cvičenie – ovládanie jednoduchého simulovaného robota pomocou fuzzy logiky, neurónových sietí, posilňovacieho učenia alebo kódu vytvoreného Chatbotom z príkazov v prirodzenom jazyku, pomocou softvéru na simuláciu robotiky pre začiatočníkov, ako je Microsoft Robotics Developer Studio, Robotics Virtual Worlds, NVIDIA ISAAC Platforma pre robotiku...)

Výhody navrhovaných tém

- Dodržiava plán v návrhu aj AI časti „Výpočtové kompetencie...“
- Logicky nadväzuje na vnútornú štruktúru, tzn

Umela inteligencia⇒Fuzzy logika ako súčasť voliteľnej logiky v AI⇒Expertné systémy (môžu používať fuzzy logiku)⇒Strojové učenie ako súčasť AI⇒Neurónové siete ako súčasť ML⇒Hlboké posilňovanie učenia⇒Spracovanie prirodzeného jazyka (pomocou NN)⇒Robotika (s NN, NLP)

Nevýhody navrhovaných tém

- AI časť „Computing Competencies...“ obsahuje niektoré menej zaujímavé základy (napríklad používanie klasickej logiky)
- Tieto témy zaberajú príliš veľký kus z učebných osnov, ponechávajú príliš málo pre neurónové siete a prakticky nič na spracovanie obrazu, čo na praktické zvaženie ponecháva čas len na jednoduché cvičenia a pravdepodobne nie aplikácie v reálnom svete.

Alternatívna štruktúra tém?

- Témy 1-3 Umelá inteligencia
- Témy 4 Fuzzy logika
- Téma 5 Expertné systémy
- Témy 6-7 Strojové učenie
- Témy 9-10 Neurónové siete, posilňovacie učenie.
- Téma 11 Spracovanie prirodzeného jazyka
- Téma 12 Robotika Možno zahrnúť spracovanie obrazu?

III. KOMPETENCIE A VZDELÁVANIE ZALOŽENÉ NA KOMPETENCIÁCH

A. kompetencie¹

Kompetencia je znalosť, správanie, postoj a zručnosti osoby, ktoré ju vedú k schopnosti uspieť v práci.

B. Vzdelávanie založené na kompetenciách

CBE je systém výučby, hodnotenia, spätnej väzby, sebareflexie a akademických správ, ktorý je založený na tom, že študenti preukazujú, že sa naučili vedomosti, postoje, motiváciu, sebaopímanie a zručnosti, ktoré sa od nich očakávajú, keď postupujú vo vzdelávaní.²

¹Kompetencia verzus kompetencia

kompetencie je vaša schopnosť vo všeobecnosti rozumieť a vykonávať čokoľvek na základnej úrovni – znalosti a všeobecný stav bytia. **kompetencia** sa vzťahuje na vašu schopnosť vykonávať konkrétnu úlohu, v ktorej vás niekto vyškolil.

²<https://www.aacnursing.org/Essentials/Definition-of-Competency-Based-Education>



CBE je systém³ v ktorom:

- Študenti:
 - napredovať na základe ich schopnosti zvládnuť zručnosť alebo kompetenciu vlastným tempom bez ohľadu na prostredie;
 - majú každý deň možnosť robiť dôležité rozhodnutia o svojich vzdelávacích skúsenostiach, o tom, ako budú vytvárať a uplatňovať vedomosti a ako budú demonštrovať svoje učenie;
 - dostávajú včasnú, diferencovanú podporu založenú na ich individuálnych vzdelávacích potrebách;
- Prísne, bežné očakávania týkajúce sa učenia sú explicitné, transparentné, merateľné a prenosné.
- Pokrok študentov založený na dôkazoch majstrovstva, nie na čase strávenom sedadiel;
- Hodnotenie je zmysluplná, pozitívna a posilňujúca vzdelávacia skúsenosť pre študentov, ktorá prináša aktuálne, relevantné a použiteľné dôkazy;

Zmena paradigmy:

- Kreditná hodina -> zvládnutie obsahu
- Zameranie na vyučovanie -> zameranie na učenie (Presúva primárne zameranie vzdelávania na požadované výsledky (pre učiacich sa) a nie na štruktúru a proces vzdelávacieho systému)
- Čas je konštantný/učenie je premenlivé -> čas je premenlivé/učenie je konštantné
- **Väčšie zameranie na vstup zamestnávateľ**ao potrebách vedomostí, zručností a schopností (KSA) budúcich zamestnancov

Základné princípy CBE

- Vzdelávanie zamerané na študentov
- Súbor očakávaní, ktoré demonštrujú, s čím môžu študenti robiť a čo vedieť
- Žiakom, zamestnávateľom a verejnosti sú jasné očakávania.
- Viditeľne preukázané a hodnotené v priebehu času viacerými metódami a viacerými posudzovateľmi.

Vzdelávacie skúsenosti v CBE musia byť:

- integračné a zážitkové
- sebauvedomujúci a reflektujúci
- aktívne a interaktívne
- vývojový
- prenosné

CBE nie je:

- Kontrolný zoznam úloh
- Jedinečná skúsenosť alebo ukážka.
- Izolované v jednej sfére starostlivosti alebo kontextu;
- Preukázané len na objektívnom teste.

C. Vývoj rámca kompetencií AI

1) Existujúce rámce kompetencií

Podľa ACM/IEEE Computing Competencies for Undergraduate Data Science Curricula (strana 48), Artificial Intelligence (AI) zahŕňa metodológie na modelovanie a simulovanie niekoľkých ľudských schopností, ktoré sú všeobecne akceptované ako reprezentujúce inteligenciu. Vnímanie, reprezentovanie, učenie sa, plánovanie a uvažovanie pomocou vedomostí a dôkazov sú kľúčové témy.

³<https://aurora-institute.org/our-work/competencyworks/competency-based-education/>

Rozsah	Kompetencie
<ul style="list-style-type: none"> Hlavné podpolia AI Reprezentácia a zdôvodnenie Plánovanie a riešenie problémov Etické úvahy 	<ul style="list-style-type: none"> Opíšte hlavné oblasti AI, ako aj kontexty, v ktorých možno metódy AI použiť. Reprezentovať informácie v logickom formalizme a aplikovať relevantné metódy uvažovania. Reprezentovať informácie v pravdepodobnostnom formalizme a aplikovať relevantné metódy uvažovania. Uvedomte si širokú škálu etických úvah týkajúcich sa systémov AI, ako aj mechanizmov na zmiernenie problémov.

Subdomény

<ul style="list-style-type: none"> AI-generál Reprezentácia znalostí AI a uvažovanie (modely založené na logike) Reprezentácia znalostí AI a uvažovanie (modely založené na pravdepodobnosti) 	<ul style="list-style-type: none"> AI-plánovanie a stratégie vyhľadávania
--	--

Na druhej strane konzultácie UNESCO o rámcoch kompetencií AI pre učiteľov zahŕňa:

- AI gramotnosť,
- AI a pedagogika,
- etika AI,
- používanie AI na nepretržitý profesionálny rozvoj,
- schopnosť rozvíjať kompetencie AI pre študentov atď.

Podľa kompetenčného rámca AI Concordia University a Dawson College (2021) by kompetenčné domény mohli byť štruktúrované v troch hlavných smeroch: technické, obchodné a ľudské, kde sú etické kompetencie horizontálne a sú integrované v každej z týchto troch domén.

Technická	Podnikanie	Ľudské
<ul style="list-style-type: none"> Údaje Matematika a štatistika Programovanie Strojové učenie Hlboké učenie Infraštruktúra Knižnice a rámce 	<ul style="list-style-type: none"> Iniciatíva AI a plánovanie projektov Iniciatíva AI a škálovanie projektu AI technológie 	<ul style="list-style-type: none"> Inovácia Tímová práca Profesionalita Etika

2) Cieľové skupiny FAAI

Na rozlíšenie hlavných kompetencií pre projekt je dôležité zamerať sa na priame cieľové skupiny. Oni sú:

- Vysokoškóľáci
- manažérov MSP
- výskumníkov a odborníkov



3) *Rámec kompetencií FAAI*

Vybraných dvanásť hlavných technických kompetencií je:

1. Rozpoznať šírku a užitočnosť metód strojového učenia
2. Porovnajte a porovnajte metódy strojového učenia
3. Vyberte vhodné (triedy) metód strojového učenia pre konkrétne problémy.
4. Pri nasadzovaní algoritmov strojového učenia používajte vhodné školiace a testovacie metodiky.
5. Vysvetlite metódy na zmiernenie účinkov nadmerného prispôsobenia a priebehu dimenzionality v kontexte algoritmov strojového učenia.
6. Identifikujte vhodnú metriku výkonu na vyhodnotenie algoritmov/nástrojov strojového učenia pre daný problém.
7. Rozpoznať problémy súvisiace so skreslením algoritmov a údajov, ako aj so súkromím a integritou údajov.
8. Diskutujte o možných účinkoch – pozitívnych aj negatívnych – rozhodnutí vyplývajúcich zo záverov strojového učenia.
9. Opíšte hlavné oblasti AI, ako aj kontexty, v ktorých možno metódy AI použiť.
10. Reprezentovať informácie v logickom formalizme a aplikovať relevantné metódy uvažovania.
11. Reprezentovať informácie v pravdepodobnostnom formalizme a aplikovať relevantné metódy uvažovania.
12. Uvedomte si širokú škálu etických úvah týkajúcich sa systémov AI, ako aj mechanizmov na zmiernenie problémov.

V rámci kompetencií FAAI bude etika horizontálnou zložkou.

IV. MODULY KURZU FAAI

A. *Moduly V1*

Časť 1 - Úvod

- Modul 1 - Základné princípy aplikácie umelej inteligencie vo vede av moderných podnikových riešeniach

Časť 2 – Skutočné prípady AI v životeza podporu a inovatívne riešenia

- Modul 2 - AI v poľnohospodárstve
- Modul 3 – AI v zdravotníctve
- Modul 4 - AI v ekológii
- Modul 5 – AI v životnom štýle a inteligentnom meste
- Modul 6 – AI v priemysle a robotoch
- Modul 7 – AI v ľudstve

Časť 3– Softvérové riešenia, knižnice a moduly AI

- Modul 8 – Vstavaný komerčný softvér: IBM, Microsoft, AWS atď.
- Modul 9 - Vstavaný softvér s otvoreným zdrojom
- Modul 10 - Vykonávanie výskumu súvisiaceho s praktickou aplikáciou umelej inteligencie
- Modul 11 – Vytváranie softvérových aplikácií pomocou AI
- Modul 12 - Implementácia externých modulov AI v softvérových aplikáciách

B. *Moduly V2*

Časť 1 - Úvod

- Modul 1 - Základné princípy aplikácie umelej inteligencie vo vede av moderných podnikových riešeniach

Časť 2- Spôsob implementácie softvéru

- Modul 2 – Zabudovateľné moduly od IBM, Microsoft, Google, AWS atď.
- Modul 3 – Vykonávanie výskumu súvisiaceho s praktickou aplikáciou umelej inteligencie
- Modul 4 – Vytváranie softvérových aplikácií pomocou AI
- Modul 5 - Implementácia externých modulov AI do softvérových aplikácií

3. časť – Oblasť aplikovanej umelej inteligencie

- Modul 6 – Riešenia pre ekológiu založené na AI
- Modul 7 – Riešenia založené na AI pre poľnohospodárstvo
- Modul 8 – Riešenia založené na AI pre HealthCare
- Modul 9 – Riešenia založené na AI pre Smart City
- Modul 10 – Riešenia založené na AI pre priemysel
- Modul 11 – Riešenia založené na AI v robotike
- Modul 12 – Aplikácia ďalších modulov AI



V. KOMPETENCIE CROSS MATRIX MODULE

Téma kompetencie	Úvod- Základné princípy aplikácie AI vo vede av moderných podnikových riešeniach	Skutočné prípady pre AI v živote pre podporu a inovatívne riešenia						Softvérové riešenia AI – komerčné a open source				
		poľnohospo dárstvo	Zdravotná starostlivos ť	Ekológia	Životný štýl a Smart City	Priemyse l a roboty	Humanitné vedy	Vstavaný komerčný softvér	Vstavaný softvér s otvoreným zdrojom	Vykonávanie výskumu súvisiaceho s praktickou aplikáciou AI	Vytváranie softvérovýc h aplikácií pomocou AI	Implementácia externých modulov AI do softvérových aplikácií
Rozpoznať šírku a užitočnosť metód strojového učenia												
Porovnajate a porovnajate metódy strojového učenia												
Vyberte vhodné (triedy) metód strojového učenia pre konkrétne problémy.												
Pri nasadzovaní algoritmov strojového učenia používajte vhodné školiace a testovacie metodiky.												
Vysvetlite metódy na zmiernenie účinkov nadmerného prispôsobenia a priebehu dimenzionality v kontexte algoritmov strojového učenia.												
Identifikujte vhodnú metriku výkonu na vyhodnotenie algoritmov/nástrojov v strojového učenia pre daný problém.												
Rozpoznať problémy súvisiace so skreslením algoritmov a údajov,												



VI. CROSS MATRIX „MODUL-COMPETENCE“

modul \ kompetencie	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12
Opište hlavné oblasti AI, ako aj kontexty, v ktorých možno metódy AI použiť.	X	X	X		X							X
Reprezentovať informácie v logickom formalizme a aplikovať relevantné metódy uvažovania.		X			X							X
Reprezentovať informácie v pravdepodobnostnom formalizme a aplikovať relevantné metódy uvažovania.		X			X							X
Uvedomte si širokú škálu etických úvah týkajúcich sa systémov AI, ako aj mechanizmov na zmiernenie problémov.		X	X		X							X
Rozpoznať šírku a užitočnosť metód strojového učenia	X		X									
Porovnajte a porovnajte metódy strojového učenia		X		X	X	X	X	X	X	X	X	X
Vyberte vhodné (triedy) metód strojového učenia pre konkrétne problémy.	X		X			X	X	X	X	X	X	
Pri nasadzovaní algoritmov strojového učenia používajte vhodné školiace a testovacie metodiky.	X			X		X	X	X	X	X	X	
Vysvetlite metódy na zmiernenie účinkov nadmerného prispôsobenia a priebehu dimenzionality v kontexte algoritmov strojového učenia.				X		X	X	X	X	X	X	
Identifikujte vhodnú metriku výkonu na vyhodnotenie algoritmov/nástrojov strojového učenia pre daný problém.				X		X	X	X	X	X	X	
Rozpoznať problémy súvisiace so skreslením algoritmov a údajov, ako aj						X	X	X	X	X	X	

so súkromím a integritou údajov.												
Diskutujte o možných účinkoch – pozitívnych aj negatívnych – rozhodnutí vyplývajúcich zo záverov strojového učenia.						X	X	X	X	X	X	

Moduly:

M1 - Základné princípy aplikácie AI vo vede a v moderných podnikových riešeniach

M2 - Zabudovateľné moduly od IBM, Microsoft, Google, AWS atď.

M3 - Vykonávanie výskumu súvisiaceho s praktickou aplikáciou umelej inteligencie

M4 – Vytváranie softvérových aplikácií pomocou AI

M5 - Implementácia externých modulov AI do softvérových aplikácií

M6 - Riešenia pre ekológiu založené na AI

M7 – riešenia založené na AI pre poľnohospodárstvo

M8 – riešenia založené na AI pre HealthCare

M9 – riešenia založené na AI pre Smart City

M10 – riešenia založené na AI pre priemysel

M11 - Riešenia založené na AI v robotike

M12 - Aplikácia ďalších modulov AI

VII. ŠTRUKTÚRA HLAVNÉHO MODULU

1. Trvanie:

120 hodín

- 12modul

o 10 hodín na modul

- 4 hodinová prednáška
- 6 hodín vzdelávacích aktivít

2. Modul Design – štruktúra**Učebný plán**

Prednášky - 1

Ukážka, praktické úlohy v tíme, Zadanie seminára - 1 za prednášku

Učebné scenáre – min 5

Návody, úlohy – 1

Zdroje

Otázky do diskusie – min 5

Kvíz: 1 s ~40-50 blízkyimi otázkami so 4 odpoveďami/rozptyľovačmi

Prezentácie: 1 s minimálne 30 snímkami

Demonštranti: 2

Učebné video: min 2

Obsah - 1

Externá URL – podľa potreby

VIII. PRÍKLADY VZDELÁVACÍCH AKTIVÍT

Laboratórna práca s lacnými 3D senzormi


- Spracovanie mračna bodov pomocou 3D senzorov

Spolupráca s priemyslom

- Spracovanie mračna bodov pomocou 3D senzorov
- 2D spracovanie obrazu na charakterizáciu defektov

Fotogrametria a 3D vizualizácia (workshop pre študentov)

- Spolupráca s Fakultou námorných štúdií
- Cieľ vzdelávania: vytváranie fotorealistických 3D modelov a ich neskoršie použitie v rôznych aplikáciách AI: inteligentné monitorovanie kultúrneho dedičstva pod vodou, detekcia odpadu pod vodou, AR pre podvodné múzeum




Zamerajte sa na Edge AI

- Modely počítačového videnia AI nasadené na vstavaných systémoch



Laboratórna práca – prepojenie Raspberry Pi poháňaného AI s Arduino na ovládanie efektora

- Spolupráca so strojnickou fakultou




Malé európske projekty zisťovanie chýb





Autori: Jakob Božič, Domen Tabernik, Danijel Škočaj, Kolektor Group d.o.o



Tobias Schlagenhau, Magnus Landwehr, industrial machine tool component surface defect dataset, Data in Brief, Volume 39, 2021, 107643, ISSN 2352-3409, <https://doi.org/10.1016/j.dib.2021.107643>



Matthias Wieler, Tobias Hahn, Fred A. Hamprecht. (2007) Weakly supervised learning for industrial optical inspection. [Dataset]. Retrieved from: <https://hci.iwr.uni-heidelberg.de/content/weakly-supervised-learning-industrial-optical-inspection>



Autori: Jakob Božič, Domen Tabernik, Danijel Škočaj, Kolektor Group d.o.o



Source: <https://www.micro.ai/resources/case-studies/ai-enabled-defect-detection-solutions-in-manufacturing>

HPC pre najpokročilejšie hlavné projekty



Zdrojilustrácia: <https://www.kingston.com/en/blog/servers-and-data-centers/4-things-data-centers-can-ucit-sa-od-hpc>

IX. ZÁVERY

Okrem pestovania základných kompetencií v oblasti výpočtovej techniky a štatistiky by študenti, ktorí sa venujú vede o údajoch, mali byť vybavení na to, aby tieto zručnosti mohli efektívne aplikovať na praktické scenáre. Integrácia autentických súborov údajov v relevantnom kontexte je nevyhnutná pre holistické vzdelávanie v oblasti vedy o údajoch.

Ukázalo sa, že je výhodné štruktúrovať určité kurzy v rámci disciplinárneho rámca, čím sa podporuje porozumenie medzi študentmi, že veda o údajoch nie je len abstraktným súborom metodológií. Možné aplikačné disciplíny zahŕňajú fyziku, biológiu, chémiu, humanitné vedy alebo iné relevantné oblasti. Tento prístup zvyšuje pochopenie študentov pre dôsledky v reálnom svete a rôzne aplikácie vedy o údajoch.

X. REFERENCIE

1. Danyluk, Andrea a Leidig, Paul, "Výpočtové kompetencie pre vysokoškolské učebné osnovy dátových vied: ACM Data Science Task Force" (2021). Recenzované publikácie.
8. <https://scholarworks.gvsu.edu/cispeerpubs/8>