



Co-funded by  
the European Union

FAAI:

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

01.09.2022 – 31.08.2024

## A3.3 Wymagania dotyczące uczenia się sztucznej inteligencji: WP3





**Co-funded by  
the European Union**

Powstanie tego dokumentu było możliwe dzięki wsparciu projektu ERASMUS+: Przyszłość tkwi w stosowanej sztucznej inteligencji (2022-1-PL01-KA220-HED-000088359)

Finansowany przez Unię Europejską. Wyrażone poglądy i opinie są jednak wyłącznie poglądami i opiniami autora (autorów) i niekoniecznie odzwierciedlają poglądy i opinie Unii Europejskiej lub agencji narodowej (NA). Ani Unia Europejska, ani Ameryka Północna nie mogą ponosić za nie odpowiedzialności.



**Data**

21.05.2023

**Miejsca rozwoju wyniku**

Uniwersytet Bielsko-Biała, Bielsko-Biała, Polska

Uniwersytet Bibliotekoznawstwa i Technologii Informacyjnych, Sofia, Bułgaria

Uniwersytet w Niszu, Serbia

Uniwersytet św. Cyryla i Metodego w Trnawie, Słowacja

Uniwersytet Czarnogóry, Czarnogóra

**Streszczenie:** Konsorcjum projektu „The Future is in Applied Artificial Intelligence” opracowało pierwszy projekt oparty na kompetencjach program nauczania sztucznej inteligencji na poziomie instytucji szkolnictwa wyższego. Opracowanie opierało się na zaawansowanych badaniach systemowych istniejących zasobów związanych ze sztuczną inteligencją oraz badaniach grup docelowych nauczycieli, studentów technologii informatycznych i pracodawców, co powinno poprawić wyniki wdrażania edukacji w zakresie sztucznej inteligencji. Przygotowano przegląd stosowanej sztucznej inteligencji w formie klasteryzacji słów kluczowych. Wstępne dane zostały zebrane za pomocą ankiet, ofert pracy, istniejących szkoleń z zakresu sztucznej inteligencji, projektów naukowych i rzeczywistych przypadków. Syntetyczną analizę informacji tekstowych z badań przeprowadzono z wykorzystaniem techniki chmur słów. Do prezentacji kursu opartego na kompetencjach wykorzystano podejście oparte na tensorach. Specyficzne wymagania liczbowe dla przedmiotu w postaci priorytetów wynikają z rozwiązywania problemów decyzyjnych z wykorzystaniem techniki analitycznego procesu hierarchicznego. Na podstawie kompleksowej analizy ankiet, doświadczeń edukacyjnych, projektów naukowych i wymagań biznesowych, metaanalizy ostatnich referencji, określiliśmy kryteria szkolenia w formie reprezentacji kompetencji w oparciu o tensory w odniesieniu do treści i modułów edukacyjnych.

**Słowa kluczowe:** Hierarchiczny proces analityczny, sztuczna inteligencja stosowana, program nauczania oparty na kompetencjach, podejście tensory, chmury słów

## WPROWADZENIE

Aby skutecznie zastosować sztuczną inteligencję (AI) w świecie rzeczywistym, potrzebne jest kompleksowe podejście, obejmujące solidne gromadzenie i wstępne przetwarzanie danych, skuteczne projektowanie i szkolenie algorytmów, względy etyczne, ciągła ocena i doskonalenie, współpracę międzydyscyplinarną oraz staranną integrację z istniejącymi systemami i przepływami projektu. Innowacyjne kursy szkoleniowe odgrywają kluczową rolę w pomyślnym wdrażaniu modeli sztucznej inteligencji w świecie rzeczywistym, wyposażając uczniów w praktyczną wiedzę, praktyczne doświadczenie i umiejętność radzenia sobie ze złożonymi wyzwaniami, umożliwiając w ten sposób skuteczne opracowywanie, wdrażanie i dostosowywanie modeli sztucznej inteligencji do rzeczywistych scenariuszy.

Ogólne wymagania dotyczące skutecznego kursu szkoleniowego w zakresie sztucznej inteligencji obejmują kompleksowy program nauczania obejmujący koncepcje funkcjonalnej sztucznej inteligencji, praktyczne ćwiczenia i projekty, studia przypadków z życia wzięte, dostęp do odpowiednich zbiorów danych i narzędzi, doświadczonych instruktorów oraz skupienie się na kwestiach etycznych i zastosowaniach branżowych.

Celem pracy jest wypracowanie kompleksowego podejścia do projektowania szkolenia z zakresu stosowanej sztucznej inteligencji (AAI), które w oparciu o systemowe poszukiwanie wymagań biznesowych odpowiada zasadzie edukacji opartej na kompetencjach i innowacyjnej pedagogiki.

### *IDENTYFIKATOR PROJEKTU*

Prezentowana praca została zrealizowana w ramach projektu Erasmus+ 2022-1-PL01-KA220-HED-000088359 pt. "The Future is in Applied Artificial Intelligence"



Co-funded by  
the European Union

(FAAI) przez konsorcjum, w skład którego wchodzi Uniwersytet w Bielsku-Białej (Polska), Uniwersytet Bibliotekoznawstwa i Technologii Informacyjnych (Bułgaria), Uniwersytet Św. Cyryla i Metodosa w Trnawie (Słowacja), Uniwersytet w Niszu (Serbia), Uniwersytet Czarnogóry (Czarnogóra) i współfinansowany przez Unię Europejską. Projekt ma na celu zbliżenie uczelni i przedsiębiorstw w celu dostarczenia innowacyjnych rozwiązań w zakresie rozwoju ekspertów w dziedzinie sztucznej inteligencji [1].

Termin AAI odnosi się do praktycznego wdrażania i wykorzystywania technik i technologii sztucznej inteligencji do rozwiązywania rzeczywistych problemów i osiągania określonych celów w różnych dziedzinach. Stał się szeroko przyjęty i stosowany w społeczności i przemyśle sztucznej inteligencji w celu odróżnienia praktycznego zastosowania sztucznej inteligencji od teoretycznych badań i rozwoju. Termin ten podkreśla nacisk na wykorzystanie sztucznej inteligencji w praktycznych warunkach i wykorzystanie jej możliwości w celu sprostania konkretnym wyzwaniom i osiągnięcia wymiernych wyników.

Jednym z celów projektu jest zaprojektowanie kursu szkoleniowego z zakresu AAI, który odzwierciedlałby rzeczywiste potrzeby i powinien być oparty na kompetencjach. Przez cały czas trwania projektu prowadzone były badania systemowe, które opierały się na badaniach istniejących kursów AI, projektów naukowych, rzeczywistych przypadków, rynku pracy AI, studentów IT, wykładowców i pracodawców.

#### *POWIĄZANE ARTYKUŁY NA TEMAT AAI*

Przygotowując ankietę do powiązanych artykułów, wybraliśmy 10 tys. referencji z biblioteki WoS w wyniku zapytania "stosowana sztuczna inteligencja". Za pomocą CiteSpace [2] otrzymany zbiór prac został podzielony na 12 najbardziej znaczących klastrów pod względem słów kluczowych, jak pokazano na rys. 1.

Lista uzyskanych słów kluczowych obejmuje "sztuczna sieć neuronowa", "sztuczna inteligencja", "głębokie uczenie", "rak płuc", "wytłumaczalną sztuczną inteligencję", "chorobę COVID-19", "urządzenie IoT", "uczenie ze wzmocnieniem", "opracowanie leków", "komunikację bezprzewodową", "roztwór wodny", która pokazuje najważniejsze modele i zastosowania sztucznej inteligencji. Najczęściej cytowane prace w klastrach to [3] (klaster #0) związany z rozwiązaniami sztucznej inteligencji w patologii tarczycy, [4] (klastry #1, #3, #4, #5) związany z wspieraniem decyzji modelowej w kontekście, który człowiek może łatwo zinterpretować (wytłumaczalna sztuczna inteligencja), [5] (klaster #2) [6] (klaster #6) dotyczący techniki AI/ML w przypadku epidemii COVID-19, [7] (klaster #7) poświęcony sztucznej inteligencji i technologii DL ułatwiających analitykę danych systemów IoT, [8] (klaster #8) dotyczący zastosowań uczenia się przez wzmacnianie w różnych dziedzinach, [9] (klaster #9) dotyczący zastosowania sztucznej inteligencji w odkrywaniu leków, [10] (klaster #10) dotyczący komunikacji sieciowej opartej na sztucznej inteligencji, [11] (klaster #11) dotyczący sztucznej inteligencji w celu

badania środowiskowych.

Prace "wybuchowe" w całej tej analizie są związane z dobrymi praktykami i rzeczywistymi przypadkami; Są one wymienione poniżej:

[12] Wprowadzono terminologię "głębokiego uczenia"

[13] udostępnił dwa najlepiej działające moduły ConvNet do dalszych badań nad głębokimi reprezentacjami wizualnymi w widzeniu komputerowym

[14] Kontrola na poziomie ludzkim poprzez głębokie uczenie się wzmacniające

[15] to podręcznik Deep Learning, który ma pomóc studentom i praktykom wejść w dziedzinę uczenia maszynowego w ogóle, a w szczególności uczenia głębokiego

[14] wprowadził nowy trend polegający na uczeniu się złożonych motywów przy użyciu dużych zbiorów danych. Uważa się, że głębokie sztuczne sieci neuronowe wykorzystują wiele warstw do odkrywania wzorców (bardziej złożonych z każdą warstwą) i struktury dużych zbiorów danych. Podejście to może być stosowane do DNA, RNA i zastosowań w medycynie.

[16] Dokonano przeglądu głębokiego uczenia nadzorowanego, uczenia nienadzorowanego, uczenia się przez wzmacnianie i obliczeń ewolucyjnych.

[17] zaprezentował ImageNet, punkt odniesienia w klasyfikacji i wykrywaniu kategorii obiektów na setkach kategorii obiektów i milionach obrazów

[18] zaprezentował szkolenie dużej, głębokiej konwolucyjnej sieci neuronowej w celu sklasyfikowania 1,2 miliona obrazów o wysokiej rozdzielczości w konkursie ImageNet LSVRC-2010 na 1000 różnych klas.

[19] zaprezentowali nowe podejście do komputerowego Go, które wykorzystuje głębokie sieci neuronowe wytrenowane przez nowatorskie połączenie nadzorowanego uczenia się z gier eksperckich i uczenia się przez wzmacnianie z gier samodzielnych.

## KONTEKST BADANIA

### EDUKACJA OPARTA NA KOMPETENCJACH

Edukacja oparta na kompetencjach (CBE) zyskiwała na popularności jako podejście edukacyjne, które koncentruje się na rozwijaniu konkretnych umiejętności i zdolności, a nie tylko na zdobywaniu wiedzy. CBE ma na celu przygotowanie uczniów do rzeczywistych wyzwań poprzez zapewnienie im niezbędnych kompetencji, aby odnieść sukces w wybranych przez nich dziedzinach. Poniżej przedstawiamy kilka kluczowych cech i elementów powszechnie kojarzonych z najnowocześniejszą edukacją opartą na kompetencjach, koncentrującą się na edukacji informatycznej.

CBE opiera się na jasno zdefiniowanych *ramach kompetencji*, które określają konkretne umiejętności i wiedzę, które uczniowie powinni zdobyć. Ramy te zazwyczaj dzielą kompetencje na mierzalne efekty uczenia się [20].

CBE często promuje *personalizowane* doświadczenia edukacyjne dostosowane do indywidualnych potrzeb i zainteresowań uczniów. Pozwala uczniom na postępy we własnym tempie i zapewnia elastyczność w zakresie treści, działań edukacyjnych i metod oceny [21].

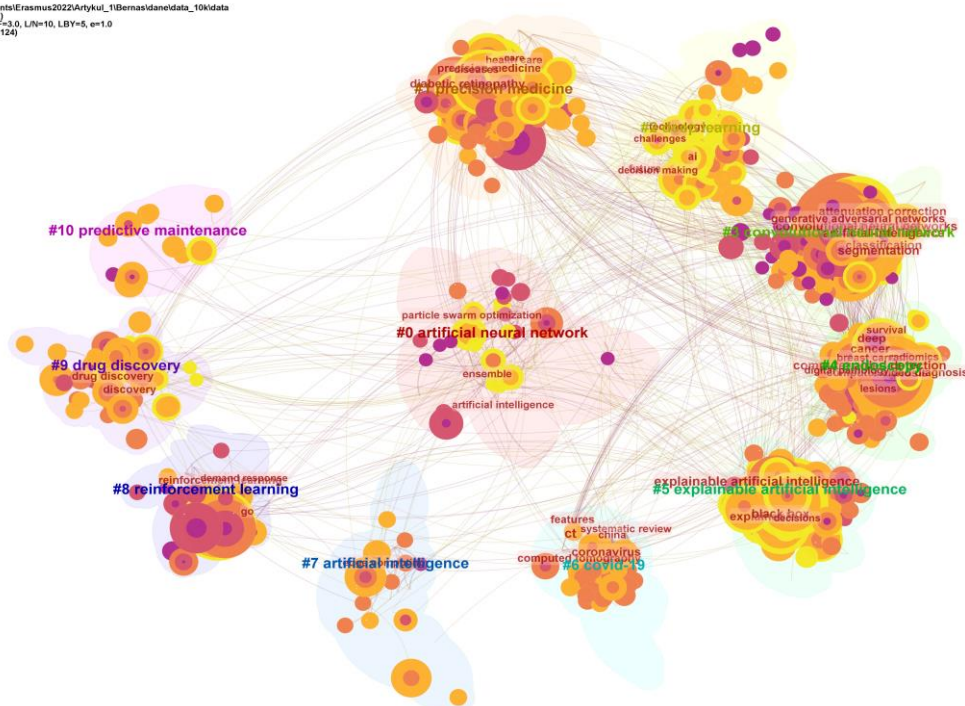
W CBE oceny koncentrują się na ocenie wykazanych kompetencji uczniów, a



Co-funded by  
the European Union

nie polegają wyłącznie na tradycyjnych egzaminach lub standaryzowanych testach. *Autentyczne oceny* [22] mogą obejmować projekty, portfolio, prezentacje, symulacje lub zadania w świecie rzeczywistym, które pokazują umiejętności uczniów w rzeczywistych kontekstach.

CiteSpace, v. 5.2.R4 (64-bit) Advanced  
July 2, 2023 at 4:06:53 PM CEST  
WoS: C:\Users\AM\OneDrive\Documents\Erasmus2022\Artyku\11Bernas\data\data\_10\data  
Timespan: 2019-2023 (Since Length=1)  
Selection Criteria: g-index (k=25), LRF=3.0, L/N=10, LBY=5, e=1.0  
Network: N=256, E=2644 (Density=0.0324)  
Largest CC: 832 (97%)  
Nodes Labeled: 1.0%  
Pruning: None  
Modularity Q=0.62  
Weighted Mean Silhouette S=0.8166  
Harmonic Mean(Q, S)=0.7145



CiteSpace

**RYСУNEK 1.** Wykres klastrowy dla publikacji WoS na przestrzeni ostatnich 10 lat w odpowiedzi na zapytanie dotyczące sztucznej inteligencji stosowanej

*Nauczanie w CBE* jest zaprojektowane w oparciu o ścieżki uczenia się mające na celu rozwój i wzmocnienie zidentyfikowanych kompetencji. Często obejmuje aktywne i empiryczne metody uczenia się, takie jak uczenie się oparte na projektach, rozwiązywanie problemów, praca zespołowa i praktyczne doświadczenia [23].

Najnowocześniejsze CBE często wykorzystują *integrację technologii* w celu poprawy doświadczeń edukacyjnych. Może to obejmować korzystanie z platform internetowych, adaptacyjnych systemów uczenia się, aplikacji edukacyjnych, narzędzi rzeczywistości wirtualnej (VR) i rzeczywistości rozszerzonej (AR), które mogą dostarczać spersonalizowanych informacji zwrotnych, symulacji i treści

interaktywnych [24].

CBE opowiada się za uznawaniem i przyznawaniem *referencji* na podstawie wykazanych kompetencji [25]. Może to obejmować wydawanie cyfrowych odznak, certyfikatów, a nawet stopni naukowych, które podkreślają określone umiejętności i zdolności osiągnięte przez uczniów.

CBE wykracza poza formalne ramy edukacyjne i podkreśla znaczenie *uczenia się przez całe życie i ustawicznego rozwoju zawodowego* [26]. Ma na celu promowanie nastawienia na ciągłe doskonalenie i zdolność adaptacji, aby sprostać zmieniającym się wymaganiom siły roboczej.

#### EDUKACJA IT

Stan wiedzy informatycznej obejmował kilka kluczowych obszarów.

*Nauczanie mieszane* łączy tradycyjne nauczanie w klasie z zasobami i zajęciami online. Wykorzystuje technologię, aby zapewnić bardziej interaktywne i spersonalizowane doświadczenie edukacyjne. Takie podejście umożliwia uczniom dostęp do materiałów szkoleniowych, współpracę z rówieśnikami i angażowanie się w praktyczne ćwiczenia za pośrednictwem platform cyfrowych.

*Nauczanie oparte na projektach* koncentruje się na praktycznych zastosowaniach umiejętności informatycznych. Studenci pracują nad rzeczywistymi projektami, indywidualnie lub w zespołach, aby rozwiązywać problemy, projektować oprogramowanie lub tworzyć innowacyjne rozwiązania. Takie podejście promuje krytyczne myślenie, rozwiązywanie problemów i współpracę, jednocześnie dając uczniom praktyczne doświadczenie.

*Adaptacyjne systemy nauczania* wykorzystują technologię do personalizacji doświadczeń edukacyjnych w oparciu o indywidualne potrzeby i wyniki uczniów. Systemy te analizują dane dotyczące mocnych i słabych stron uczniów oraz stylów uczenia się, aby zapewnić dostosowane treści, tempo i informacje zwrotne. Dostosowując się do wymagań każdego ucznia, adaptacyjne uczenie się zwiększa zaangażowanie i poprawia wyniki uczenia się.

Dostrzegając rosnące znaczenie umiejętności kodowania, wiele instytucji edukacyjnych kładzie nacisk na kodowanie i *myślenie obliczeniowe* w swoich programach nauczania IT. Studenci uczą się języków programowania, algorytmów, struktur danych i technik rozwiązywania problemów. To skupienie wyposaża ich w podstawowe umiejętności wymagane do tworzenia oprogramowania, analizy danych i innych dziedzin IT.

Biorąc pod uwagę rosnące znaczenie *cyberbezpieczeństwa*, edukacja informatyczna często obejmuje zasady i praktyki w zakresie cyberbezpieczeństwa. Studenci uczą się zabezpieczania sieci, ochrony danych, identyfikowania luk w zabezpieczeniach i reagowania na zagrożenia cybernetyczne. Instytucje mogą oferować specjalistyczne kursy lub programy studiów w zakresie cyberbezpieczeństwa, aby zaspokoić zapotrzebowanie na wykwalifikowanych specjalistów w tej dziedzinie.

Rozprzestrzenianie się danych w różnych branżach doprowadziło do zwiększonego nacisku na *edukację w zakresie nauki o danych i analityki*. Studenci uczą się analizy statystycznej, wizualizacji danych, uczenia maszynowego i technik eksploracji danych. Programy edukacyjne często obejmują praktyczne





Co-funded by  
the European Union

doświadczenie z narzędziami do analizy danych i językami programowania powszechnie używanymi w tej dziedzinie, takimi jak Python lub R.

Najnowocześniejsza edukacja informatyczna kładzie również nacisk na *etyczne i społeczne implikacje* technologii. Uczniowie badają najważniejsze zagadnienia, takie jak prywatność, bezpieczeństwo, etyka cyfrowa, stronniczość algorytmiczna i wpływ technologii na społeczeństwo. To skupienie zachęca studentów do rozważenia szerszych konsekwencji swojej pracy i rozwijania odpowiedzialnego i integracyjnego podejścia do IT. Wiele instytucji edukacyjnych nawiązuje współpracę z liderami branży i oferuje *staże lub programy edukacyjne oparte na współpracy*. Współpraca ta daje studentom możliwość zdobycia praktycznego doświadczenia, pracy nad rzeczywistymi projektami i rozwijania sieci kontaktów zawodowych. Takie zaangażowanie przemysłu pomaga wypełnić lukę między środowiskiem akademickim a przemysłem, zapewniając absolwentom lepsze przygotowanie do Pracowników.

#### DEFINICJA AII

AAI odnosi się do wykorzystania technik i technologii sztucznej inteligencji do rozwiązywania rzeczywistych problemów i rozwiązywania praktycznych wyzwań w różnych dziedzinach, mających na celu zwiększenie ludzkich możliwości, usprawnienie procesów decyzyjnych i automatyzację złożonych procesów.

Stosowana sztuczna inteligencja obejmuje szeroki zakres dziedzin, w tym między innymi opiekę zdrowotną, finanse, transport (np. pojazdy autonomiczne), produkcję, cyberbezpieczeństwo i usługi dla klientów, takie jak spersonalizowane systemy rekomendacji. Najnowocześniejsze aplikacje wykorzystują takie techniki, jak uczenie maszynowe, głębokie sieci neuronowe, przetwarzanie języka naturalnego do rozumienia i generowania języka, widzenie komputerowe do analizy obrazu i wideo oraz robotyka do automatyzacji zadań fizycznych. Systemy eksperckie są również nadal istotne dla wspomagania decyzji opartych na wiedzy.

W przypadku stosowanej sztucznej inteligencji nacisk kładziony jest na opracowywanie praktycznych rozwiązań, które można zintegrować z istniejącymi systemami lub przepływami pracy w celu osiągnięcia wymiernych wyników. Często wiąże się to z gromadzeniem i wstępnym przetwarzaniem danych, analizowaniem i interpretowaniem złożonych zestawów danych, wyodrębnianiem znaczących wzorców i spostrzeżeń, trenowaniem modeli sztucznej inteligencji przy użyciu odpowiednich algorytmów, walidacją i dostrajaniem modeli oraz wdrażaniem ich w rzeczywistych scenach. Dzięki iteracyjnemu uczeniu się i udoskonalaniu modele sztucznej inteligencji są stale ulepszone w celu osiągnięcia większej dokładności, niezawodności i zdolności adaptacyjnych.

Ponadto stosowana sztuczna inteligencja uwzględnia implikacje etyczne, prawne i społeczne, zapewniając, że wdrożone systemy są przejrzyste, sprawiedliwe, bezpieczne i odpowiedzialne.



*ZAKRES PROBLEMÓW I OBSZARY AAI*

Zakres problemów związanych ze sztuczną inteligencją jest szeroki i różnorodny. Sztuczna inteligencja może być stosowana w wielu dziedzinach i może rozwiązywać różnego rodzaju problemy. Niektóre obszary, w których można wykorzystać sztuczną inteligencję, to: automatyzacja, wspomaganie decyzji,

**TABELA 1.** Zakres problemów związanych ze sztuczną inteligencją według malejącej kolejności istotności

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%

Przetwarzanie języka naturalnego, analiza obrazu i wideo, opieka zdrowotna, robotyka i systemy autonomiczne, gry i rozrywka, cyberbezpieczeństwo, inteligentne miasta i monitorowanie środowiska. Przykłady te stanowią zaledwie ułamek zakresu problemów związanych ze sztuczną inteligencją. Sztuczna inteligencja stale się rozwija i znajduje zastosowania w różnych branżach i sektorach, tworząc nowe możliwości rozwiązywania złożonych wyzwań oraz poprawy wydajności i procesów decyzyjnych. Projektując kurs oparty na kompetencjach w zakresie sztucznej inteligencji, należy wziąć pod uwagę całą gamę rzeczywistych przypadków sztucznej inteligencji.

W ramach projektu FAAI zbadano 267 rzeczywistych przypadków opartych na rozwiązaniach AAI. Tabela 1 przedstawia obszary zadań wraz z ich znaczeniem.



Co-funded by  
the European Union

#### *PROJEKTY NAUKOWE AAI*

Część badań w ramach programu FAAI Erasmus+ obejmowała ankietę dotyczącą projektów naukowych z zakresu stosowanej sztucznej inteligencji. Pytania miały na celu zbadanie potrzeb i oczekiwań projektów naukowych, które mają pomóc w szkoleniu specjalistów w dziedzinie Applied AI. Zebrano i przeanalizowano kwestionariusze dotyczące 63 projektów zebranych przez organizacje partnerskie z 5 krajów. Koordynatorzy projektu pochodzili z 19 krajów, 34 z uniwersytetów, 6 z akademii nauk, a 24 z innych organizacji lub firm. Ponieważ kwestionariusze koncentrowały się przede wszystkim na trwających projektach, uzyskane wyniki można uznać za aktualne i aktualne. Większość projektów ma od 1 do 6 uczestników; Jednak w jednym projekcie bierze udział 50 uczestników.

Do ciekawszych wyników należy odkrycie że ponad połowa projektów dotyczyła modułów uczenia się głębokich sieci neuronowych, a większość zadań związanych z uczeniem maszynowym, które zostały rozwiązane, dotyczyła przetwarzania obrazów, klasyfikacji, regresji, klastrowania i przetwarzania języka naturalnego. Spośród 63 ankiet 55 dotyczyło następujących zadań ML. W projektach nie wspomniano o reprezentacji wiedzy i wnioskowaniu, strategiach planowania i wyszukiwania, systemach eksperckich i logice rozmytej. Większość przypadków korzysta z otwartych bibliotek oprogramowania. Wśród wykorzystywanych bibliotek AI dominowały TensorFlow, Keras, scikit-learn i CUDA. Językami programowania były Python i C++.

#### *EDUKACJA W ZAKRESIE SZTUCZNEJ INTELIGENCJI*

Edukacja w zakresie sztucznej inteligencji szybko zyskuje na znaczeniu w dzisiejszym świecie opartym na technologii. Pełny przegląd nauczania i uczenia się sztucznej inteligencji w ciągu ostatnich 20 lat przedstawiono w [27]. Ponieważ sztuczna inteligencja nadal znajduje zastosowanie w różnych branżach i aspektach naszego życia, rośnie zapotrzebowanie na osoby z solidnym zrozumieniem pojęć i technik AAI. Sztuczna inteligencja i automatyzacja prawdopodobnie zostaną przyjęte przez jeszcze więcej firm w celu poprawy wydajności i produktywności. Technologie te mogą być wykorzystywane do automatyzacji powtarzalnych zadań, przetwarzania dużych ilości danych i tworzenia dokładniejszych prognoz. Dlatego konieczne jest dobre i ujednolicone podejście do edukacji AI.

Na poziomie szkoły średniej w [28] opracowali i ocenili program nauczania dotyczący sztucznej inteligencji.

W [29] dowiedli, że najlepsze praktyki w nauczaniu i uczeniu się sztucznej inteligencji w szkolnictwie wyższym składają się z kluczowych czynników, takich jak pewność siebie, lęk przed matematyką i różnice w wykształceniu studentów.

Jednak paradygmaty uczenia się oparte na kompetencjach, które są szczególnie skuteczne w rozwijaniu umiejętności praktycznych i przygotowywaniu osób do rzeczywistych zastosowań sztucznej inteligencji, nie są brane pod uwagę. Kursy

dotyczące sztucznej inteligencji powinny koncentrować się na nabywaniu określonych kompetencji i oferować praktyczne szkolenia dotyczące rzeczywistych problemów, umożliwiając uczącym się rozwijanie umiejętności i wiedzy niezbędnych do tego, aby odnieść sukces w dziedzinie sztucznej inteligencji.

Dla osoby uczącej się ważne jest, aby wybrać kursy szkoleniowe, które są zgodne z jej konkretnymi potrzebami i celami, biorąc pod uwagę najnowsze innowacje w tej dziedzinie. I odwrotnie, przy opracowywaniu programu kursu konieczne jest również zdefiniowanie jasnych i konkretnych celów kursu oraz śledzenie najnowszych osiągnięć w tej dziedzinie.

### **MATERIAŁ I METODY**

Zaproponowaliśmy podejście do opracowania kursu szkoleniowego AAI z wykorzystaniem wyników różnych ankiet, standardów kompetencji i tematów, przetwarzania danych i podejmowania decyzji w oparciu o optymalizację wielokryterialną (patrz rys. 2 dla uogólnionego widoku). Obejmuje następujące kroki.

Zaczynając od określenia ogólnych celów szkolenia. Identyfikujemy pożądane wyniki, kompetencje i obszary wiedzy, które należy uwzględnić.

Przeprowadzamy ankiety i oceny w celu zebrania danych na temat potrzeb i preferencji grupy docelowej. Może to obejmować ankiety dotyczące istniejącej wiedzy, luk w umiejętnościach, preferencji edukacyjnych i pożądanych tematów.

Określamy standardy lub punkty odniesienia dla kompetencji, które uczestnicy powinni osiągnąć po ukończeniu szkolenia. Standardy te pochodzą z [30] i pomogą zdefiniować wymaganą wiedzę, umiejętności i zdolności w AAI.

Na podstawie danych z ankiety i standardów kompetencyjnych określamy konkretne tematy, które należy poruszyć w szkoleniu AAI. Bierzymy pod uwagę trafność, wagę i priorytet każdego tematu.

Multisource Data Analytics Toolbox obejmuje przetwarzanie i analizowanie danych z ankiet i badań w celu wyodrębnienia istotnych spostrzeżeń. Może to obejmować analizę statystyczną, wizualizację danych i techniki podsumowania (takie jak chmury słów, wykresy CiteSpace, AHP) w celu zidentyfikowania wzorców, trendów i korelacji między odpowiedziami na ankietę a danymi z wielu źródeł.

Na podstawie zidentyfikowanych tematów, kompetencji i wyników ankiety określamy poszczególne moduły edukacyjne, które odnoszą się do konkretnych aspektów szkolenia. Każdy moduł powinien mieć jasne cele nauczania i treść, która jest zgodna z pożądanymi wynikami.

Tworzymy macierze krzyżowe, które obrazują relacje między tematami, kompetencjami i modułami edukacyjnymi. Macierz ta pomaga zwizualizować, w jaki sposób każdy moduł przyczynia się do rozwoju określonych kompetencji oraz w jaki sposób różne tematy są ze sobą powiązane z modułami i między sobą.

Łączymy poszczególne moduły edukacyjne i macierze krzyżowe, tworząc reprezentację tensorową 3D. Tensor ten ujmuje współzależności między tematami, kompetencjami i modułami edukacyjnymi w ustrukturyzowanym i zorganizowanym zespole.



**Co-funded by  
the European Union**

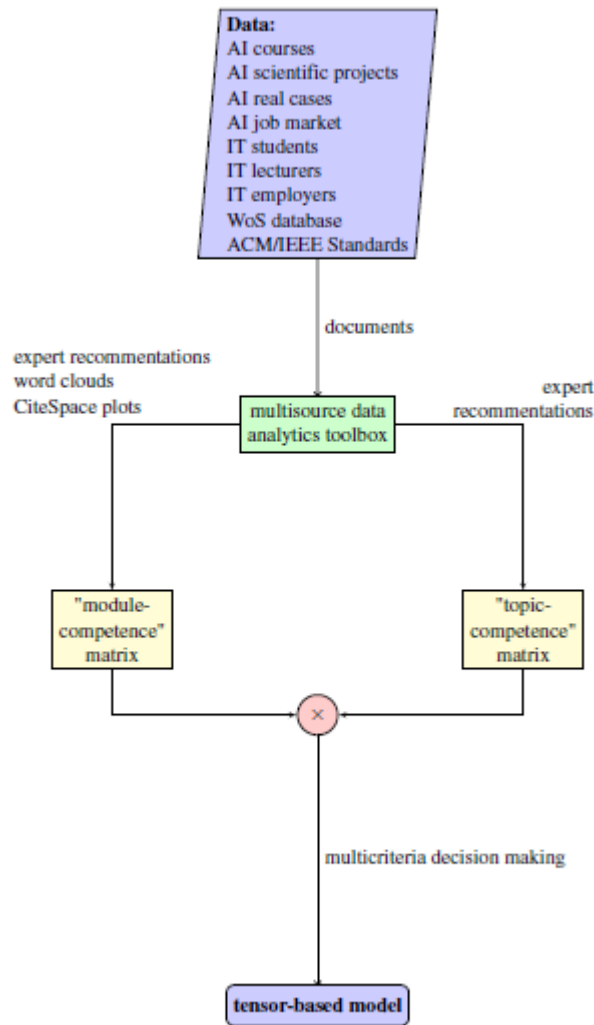
Stosujemy wielokryterialne techniki optymalizacji (AHP), aby podejmować świadome decyzje na podstawie zebranych danych. Uwzględnienie wielu czynników, takich jak znaczenie każdego tematu i preferencje grupy docelowej, zoptymalizuje projekt i realizację kursu szkoleniowego AAI.

Uwzględniamy wszelkie specyficzne wymagania, które wynikają z procesu decyzyjnego. Może to obejmować modyfikacje treści, metod dostarczania, strategii oceny lub kolejności modułów na podstawie wyników optymalizacji.

#### *MATERIAŁY*

Praca opiera się na serii danych zebranych w wyniku badania dobrych praktyk w zakresie AAI w ramach projektu FAAI. Mianowicie, przeanalizowaliśmy

- 74 oferty zebrane z rynku pracy;
- 63 projekty naukowe z zakresu AI;
- 92 istniejące kursy szkoleniowe w zakresie sztucznej inteligencji;
- 27 rozwiązań w zakresie dobrych praktyk;
- 279 rzeczywistych przypadków dotyczących rozwiązań opartych na sztucznej inteligencji;
- wypełnione ankiety (80 nauczycieli akademickich, 1054 studentów informatyki, 38 pracodawców)



**FIGURE 2.** Flowchart for determining AAI course requirements

#### B. CHMURY SŁÓW

Chmury słów, zwane również diagramami wordle lub chmurami tagów, to urzekające wizualizacje danych, które przedstawiają najważniejsze słowa lub frazy w formacie graficznym. Ta innowacyjna technika wizualnie podkreśla względną częstotliwość słów w danym tekście [31], co skutkuje estetycznym i łatwo zrozumiałym przedstawieniem.

Koncepcja chmur słów pojawiła się na początku lat dziewięćdziesiątych XX wieku, wraz z pierwszymi przykładami wizualizacji częstotliwości słów. Dostępność komputerowych narzędzi do analizy tekstu i aplikacji internetowych dodatkowo spopularyzowała ich wykorzystanie. Obecnie wiele platform internetowych i oprogramowania bez wysiłku umożliwia użytkownikom generowanie chmur słów z danych tekstowych. Tworzenie chmur słów przebiega zgodnie z prostą procedurą



Co-funded by  
the European Union

[32]. Początkowo tekst jest badany w celu wyodrębnienia unikalnych słów lub fraz i określana jest częstotliwość ich występowania. Rozmiar lub wyeksponowanie słowa w chmurze słów jest proporcjonalne do jego częstotliwości w tekście. Słowa o większym znaczeniu są zwykle wyświetlane większymi czcionkami lub umieszczone bliżej środka, podczas gdy mniej istotne słowa są mniejsze lub umieszczone na obrzeżach. Chmury słów znajdują szerokie zastosowanie w różnych dziedzinach [32], [33]. W sferze biznesowej ułatwiają analizę sentymentu, identyfikację trendów i eksplorację słów kluczowych w opiniach klientów lub opisach produktów. W dziedzinie edukacji służą jako narzędzia do wizualizacji kluczowych pojęć lub tematów, pomagając w zrozumieniu i zapamiętywaniu wiedzy. Ponadto są one wykorzystywane w badaniach społecznych, analizie treści i eksploracji opinii, oferując cenny wgląd w ogromne zbiory danych tekstowych.

#### *C. ANALIZA SKUPIEŃ SŁÓW KLUCZOWYCH*

Aby przeprowadzić analizę skupień referencji z Web of Scientific (WoS) za pomocą oprogramowania CiteSpace [2], eksportujemy 10 tys. danych referencyjnych z WoS w formacie zwykłego tekstu. CiteSpace przetworzy dane i utworzy sieć cytowań. Po utworzeniu sieci CiteSpace oferuje różne opcje wizualizacji i analizy. Zbadaliśmy różne ustawienia i parametry, aby wygenerować znaczące klastry dotyczące słów kluczowych. Odpowiednie oznakowanie pozwala nam wskazać wiodących autorów i instytucje. Można również określić prace związane z pękaniem.

#### *D. AHP*


Metoda AHP służy do rozwiązywania problemów związanych z podejmowaniem decyzji, które obejmują wiele kryteriów i alternatyw. Jest to szczególnie skuteczne w obliczu złożonych decyzji, w których należy wziąć pod uwagę subiektywne osądy i kompromisy między kryteriami o strukturze hierarchicznej [34]. W prezentowanej pracy metoda AHP zostanie zastosowana w kontekście projektowania kursu edukacyjnego AAI w celu ustalenia priorytetów i podjęcia decyzji dotyczących różnych aspektów

kursu, a mianowicie cele nauczania, treść kursu, metody oceny, strategie nauczania, alokacja zasobów, integracja technologii, ocena i informacja zwrotna. Przeprowadzając porównania parami, możemy ocenić względne znaczenie lub preferencje każdego kryterium i alternatywy. Na przykład możemy porównać trafność treści

w stosunku do wymagań rynku pracy. Zwróć uwagę, że można wziąć pod uwagę kilku decydentów, np. naukowców,

studenci, pracodawcy itp. Obliczanie priorytetu lub wagi każdego kryterium i alternatywy na podstawie wartości porównawczych parami wymaga zastosowania obliczeń matematycznych, takich jak normalizacja wartości porównawczych oraz

obliczanie wartości własnej i wektora własnego. Rezultatem jest zestaw wartości priorytetowych, które wskazują względne znaczenie każdego kryterium i alternatywy. Korzystając z obliczonych priorytetów, podejmujemy świadome decyzje dotyczące projektu szkolenia. Priorytety pomagają nam określić najbardziej krytyczne kryteria i najodpowiedniejsze alternatywy w oparciu o ich względne znaczenie. Dzięki temu możemy skupić się na aspektach, które mają większy wpływ na osiągnięcie pożądaných kompetencji.



**RYSUNEK 3.** Tensor odwzorowujący relację "kompetencja-temat-moduł"

Stosując metodę AHP do tych aspektów projektowania kursów, nauczyciele i twórcy programów nauczania mogą podejmować świadome decyzje, które promują efektywne nauczanie i uczenie się, są zgodne z celami edukacyjnymi i zaspokajają potrzeby uczniów.

#### *E. TENSOR APPROACH FOR RELATIONS*

Metoda ta przedstawia trójwymiarowy tensor (rys. 3) złożony z tematu i kompetencji za pomocą przedstawienia opartego na tensorze, który jest sposobem na przedstawienie każdego modułu. Aby skonstruować tensor 3D z elementami binarnymi  $\tau_i$  przy użyciu wektorów  $C \in R_m$ ,  $T \in R_l$ , i  $M \in R_n$  jako kierunki (rys.3), wraz z dwiema macierzami  $A_{MC}$ ,  $A_{CT}$  pokazujący relacje logiczne między wektorami  $M i C$ ,  $i C i T$ , możemy użyć następujących wyrażeń:





Co-funded by  
the European Union

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

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

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

gdzie  $\cdot$  jest operatorem logicznym AND. Tensor  $\mathbf{T}$  może być również skonstruowany za pomocą Kroneckera - iloczyn ( $\otimes$ ) dwóch macierzy.

#### IV. WYNIKI

##### A. BADANIA RYNKU PRACY

AAI to bardzo ważna dziedzina, jeśli chodzi o rynek pracy. Widzimy, że możliwości jest bardzo dużo, że w tym obszarze można wykorzystać sztuczną inteligencję. Sztuczna inteligencja jest ważną technologią, która pomaga firmom poprawić wydajność, obniżyć koszty i podejmuj lepsze decyzje. Widzimy, że ulepszenia w zakresie sztucznej inteligencji wiążą się również z tworzeniem nowych możliwości i tworzeniem

**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%

nowych miejsc pracy w przemyśle. Są one szczególnie ważne w dziedzinie nauki o danych, uczenia maszynowego i robotyki.

##### 1) Stanowiska oferowane na rynku pracy

W odniesieniu do stanowisk na rynku pracy w zakresie AAI, oferowane są różne pozycje dominujące. Stanowiska te są rozmieszczone w całej UE, co oznacza, że

AAI jest szeroko rozpowszechnione na całym świecie. Z badań rynku pracy przedstawionych w tabeli 2 wynika, że najbardziej dominującymi stanowiskami oferowanymi na rynku są stanowiska Data Engineer i Data Scientist, odpowiednio 25,68% i 22,97%. Podczas gdy inżynierowie danych specjalizują się w projektowaniu, budowaniu i utrzymywaniu infrastruktury systemów wymaganych do obsługi przetwarzania danych, naukowcy zajmujący się danymi są odpowiedzialni za wydobywanie spostrzeżeń i wiedzy z danych. Analitycy danych i inżynierowie sztucznej inteligencji mają ten sam odsetek wynoszący 10,81%. Pokazuje to, że znaczna część stanowisk wymaga skupienia się na interpretacji i analizie danych,

z silnymi umiejętnościami wizualizacji. Wraz z silną zdolnością do opracowywania i wdrażania systemów i algorytmów sztucznej inteligencji.

Wśród innych pozycji nie ma konkretnej pozycji, która występuje bardziej dominująco niż inne. Różni się od inżynierów dev ops po inżynierów oprogramowania lub stanowiska programisty internetowego.

## 2) Problem z uczeniem maszynowym

Jedną z najważniejszych informacji istotnych dla rynku pracy jest swego rodzaju problem uczenia maszynowego, który wymaga rozwiązania. Może to wskazywać, które kompetencje mogą być najważniejsze w pracy w AAI. Ten wyniki przedstawiono w tabeli 3. Na podstawie wyników widać, że największa część problemów związanych z uczeniem maszynowym koncentruje się na problemach z klasycznym ML i Deep ML. Oznacza to, że tradycyjne techniki uczenia maszynowego, które obejmują algorytmy, takie jak drzewa decyzyjne, maszyny wektorów nośnych i lasy losowe, są potrzebne, aby być kompetentnym w zakresie stosowanej sztucznej inteligencji.

Drugi najważniejszy zestaw rozwiązywanych problemów uczenia maszynowego reprezentuje problemy głębokiego uczenia maszynowego. Deep ML zyskał znaczną popularność w ciągu ostatnich kilku lat i

**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%

stać się jednym z najczęściej używanych ML w obszarach takich jak widzenie komputerowe czy przetwarzanie języka naturalnego.

Wyniki pokazują również, że konieczne jest pozyskanie wiedzy z dziedziny naukowej i włączenie jej do uczenia maszynowego. W związku z tym można stwierdzić, że stosowana sztuczna inteligencja ma istotne zastosowanie w modelach, które są zorientowane na modele oparte na fizyce, symulacje lub równania różniczkowe [35].

## 3) Opracowywane modele



Co-funded by  
the European Union

Jednym z najważniejszych zadań inżyniera uczenia maszynowego jest opracowanie modelu, który zostanie wykorzystany w algorytmie dla rzeczywistego problemu. Opracowywane są różne możliwe modele, a ich rozkład przedstawiono w tabeli 4.

Tabela 4 przedstawia rozkład różnych modeli opracowywanych na rynku pracy. MLP, jako wielowarstwowe sieci neuronowe, są szeroko stosowane w zadaniach takich jak klasyfikacja, regresja i rozpoznawanie wzorców, ze względu na ich zdolność do przechwytywania złożonych wzorców z danych [36].

Wyniki pokazują, że jednym z najważniejszych wyzwań podczas pracy w stosowanej sztucznej inteligencji jest tworzenie reguł logicznych w oparciu o warunki predefiniowane na podstawie rzeczywistego problemu. Techniki te mogą być wykorzystywane do przewidywania i odkrywania korelacji między danymi z różnym powodzeniem.

Wykazano, że sieci neuronowe stanowią największą część modeli opracowywanych na rynku pracy. Zarówno konwolucyjne, jak i rekurencyjne sieci neuronowe mogą być wykorzystywane w wielu dziedzinach, takich jak przetwarzanie obrazu lub danych wizualnych.

Ogólnie rzecz biorąc, dane wskazują na dominację MLP i podejść opartych na regułach w kontekście opracowywanych modeli. Znaczna część posiada drzewa decyzyjne oraz konwolucyjne i rekurencyjne sieci neuronowe. Warto zwrócić uwagę na obecność specyficznych architektur, takich jak sieci koder-dekoder, U-NET, GRU i LSTM, z mniejszymi wartościami procentowymi, co wskazuje na ich znaczenie w niektórych specjalistycznych aplikacjach w dziedzinie uczenia maszynowego.

#### 4) Zadania uczenia maszynowego do rozwiązania

Na rynku pracy stosowanej sztucznej inteligencji istnieją różne maszyny zadania edukacyjne, które firmy starają się rozwiązywać za pomocą technik sztucznej inteligencji. Zadania te obejmują różne dziedziny i branże i wymagają kilku umiejętności w zakresie uczenia maszynowego, aby skutecznie je rozwiązać.

**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%

Tabela 5 przedstawia rozkład zadań uczenia maszynowego, które należy

rozwiązać. Ogólnie rzecz biorąc, dane podkreślają rozpowszechnienie zadań klasyfikacji i regresji, które są podstawowymi zadaniami w uczeniu maszynowym, a ich zastosowanie jest szerokie. Wskazuje również na znaczenie posiadania umiejętności przetwarzania obrazu i języka naturalnego, a także rozpoznawania mowy. Klasteryzacja, segmentacja obrazów i napisy pokazują konkretne wyzwania i zastosowania na rynku pracy. Co więcej, podział zadań ujawnia znaczenie przetwarzania obrazu, przetwarzania języka naturalnego i rozpoznawania mowy jako ważnych technik, które należy znać i na kursach AI.

Zrozumienie rozkładu zadań uczenia maszynowego jest cenne dla firm, które chcą zastosować techniki sztucznej inteligencji do rozwiązywania problemów w różnych dziedzinach. Dzięki tym spostrzeżeniom firmy, które stosują techniki sztucznej inteligencji w różnych dziedzinach, pozwalają im ustalać priorytety i koncentrować swoje wysiłki w oparciu o znaczenie różnych zadań.

#### *BADANIA PRACODAWCÓW*

W ankiecie zebrano odpowiedzi od 38 firm, aby zbadać ich potrzeby i oczekiwania dotyczące szkolenia specjalistów w zakresie stosowanej sztucznej inteligencji. Większość respondentów (86,84%) reprezentuje organizacje prywatne, a tylko 13,16% wskazuje na przynależność do organizacji publicznych. Jeśli chodzi o wielkość organizacji, ponad połowa respondentów (52,63%) klasyfikuje swoje firmy jako małe, około 26,32% respondentów klasyfikuje swoje firmy jako średnie, a 21,05% respondentów klasyfikuje swoje firmy jako duże, wskazując, że zatrudniają ponad 250 pracowników. Największy odsetek respondentów (36,84%) pracuje w segmencie usług IT. Inne istotne segmenty to start-upy z innymi produktami (15,79%) i różne kategorie (15,79%). Reprezentowany jest również outsourcing IT, sprzedaż technik obliczeniowych, rozwój oprogramowania hybrydowego, outsourcing IT, programowanie offshore i technologie gier. Niektóre firmy to start-upy produktowe działające w takich dziedzinach, jak działalność administracyjna i MES, rozwój oprogramowania i outsourcing IT, badania i technologia (obszar IT), usługi IT, finansowanie IT oraz badania i edukacja.

Główne obszary działalności deklarowane przez organizacje są różne, przy czym głównymi domenami są produkcja i rozwój (47,37%), projektowanie (39,47%), doradztwo (44,74%), obsługa klienta (42,11%) i badania (39,47%). Aplikacje i rozwiązania tych firm obejmują różne sektory, w tym edukację, usługi publiczne, sprzedaż, marketing, finanse, bezpieczeństwo, opiekę zdrowotną, transport i inne. Jeśli chodzi o wykorzystanie sztucznej inteligencji w działalności biznesowej, większość organizacji (86,64%) wskazuje, że obecnie wykorzystuje sztuczną inteligencję, podczas gdy niewielka część (13,16%) twierdzi, że ma zamiar robić to w przyszłości.

Jeśli chodzi o stanowiska związane ze sztuczną inteligencją, najwyższy odsetek ofert pracy ma Data Engineer (58,33%), a następnie Data Analyst (55,56%) i Data Scientist (44,44%). Inne stanowiska, takie jak rekruter techniczny, inżynier bezpieczeństwa i menedżer baz danych, mają niższy odsetek ofert pracy. Jeśli chodzi o wymagania dotyczące doświadczenia, 41,67% stanowisk pracy nie wymaga żadnego doświadczenia w dziedzinie sztucznej inteligencji. Większość



**Co-funded by  
the European Union**

stanowisk wymaga doświadczenia od krótkiej praktyki do jednego roku (25%) do od 1 do 3 lat (27,78%). Tylko niewielki odsetek stanowisk pracy wymaga doświadczenia powyżej 5 lat (5,56%). W badaniu zbadano również ogólne kompetencje potrzebne na stanowiskach związanych ze sztuczną inteligencją. Najwyższy odsetek (60%) przypisuje się kompetencjom rozpoznawania problemów związanych z błędami algorytmicznymi i stroniczością danych, prywatnością i integralnością danych. Inne wysoko oceniane kompetencje obejmują opisywanie głównych obszarów sztucznej inteligencji i jej zastosowań, rozpoznawanie użyteczności metod uczenia maszynowego oraz identyfikowanie odpowiednich wskaźników wydajności do oceny algorytmów uczenia maszynowego. Kompetencje takie jak przedstawianie informacji w formalizmach logicznych i probabilistycznych oraz debatowanie nad skutkami decyzji wynikających z wniosków z uczenia maszynowego mają niższe wartości procentowe. Jeśli chodzi o predyspozycje wymagane od pracowników zajmujących się sztuczną inteligencją i nauką o danych, respondenci podkreślają znaczenie poszanowania historii i ograniczeń sztucznej inteligencji, zdolności adaptacyjnych w projektowaniu algorytmów, etycznego i odpowiedzialnego wykorzystywania uczenia maszynowego oraz dokładności i etyki w prezentowaniu wyników. Inne ważne dyspozycje obejmują wybór i ocenę algorytmów, dokładne i etyczne podejście do oceny, dbałość o szczegóły w technikach uczenia się nienadzorowanego oraz uwzględnianie wyzwań specyficznych dla kontekstu. W ramach badania zbadano rodzaje problemów związanych z uczeniem maszynowym rozwiązywanych przez firmy. Większość firm (68,57%) korzysta z technik klasycznego i głębokiego uczenia maszynowego, podczas gdy mniejszy odsetek korzysta z metod SciML (8,57%). Jeśli chodzi o opracowane lub zbadane modele, najczęściej wymienia się drzewa decyzyjne i wielowarstwowe perceptrony (MLP), a następnie reguły, konwolucyjne sieci neuronowe (CNN) i rekurencyjne sieci neuronowe (RNN). Wykorzystanie sieci neuronowych, zarówno tradycyjnych, jak i głębokiego uczenia, jest powszechne w firmach. Najczęstsze zadania związane ze sztuczną inteligencją i uczeniem maszynowym rozwiązywane lub badane przez firmy obejmują klasyfikację, regresję, klasyfikację obrazów, klastryzację i przetwarzanie języka naturalnego. Zadania takie jak podpisy obrazów, rozpoznawanie mowy i selekcja obrazów mają niższy odsetek odpowiedzi. Python jest najczęściej wymaganym językiem programowania (85,71%), a następnie C++ (45,71%), Java (42,86%), R (37,14%) i C# (22,86%). Inne języki, takie jak JavaScript i Matlab, są wymagane rzadziej. Jeśli chodzi o biblioteki (frameworki) AI, najczęściej używany jest TensorFlow (78,79%), a następnie Keras (48,48%) i scikit-learn (42,42%). Używane są również inne elementy ramowe, takie jak PyTorch, Apache TVM, AMD HIP, OpenAI i Matlab, ale w mniejszym stopniu. Najczęściej używanym ekosystemem jest Anaconda (54,55%), a następnie Apache Hadoop (39,39%), Matlab (39,39%) i R Studio (33,33%). W przypadku pracowników akademickich/analytycznych wysoko oceniane są kompetencje takie jak

przeprowadzanie studiów wykonalności, wprowadzanie innowacji i modyfikowanie metod oraz stosowanie nowoczesnych metod psychopsychologii i pedagogiki. Relatywnie niżej oceniane są kompetencje związane z symulacjami, weryfikacją statystyczną i ochroną praw autorskich. Wymagane umiejętności miękkie obejmują krytyczne myślenie, komunikację, pracę z narzędziami i technologią, planowanie i organizowanie oraz podstawy biznesu. Współpraca, koncentracja na kliencie, dynamiczne przekwalifikowanie i profesjonalne nawiązywanie kontaktów są również cenione, ale w mniejszym stopniu. Zgodnie z wynikami ankiety, firmy cenią sobie dodatkowe kompetencje, w tym umiejętność doboru odpowiednich struktur danych i algorytmów, a także wizualizację wyników analizy AI. Dodatkowo firmy priorytetowo traktują kompetencje związane z wdrażaniem rozwiązań opartych na chmurze obliczeniowej. Z drugiej strony kompetencje takie jak analiza zagrożeń dla aplikacji czasu rzeczywistego, tworzenie i obsługa wielkoskalowych magazynów danych oraz korzystanie z szerokiej gamy platform analitycznych Big Data są uważane za mniej istotne. Firmy wymagają również od pracowników umiejętności realizacji zadań zarówno na poziomie jednostki, jak i na poziomie ogólnym/universalnym problemu, wykazując się wszechstronnością i umiejętnością rozwiązywania problemów.

Wyniki ankiety dostarczają cennych informacji na temat opinii i poziomu zadowolenia pracodawców z tytułu specjalistów kończących szkolenie w zakresie sztucznej inteligencji i IT. Pracodawcy wyrażają zaniepokojenie niedoborem specjalistów AI na rynku pracy oraz brakiem praktycznego doświadczenia wśród absolwentów. Praktyczne zastosowanie uczenia maszynowego jest postrzegane jako obszar, który wymaga poprawy. Ponadto niektórzy pracodawcy wspominają o wysokich oczekiwaniach płacowych wobec specjalistów ds. sztucznej inteligencji, co utrudnia znalezienie odpowiednich kandydatów lokalnie. Jeśli chodzi o specjalistów IT, opinie są mieszane. Podczas gdy niektórzy pracodawcy doceniają ich dobre wykształcenie i biegłość techniczną, inni uważają, że brakuje im umiejętności praktycznych. Współpraca i kreatywność są uznawane za podstawowe umiejętności specjalistów IT i wydaje się, że dostępna jest odpowiednia pula młodych talentów. Sytuacja staje się jednak trudniejsza w przypadku poszukiwania specjalistów średniego lub wyższego szczebla. Zapotrzebowanie na specjalistów od sztucznej inteligencji jest tematem debaty wśród pracowników, przy czym niektórzy twierdzą, że nie ma takiej potrzeby, podczas gdy inni obserwują znaczną lukę na rynku pracy. Zadowolenie osób zatrudnionych z poziomu przygotowania absolwentów studiów magisterskich w obszarze sztucznej inteligencji jest ogólnie umiarkowane, przy czym większość z nich wyraża umiarkowane zadowolenie. Wskazuje to, że potrzebne są usprawnienia, aby lepiej dostosować umiejętności absolwentów do oczekiwań pracodawców. O ile podaż specjalistów AI na rynku pracy zadowala większość firm, o tyle znaczna część nie jest zadowolona, co sugeruje zapotrzebowanie na bardziej wykwalifikowanych specjalistów. Przedsiębiorstwa na ogół pozytywnie podchodzą do podnoszenia kwalifikacji swoich obecnych pracowników poprzez studia magisterskie w zakresie sztucznej inteligencji, co wskazuje na gotowość do inwestowania w edukację i szkolenia. Jeśli chodzi o kompetencje



Co-funded by  
the European Union

absolwentów uczelni wyższych w zakresie sztucznej inteligencji, firmy mają neutralne lub pozytywne postrzeganie. Uważa się, że absolwenci mają wysoką wiedzę teoretyczną, ale opinie na temat praktycznego zastosowania tej wiedzy są różne. Podstawowa wiedza z zakresu zarządzania przedsiębiorstwem, ekonomii i prawa jest postrzegana jako dobra, podobnie jak zrozumienie najnowszych międzynarodowych standardów. Cechy osobiste, takie jak innowacyjność, etyka pracy, ambicja osobista i samoocena, spotykają się z mieszanymi reakcjami. Wyniki ankiety podkreślają potrzebę poprawy praktycznych umiejętności i doświadczenia absolwentów AI, dostosowania programów edukacyjnych do wymagań branżowych oraz wypełnienia luki między wiedzą teoretyczną a jej praktycznym zastosowaniem. Pracodawcy chętnie zatrudniają wykwalifikowanych specjalistów AI i chętnie inwestują w edukację i szkolenia swoich obecnych pracowników. Wyniki podkreślają również znaczenie współpracy między instytucjami edukacyjnymi a interesariuszami z branży w celu zapewnienia przygotowania absolwentów do dynamicznego rynku pracy AI.

Wyniki badania dają wgląd w opinie pracodawców na temat działań projektowych związanych z badaniami nad sztuczną inteligencją oraz ich gotowości do udziału. Budowa strony internetowej prezentującej wyniki badań nad sztuczną inteligencją przez lokalny uniwersytet jest uważana przez większość firm za umiarkowanie ważne, przy czym 20% z nich jest neutralne, a mniejszy odsetek uważa je za bardzo ważne. Żadna z firm nie ocenia tego pomysłu jako nieistotnego. Wskazuje to na ogólne zainteresowanie prezentowaniem wyników badań nad sztuczną inteligencją za pośrednictwem specjalnej strony internetowej. Jeśli chodzi o komunikację i zaangażowanie, znaczna liczba firm, 63,89%, wyraża chęć otrzymywania newslettera o postępach w projekcie.

Jednak znaczna mniejszość, 36,11%, nie wykazuje zainteresowania takimi biuletynami. W przypadku aktywnego udziału w rozwoju projektu poprzez szkolenia i przypadki użycia, 44,74% firm odpowiedziało pozytywnie, podczas gdy 55,26% odmówiło. Sugeruje to, że znaczna część pracodawców jest otwarta na zaangażowanie się w działania projektowe. Jeśli chodzi o prezentację rezultatów projektu, większość przedsiębiorstw (60,53%) wyraziła zainteresowanie zaproszeniem do udziału w wydarzeniu upowszechniającym. Świadczy to o tym, że firmy chętnie informują się o wynikach projektu i są na bieżąco z najnowszymi osiągnięciami w dziedzinie sztucznej inteligencji i nauki o danych. O ile istnieje ogólne zainteresowanie stroną internetową prezentującą wyniki badań nad sztuczną inteligencją i otrzymywanie aktualnych informacji o postępach, o tyle chęć aktywnego udziału w rozwoju projektu i udziału w wielu wydarzeniach jest bardziej zróżnicowana. Zrozumienie i uwzględnienie preferencji i potrzeb pracodawców ma kluczowe znaczenie dla pomyślnego wdrożenia i rozpowszechnienia projektu FAAI.



*BADANIE STUDENTÓW*

Ankiety dla studentów, magistrów i absolwentów informatyki na kierunku Systemy i technologie informatyczne wypełniły łącznie 1052 osoby, wykazując duże zainteresowanie tematami AAI w populacji studentów. Pierwsza grupa trzech pytań w ankiecie (pytania 1-3) miała charakter ogólny, a jej celem było uzyskanie podstawowych informacji o badanej narodowości, wieku i statusie studenta. Zgodnie z oczekiwaniami studenci pochodzili głównie z krajów uczestniczących w projekcie: Polska 13,88%, Serbia 15,11%, Bułgaria 34,98%, Czarnogóra 19,68%, a Słowacja 10,55%. Jest też 61 osób (5,8%) innych narodowości. Respondenci to w zdecydowanej większości osoby poniżej 24 roku życia – 72,34% oraz nadal studenci 89,45% (64,83% studiów I stopnia i 24,62% II stopnia studiów). Tylko 11,55% to absolwenci.

Poniższy zestaw dziesięciu pytań (pytania 4-13) był przeznaczony wyłącznie dla studentów. Najpierw poproszono ich o określenie, na jakim kierunku się uczą. Większość respondentów pochodzi ze studiów licencjackich 72,81% lub magisterskich 22,15% (71,96% w pierwszych dwóch latach studiów) ze specjalizacją w niektórych odmianach z zakresu informatyki (informatyka 28,69%, informatyka 25,82%). Na pytanie, czy znają jakieś kierunki studiów z zakresu Sztucznej Inteligencji Stosowanej oferowane na ich uczelni, studenci w zdecydowanej większości wybrali odpowiedzi "nie" (54,03%) i "Tak, znam tylko niewielu" (39,25%), a tylko 6,72% odpowiedziało "Tak, znam ich wiele". Najczęściej preferowane przez studentów zajęcia mające na celu poszerzenie wiedzy w AAI to projekty (59,22%), wykłady (44,49%) lub laboratoria (38,21%). Stworzenie strony internetowej prezentującej wyniki badań AAI przeprowadzonych przez pracowników lokalnej uczelni jest ważne lub bardzo ważne dla prawie 82% respondentów. Innym istotnym pytaniem było to, czy studenci byli zaznajomieni z zagadnieniami AAI, gdzie tylko 9,7% odpowiedziało Nie, nie słyszałem o tym i nie jestem zainteresowany takim dostępem. Pod koniec tej części pytań zapytano studentów, czy chcieliby wziąć udział w kursach AAI, a zdecydowana większość (90,02%) odpowiedziała neutralnie lub pozytywnie (Neutralnie – 35,36%, Raczej zgadzam się – 29,47%, Zgadzam się – 25,19%).

Trzecia grupa pytań o nazwie Uczestnictwo w szkoleniu z zakresu Stosowanej Sztucznej Inteligencji składa się tylko z dwóch pytań (14 i 15) związanych z kontekstem AAI oraz dotychczasowymi kursami z obszaru AAI. Tylko 212 respondentów (20,15%) uczestniczyło już w zajęciach opartych na AAI. Większość studentów wykazała zainteresowanie gromadzeniem danych z różnych źródeł (internet, sieci społecznościowe itp.) (44,3%) lub przeprowadzanie analiz AAI/uczenia maszynowego (47,34%).

Kolejna seria pytań dotyczyła doświadczenia zawodowego (pytania 16-19). Prawie połowa badanych pracuje obecnie 519/1052 (49,33%), co oznacza, że duża część z nich zarówno studiuje, jak i pracuje. Pozostałe pytania w tej części mają na celu zebranie informacji na temat czasu trwania i charakteru zatrudnienia respondentów. Spośród 519 pracowników 347 z nich pracuje w sektorze prywatnym, 157 w sektorze publicznym, a 11 w organizacjach non-profit. Zgodnie z oczekiwaniami (respondenci w większości mają mniej niż 24



Co-funded by  
the European Union

lata), ankietowani w większości mają mniej niż 3 lata doświadczenia (356 na 519 zatrudnionych) i pracują w branży IT (311 na 519).

Pracownicy branży IT odpowiedzieli na pytania grupy (20-23). Pytania zostały sformułowane w taki sposób, aby lepiej opisywać stanowisko pracy, wymagania i doświadczenie pracowników IT. Ankieta wykazała, że większość pracowników IT pracuje jako programiści (17,4%), w dziale wsparcia (4,75%), jako administratorzy (3,61%) oraz w budowie i obsłudze sieci (3,33%). Ponad połowa pracowników IT stwierdziła, że do powołania na swoje stanowisko potrzebny jest dyplom licencjata. Spośród 1052 respondentów tylko 136 miało doświadczenie w pracy w dziedzinie sztucznej inteligencji stosowanej i wykorzystuje je w swojej pracy.

Być może najważniejszy zestaw pytań dla realizacji projektu FAAI dotyczył ważnych kompetencji niezbędnych do zastosowania sztucznej inteligencji (pytania 24-29). Respondenci mieli możliwość wyboru z listy ponad 30 opcji, które umiejętności miękkie uważają za najważniejsze dla zatrudnienia w organizacji, w której pracują. Niewiele umiejętności wyróżnia się w tym sensie, że zdecydowana większość pracowników uważa je za ważniejsze od innych: Umiejętność pracy w zespole (66,73%), Umiejętność planowania i zarządzania czasem (62,55%), Umiejętność porozumiewania się w drugim języku (obcym) (60,27%). Popularnością cieszyły się również: umiejętność identyfikowania, proponowania i rozwiązywania problemów (55,8%), zdolność uczenia się i bycia na bieżąco z nauką (51,14%), umiejętność zastosowania wiedzy w sytuacjach praktycznych (50,38%), zdolność do generowania nowych pomysłów (kreatywność) (48,95%). Rzadziej wybierano pozostałe kompetencje, a za najmniej ważne uznano następujące kompetencje: zaangażowanie w ochronę środowiska (11,88%), umiejętność wykazywania świadomości równości szans i problematyki płci (12,36%), zdolność do podejmowania inicjatywy oraz rozwijania ducha przedsiębiorczości i ciekawości intelektualnej (13,5%).

Na pytanie, jakie kompetencje powinien posiadać specjalista w zakresie AAI, respondenci najczęściej wybierali odpowiedzi: Stosowanie odpowiednich metodologii szkoleniowych i testowych przy wdrażaniu algorytmów uczenia maszynowego, Rozpoznawanie zakresu i użyteczności metod uczenia maszynowego, Dobór odpowiednich metod uczenia maszynowego (klas) dla konkretnych problemów, Porównywanie i kontrastowanie metod uczenia maszynowego. Najbardziej cenioną kompetencją pokrewną, którą powinien posiadać specjalista w zakresie AAI i której powinien uczyć się podczas szkoleń AAI, jest efektywne wykorzystanie różnorodnych technik analizy danych (Machine Learning, Data Mining, Prescriptive i Predictive Analytics). Najpopularniejszymi narzędziami AAI, które mogą być wykorzystywane do wspomaganie wykładów teoretycznych, są: platformy Applied Artificial Intelligence Analytics (Hadoop, Spark, Data Lakes), Applied Artificial Intelligence i rozproszone narzędzia obliczeniowe (Spark, MapReduce, Hadoop, Mahout, Lucene, NLTK, Pregel) oraz

Google Colab. Najmniej popularne są: ekosystem Anaconda, R Studio i Mathcad.

#### *STUDIA AKADEMICKIE*

Ocena stosowanej edukacji w zakresie sztucznej inteligencji: badanie perspektyw naukowców W tym badaniu przeprowadzono szeroko zakrojoną ankietę w celu oceny obecnego stanu edukacji w zakresie stosowanej sztucznej inteligencji (AI) wśród akademików. W ankiecie, przeprowadzonej w ramach programu FFAI Erasmus+, zebrano i przeanalizowano kwestionariusze od 80 wykładowców z pięciu krajów. Wyniki dostarczają cennych informacji na temat praktyk nauczania, kompetencji i obszarów wymagających poprawy w edukacji stosowanej w zakresie sztucznej inteligencji.

Wyniki pokazały, że znaczna liczba respondentów była początkująca w dziedzinie stosowanej sztucznej inteligencji, podczas gdy większość respondentów twierdziła, że posiada umiejętności na poziomie średniozaawansowanym. Biegłość na poziomie zaawansowanym zgłosiło 23,75% uczestników, a tylko 7,50% uważało się za ekspertów. W związku z tym badanie przedstawia kompleksowy przegląd, a nie wąską perspektywę ekspercką.

Jednym z godnych uwagi ustaleń było to, że ponad połowa nauczycieli była samoukami w zakresie sztucznej inteligencji, a następnie ci, którzy otrzymali lekcje sztucznej inteligencji podczas studiów wyższych. Tylko mniej niż jedna piąta przeszła specjalistyczne kursy AI. Jeśli chodzi o preferowane działania służące poszerzaniu wiedzy, największą popularnością cieszyły się kursy tematyczne, a udział w konferencjach był o połowę mniejszy. Projekty komercyjne, projekty open source, współpraca z publicznymi grupami naukowymi i poznawanie wyników badań prowadzonych na uniwersytetach uzyskały podobny poziom wsparcia (około 50 procent).

W badaniu podkreślono, że znaczna liczba nauczycieli nie miała doświadczenia w nauczaniu sztucznej inteligencji i miała ograniczony udział w publikacjach i badaniach nad stosowaną sztuczną inteligencją (prawie czterdzieści procent nigdy nie opublikowało artykułu na temat stosowanej sztucznej inteligencji, a tylko połowa uczestniczyła w badaniach nad stosowaną sztuczną inteligencją). Podkreśla to potrzebę zaangażowania większej liczby współpracowników w projekty związane ze sztuczną inteligencją, biorąc pod uwagę ich wyraźne zainteresowanie. Jednak ponad 50% nauczycieli miało co najmniej roczne doświadczenie w nauczaniu, a prawie jedna piąta posiadała ponad pięcioletnie doświadczenie w nauczaniu, co pozycjonuje ich jako ekspertów. Zaledwie 15% nauczycieli wyraziło brak zainteresowania nauczaniem AI.

Co ciekawe, większość nauczycieli nie brała udziału w komercyjnych projektach AI, ale wyraziła pozytywną skłonność do angażowania zewnętrznych ekspertów AI z przemysłu (Niektórzy- co zgadza się 37,50%, Zgadzam się 42,50%, nikt nie był przeciwny ekspertom z przemysłu). Wśród respondentów panowała silna zgoda co do znaczenia włączenia do programu nauczania kompetencji w zakresie stosowanej sztucznej inteligencji, takich jak główne obszary sztucznej inteligencji, w tym kontekst zastosowań, rozpoznawanie



Co-funded by  
the European Union

oddechu i użyteczności metod uczenia maszynowego (ML) oraz ich praktyczne zastosowanie. Obejmuje to konieczność porównania metod ML i doboru odpowiedniej wraz z jej szkoleniem i testowaniem. Jednak zaawansowane tematy, takie jak nadmierne dopasowanie, kłątwa wymiarowości, wskaźniki wydajności, algorytmy i stroniczość danych, zostały uznane za mniej krytyczne.

Znaczenie dyskusji na temat potencjalnych konsekwencji podejmowania decyzji wynikających z uczenia maszynowego (ML) spotkało się ze stosunkowo ograniczoną uwagą respondentów, sugerując, że nie zostało uznane za bardzo istotne. Podobne wyniki zaobserwowano w odniesieniu do kwestii etycznych związanych z systemami sztucznej inteligencji. Jest prawdopodobne, że nauczyciele postrzegali zdobywanie wszechstronnej wiedzy na temat samych metod jako główny cel dla uczniów, ponieważ debata na temat użycia i etyki byłaby daremna bez solidnego zrozumienia funkcjonowania tych metod. Co więcej, znaczenie logiki i formalizmu probabilistycznego, wraz z ich rozumowaniem, również uznano za stosunkowo mniej znaczące.

Aby promować edukację w zakresie sztucznej inteligencji, respondenci podkreślili znaczenie utworzenia strony internetowej prezentującej lokalne badania uniwersyteckie nad stosowaną sztuczną inteligencją i tworzących projekty open source poświęcone rozwiązywaniu problemów związanych ze sztuczną inteligencją. Podkreślili również znaczenie prezentacji ustnych, studenckich kół naukowych, a także webinarium, ale wspieranie współpracy z ekspertami z firm zajmujących się sztuczną inteligencją jest uważane za najważniejsze dla lepszego zrozumienia zagadnień związanych ze sztuczną inteligencją stosowaną. Dla studentów wymagania rynku pracy są uważane za ważne, ale aby zdobyć krytyczną praktyczną wiedzę na temat sztucznej inteligencji, wymagana jest współpraca z firmami zajmującymi się sztuczną inteligencją.

Z zaleceń nauczycieli można wybrać następujące porady dotyczące programu nauczania:


- Skoncentruj się bardziej na darmowych wersjach.
- Najpierw wybierz odpowiedni język obliczeniowy i biblioteki
- Uwaga na widzenie komputerowe, wytłumaczalną sztuczną inteligencją, interakcję człowiek-sztuczna inteligencja
- Dodaj więcej działań na podstawie przykładów
- Rozwiązywanie prawdziwych przypadków sztucznej inteligencji na zajęciach

Fakt, że ani kursy uniwersyteckie, ani kursy specjalistyczne nie są głównym zasobem umiejętności nawet wśród nauczycieli, wskazuje na konieczność doskonalenia zarówno kursów uniwersyteckich, jak i specjalistycznych. Badanie ujawniło potrzebę udoskonalenia kursów uniwersyteckich i specjalistycznych

programów szkoleniowych w zakresie stosowanej sztucznej inteligencji. Większość nauczycieli wyraziła chęć uczestniczenia w sponsorowanych kursach sztucznej inteligencji w celu poszerzenia swojej wiedzy. Podczas gdy większość nauczycieli od czasu do czasu badała najnowsze trendy w zakresie sztucznej inteligencji, prawie jedna piąta przyznała, że posiada tylko podstawową wiedzę. Na pytanie o znajomość najnowszych trendów, technik, rozwiązań sztucznej inteligencji, większość osób odpowiedziała, że od czasu do czasu bada ten obszar. Z kwestionariuszy, co nie jest zaskakujące, wynika, że nauczyciele muszą doskonalić swoje umiejętności w zakresie nauczania i promowania stosowanej sztucznej inteligencji. Zidentyfikowano przeszkody w doskonaleniu edukacji w zakresie sztucznej inteligencji, w tym problemy z programem studiów, bariery formalne dla nowych metod nauczania oraz nieodpowiedni sprzęt. Sprostanie tym wyzwaniom wymaga kompleksowych ulepszeń obejmujących programy studiów, metodologie nauczania i dostęp do odpowiednich zasobów. Pożądane kompetencje obejmują nauczanie, promowanie i doskonalenie wiedzy z zakresu AI. Umiejętności twarde wymagane do skutecznego nauczania i uczenia się stosowanej sztucznej inteligencji obejmują uczenie maszynowe, wybrane języki programowania i biblioteki, analizę i wizualizację danych, definiowanie i optymalizację algorytmów, głębokie uczenie i przetwarzanie języka naturalnego. W badaniu podkreślono znaczenie uwzględnienia kwestii etycznych jako kluczowej części programu nauczania sztucznej inteligencji, aspektu, który obecnie nie jest traktowany priorytetowo przez nauczycieli. Ponadto rozwój umiejętności miękkich, takich jak komunikacja, współpraca, zdolność adaptacji, kreatywność, rozwiązywanie problemów i przywództwo, uznano za kluczowy dla skutecznej edukacji stosowanej w zakresie sztucznej inteligencji. Zdecydowanie zachęcano do aktywnego uczestnictwa w społecznościach zajmujących się sztuczną inteligencją i współpracy z ekspertami w tej dziedzinie, aby być na bieżąco z najnowszymi osiągnięciami i trendami w branży. Ogólnie rzecz biorąc, ankieta ta dostarcza cennych informacji na temat



Co-funded by  
the European Union



RYSUNEK 4. Obowiązki zawodowe Word Cloud

obecny krajobraz edukacji stosowanej w zakresie sztucznej inteligencji wśród akademii, podkreślając obszary mocnych stron i możliwości poprawy. Odkrycia te przyczyniają się do ciągłych wysiłków na rzecz poprawy jakości i adekwatności edukacji w zakresie stosowanej sztucznej inteligencji w instytucjach akademickich.

#### SYNTETYCZNA ANALIZA ANKIET

Oferty pracy, propozycje projektów i ankiety stosowane przez sztuczną inteligencję zawierały otwarte pola tekstowe, dając respondentom możliwość wyrażenia swoich myśli i opinii. Te otwarte odpowiedzi zostały przeanalizowane za pomocą narzędzia chmur słów, aby uzyskać wgląd w najczęściej wymieniane słowa lub tematy w danych. Dane zostały wstępnie przetworzone. Słowa zatrzymania i wielkość liter zostały zignorowane. Dodatkowo usunięto również słowa wspierające czasy. W pierwszym badaniu zbadano zakres odpowiedzialności zawodowej w celu przeanalizowania głównych obowiązków i zobowiązań związanych ze stanowiskiem pracy. Przeanalizowano łącznie 57 opisów odpowiedzialności, aby uzyskać wgląd w kluczowe zadania i obowiązki



związane z pracą. Wynik przedstawiono na rys. 4.

Jeśli chodzi o obowiązki zawodowe, analiza chmury słów uwypukliła znaczącą grupę słów skupionych wokół "danych" i "systemu", podkreślając znaczenie pozyskiwania cennych informacji dla określonej domeny biznesowej z wykorzystaniem technik uczenia maszynowego i sztucznej inteligencji do szkolenia. W tekście mocno podkreślono również termin "deep learning". Ponadto pojęcia takie jak "energia", "jakość", "zarządzanie" i "rozwiązania ludzkie" okazały się znaczące. Z drugiej strony, rzadziej pojawiającymi się słowami były "zastosowanie" jako "sieć", "medycyna" i "przemysł spożywczy". Zebrane ankiety na temat projektów



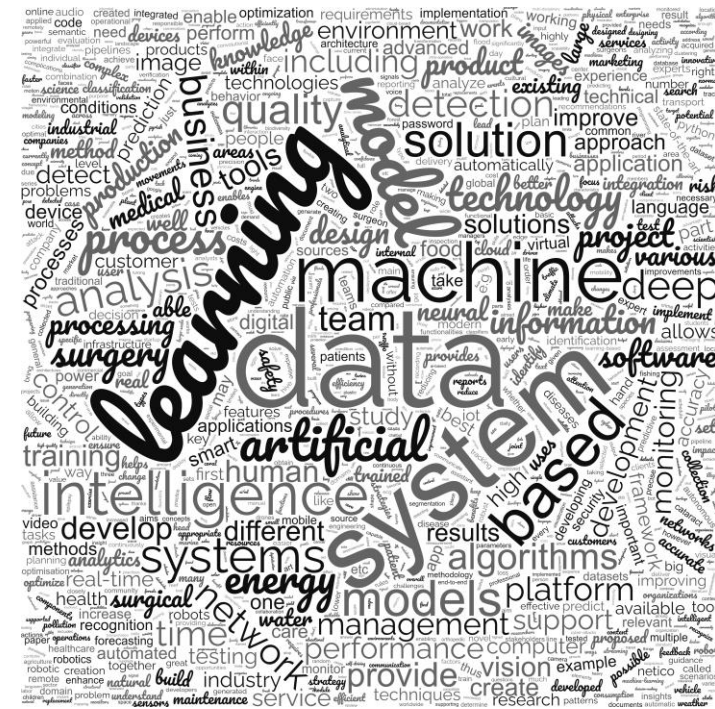
RYSUNEK 5. Cele projektu Word Cloud

zostały poddane dalszej analizie w celu wydobywania cennych spostrzeżeń i głębszego zrozumienia ich cech, celów i wyników. Rysunek 5 przedstawia analizę chmury słów celów projektu, natomiast rysunek 6 przedstawia wizualizację chmury słów wyników projektu, zapewniając wgląd w główne cele i zadania, a także znaczące wyniki i osiągnięcia analizowanych projektów. Rozbieżność w liczbie analizowanych wyników, z 63 wynikami w porównaniu do 52, można przypisać faktowi, że niektóre projekty są nadal w toku, a zatem nie przyniosły jeszcze ostatecznych wyników.

Dwie chmury słów obrazują podstawowe skupienie się na stworzeniu "projektu", który polega na opracowaniu "systemu" przy użyciu "metod uczenia się", w wyniku







RYSUNEK 7. Rzeczywiste cele studium przypadku Word Cloud

#### PROBLEMY DECYZYJNE W OPARCIU O ANALIZĘ AHP

Wyniki badań geodezyjnych przedstawione w sekcjach II-D, II-E, II-F, IV-A, IV-B, IV-C, IV-D wykorzystano jako statystyka w celu określenia atrybutów alternatyw w ramach szeregu problemów związanych z podejmowaniem decyzji, które zostaną opisane w bieżących podrozdziałach. Pod uwagę branych będzie wielu decydentów pochodzących z różnych ankiet (rynek pracy, pracownicy naukowci, studenci, pracodawcy, dobre praktyki).

Użyliśmy skali AHP (od 1 do 5), aby przypisać wartości reprezentujące względną ważność lub preferencje. Porównania parami alternatyw zostały przeprowadzone za pomocą obliczania preferencji parami lub przy użyciu funkcji parami, takich jak:

```
pairwiseFunction: function(a1, a2) min(5,
    max(1/5, a1$attribute/a2$attribute))
```

Here a1, a2 are alternatives to be compared relative to attribute.

- 1) Priorytety kompetencji z punktu widzenia AI ML Na rysunku 8 przedstawiono model procesu decyzyjnego. Problem dotyczy 12 kompetencji związanych ze sztuczną inteligencją i uczeniem maszynowym. Decydenci obejmują przedstawicieli rynku pracy, nauczycieli akademickich, studentów i pracodawców.

Na rysunkach 9-13 przedstawiono priorytety dla poszczególnych grup



Co-funded by  
the European Union

kryteriów z punktu widzenia odpowiednich decydentów. Liczby te reprezentują względne znaczenie, jakie każda grupa przypisuje różnym kompetencjom. Priority są określane w procesie porównywania parami, w którym decydenci porównują każdą kompetencję z innymi na podstawie ich istotności.

2) Języki programowania w odniesieniu do serwera dedykowanego i rozwiązania chmurowego

Wybór języka programowania jest rzeczywiście ważny podczas badania sztucznej inteligencji, ponieważ może znacząco wpłynąć na zdolność do skutecznego rozwoju systemów sztucznej inteligencji. Kryteria wyboru języka obejmują obsługiwane biblioteki i frameworki, tętniącą życiem społeczność i zasoby, elastyczny i wyrazisty kod, wydajność i wydajność, integrację i wdrażanie oraz trendy branżowe.

Tutaj, w kontekście określania priorytetów języka programowania dla szkolenia AI, AHP zostało wykorzystane do uwzględnienia punktów widzenia decydentów, takich jak rynek pracy, pracodawcy i rozwiązania w zakresie dobrych praktyk (patrz model na rys. 14).

Priorytety uzyskane od każdego decydenta są agregowane w celu wygenerowania kompleksowego zestawu priorytetów dla języków programowania w kursach szkoleniowych dotyczących sztucznej inteligencji (patrz rys. 15-18). Osiągnięto to poprzez obliczenie średnich ważonych wektorów priorytetowych decydentów.

3) Modele sztucznej inteligencji w ramach Classic ML i Deep ML

Z punktu widzenia klasycznego uczenia maszynowego decydenci powinni skupić się na badaniu ugruntowanych algorytmów uczenia maszynowego, takich jak regresja liniowa, drzewa decyzyjne i maszyny wektorów nośnych, które są szeroko stosowane i testowane na rynku pracy, preferowane przez pracodawców i uważane za dobre praktyki w zakresie sztucznej inteligencji. Z punktu widzenia Deep ML decydenci powinni priorytetowo traktować badanie głębokich sieci neuronowych, konwolucyjnych sieci neuronowych i rekurencyjnych sieci neuronowych, ponieważ modele te wykazały niezwykłą wydajność w różnych zastosowaniach sztucznej inteligencji, cieszą się dużym popytem na rynku pracy, są poszukiwane przez pracodawców i odzwierciedlają aktualne najlepsze praktyki w dziedzinie sztucznej inteligencji.

Próbując numerycznie rozwiązać dany problem decyzyjny, rysunek 19 przedstawia schemat blokowy procesu decyzyjnego. Problem dotyczy 10 modeli związanych z klasyką i DL. Decydentami są przedstawiciele rynku pracy, pracodawcy i rozwiązania dobrych praktyk.

Na rysunkach 20-23 przedstawiono priorytety dla poszczególnych grup kryteriów z punktu widzenia odpowiednich decydentów. Liczby te reprezentują względne znaczenie, jakie każda grupa przypisuje różnym modelom sztucznej

inteligencji. Priorytety są określane w procesie porównywania parami, w którym decydenci porównują każdą kompetencję z innymi na podstawie ich znaczenia.

#### A. TENSOR-BASED COURSE REPRESENTATION

Na podstawie wcześniejszych badań wyznaczono czynniki  $C$  (tab. 6),  $T$  (tab. 7),  $M$  (tab. 8). Co więcej, macierze  $A_{MC}$  i  $A_{TC}$  przedstawiono odpowiednio w tabelach 10 i 9. Mnożąc odpowiednie wpisy otrzymujemy tensor  $\tau_i^k$ .

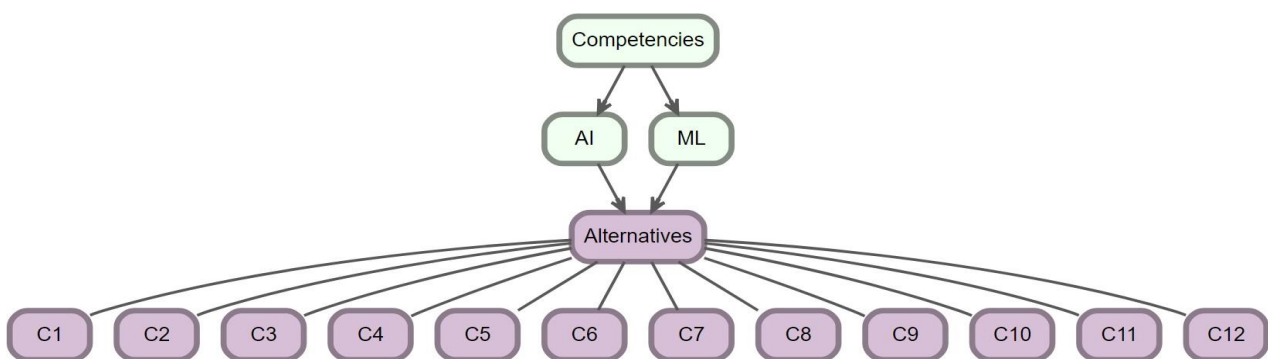
Generowanie abstrakcyjnych modeli modułowych jest teraz możliwe dzięki dekompozycji tensorowej. Każdy tensor składa się z trzech relacji lub relacji "kompetencja-temat-moduł". Każdy tensor jest wtedy cechą składającą się z ważonej sumy tensorów rangi jeden uzyskanych przez pomnożenie wektorów trójczynnikowych.

Takie podejście pozwoliło nam uzyskać szereg matryc dla relacji "moduł-temat" według różnych kompetencji. Rysunek 3 przedstawia tensor, którego składnikami są: tematy, moduły i kompetencje. Kształtowanie pożądanej kompetencji można osiągnąć poprzez realizację obu konkretnych tematów i modułów.

W tabeli 9 przedstawiono przekrojową macierz "kompetencja tematyczna" dla 12 kluczowych kompetencji w szkolnictwie wyższym zajmującym się sztuczną inteligencją, które można osiągnąć, realizując wybraną spośród 12 tematów wymienionych w tabeli

7. Tak więc, na przykład, kompetencja o nazwie: "Rozpoznaj oddech i użyteczność metod uczenia maszynowego" można osiągnąć realizując następujące tematy: Systemy eksperckie oparte na regułach; Uczenie maszynowe I; Uczenie maszynowe II; Głębokie sieci neuronowe – podstawy; Głęboka neutralna sieć - zaawansowane tematy; Głębokie uczenie się przez wzmacnianie; Przetwarzanie języka naturalnego; Robotyka.

W celu podniesienia jakości kształcenia przy jednoczesnym zapewnieniu wysokich standardów kształcenia proponujemy wzmocnienie tych kompetencji poprzez realizację konkretnych modułów.



**RYСУNEK 8.** Model podejmowania decyzji dotyczących kompetencji, na które ma wpływ sztuczna inteligencja i uczenie maszynowe



Co-funded by  
the European Union

	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%

**RYSUNEK 9.** Priorytety dla kompetencji, na które ma wpływ sztuczna inteligencja i uczenie maszynowe: łączny wynik

	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%

**RYSUNEK 10.** Priorytety kompetencji pod wpływem sztucznej inteligencji i uczenia maszynowego: rynek pracy jako decydujący

	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%

**RYSUNEK 11.** Priorytety w zakresie kompetencji, na które wpływa sztuczna inteligencja i uczenie maszynowe: środowisko akademickie jako decydujący

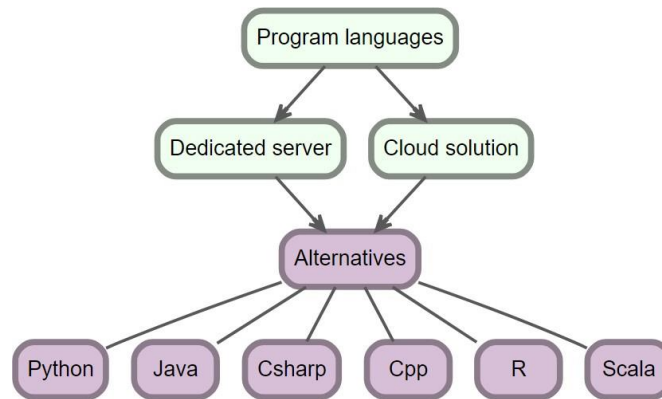
	Weight	C1	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C2	Inconsistency
Competencies	100.0%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	8.3%	0.0%
ML	75.0%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.3%	6.2%	0.0%
AI	25.0%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	2.1%	0.0%

**RYSUNEK 12.** Priorytety dla kompetencji pod wpływem sztucznej inteligencji i uczenia maszynowego: studenci jako decydujący

	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%

**RYSUNEK 13.** Priorytety dla kompetencji pod wpływem sztucznej inteligencji i uczenia maszynowego: pracodawcy jako decydujący





**RYSUNEK 14.** Model podejmowania decyzji dotyczących języków programowania w odniesieniu do serwerów dedykowanych lub rozwiązań chmurowych

**TABELA 6.** Kompetencje z zakresu sztucznej inteligencji i uczenia maszynowego, które mają zostać uwzględnione w proponowanym kursie dotyczącym sztucznej inteligencji stosowanej

---

#### Kompetencja w zakresie denotacji

- C1 Opisz główne obszary sztucznej inteligencji, a także konteksty, w których metody sztucznej inteligencji mogą być stosowane.
  - C2 Przedstaw informacje w formalizmie logicznym i zastosuj odpowiednie metody rozumowania.
  - C3 Przedstawiać informacje w formalizmie probabilistycznym i stosować odpowiednie metody rozumowania.
  - C4 Należy pamiętać o szerokim zakresie kwestii etycznych związanych z systemami sztucznej inteligencji, a także mechanizmami łagodzenia problemów.
  - C5 Rozpoznanie zakresu i użyteczności metod uczenia maszynowego
  - C6 Porównaj i zestaw metody uczenia maszynowego.
  - C7 Wybierz odpowiednie metody uczenia maszynowego (ich klasy) dla konkretnych problemów.
  - C8 Stosuj odpowiednie metodologie trenowania i testowania podczas wdrażania algorytmów uczenia maszynowego.
  - C9 Wyjaśnienie metod łagodzenia skutków nadmiernego dopasowania i przebiegu wymiarowości w kontekście algorytmów uczenia maszynowego.
  - C10 Zidentyfikuj odpowiednią metrykę wydajności do oceny algorytmów/narzędzi uczenia maszynowego dla danego problemu.
  - C11 Rozpoznawanie problemów związanych z algorytmami i stroniczością danych, a także prywatnością i integralnością danych.
  - C12 Debata nad możliwymi skutkami – zarówno pozytywnymi, jak i negatywnymi – decyzji wynikających z wniosków płynących z uczenia maszynowego.
- 

**TABELA 7.** Tematy z zakresu sztucznej inteligencji i uczenia maszynowego, które zostaną poruszone w proponowanym kursie na temat stosowanej sztucznej inteligencji

---

#### Temat denotacji

- |    |  |
|----|--|
| T1 | Sztuczna inteligencja – historia i modele oparte na logice         |
| T2 | Reprezentacja wiedzy i rozumowanie (oparte na prawdopodobieństwie) |
| T3 | Strategie planowania i wyszukiwania sztucznej inteligencji         |
| T4 | Logika rozmyta, systemy sterowania rozmytego                       |



Co-funded by  
the European Union

<i>T5</i>	Systemy eksperckie oparte na regułach
<i>T6</i>	Uczenie maszynowe I (omówienie i uczenie nadzorowane)
<i>T7</i>	Uczenie maszynowe II (uczenie nienadzorowane)
<i>T8</i>	Głębokie sieci neuronowe – podstawy
<i>T9</i>	Głębokie sieci neuronowe – tematy zaawansowane
<i>T10</i>	Głębokie uczenie przez wzmacnianie
<i>T11</i>	Przetwarzanie języka naturalnego
<i>Robotyka T12</i>	

**TABELA 8.** Moduły proponowanego kursu na temat AAI

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

**TABELA 9.** Macierz krzyżowa dla relacji "kompetencja-temat" dla kursu AAI

	<i>T<sub>1</sub></i>	<i>T<sub>2</sub></i>	<i>T<sub>3</sub></i>	<i>T<sub>4</sub></i>	<i>T<sub>5</sub></i>	<i>T<sub>6</sub></i>	<i>T<sub>7</sub></i>	<i>T<sub>8</sub></i>	<i>T<sub>9</sub></i>	<i>T<sub>10</sub></i>	<i>T<sub>11</sub></i>	<i>T<sub>12</sub></i>
<i>C<sub>1</sub></i>	1	0	0	0	0	0	0	0	0	0	0	0
<i>C<sub>2</sub></i>	1	1	0	0	0	0	0	0	0	0	0	0
<i>C<sub>3</sub></i>	0	1	0	0	0	0	0	1	0	0	0	0
<i>C<sub>4</sub></i>	1	1	1	1	1	1	1	0	1	1	1	1
<i>C<sub>5</sub></i>	0	0	0	0	0	1	1	1	1	1	1	1
<i>C<sub>6</sub></i>	0	0	0	0	0	1	1	1	1	1	1	1
<i>C<sub>7</sub></i>	0	0	0	0	0	1	1	1	1	0	1	1
<i>C<sub>8</sub></i>	0	0	0	0	0	1	1	1	1	1	0	0
<i>C<sub>9</sub></i>	0	0	0	0	0	1	1	0	1	1	0	0
<i>C<sub>10</sub></i>	0	0	0	0	0	1	1	1	1	0	0	0
<i>C<sub>11</sub></i>	1	1	1	1	1	1	1	0	1	1	1	1
<i>C<sub>12</sub></i>	0	0	0	0	0	1	1	0	1	1	1	1

Tabela 10 przedstawia macierz krzyżową "moduł – kompetencje". Z tego widać, że kształcenie pożądanych kompetencji zostało wzmocnione przez realizację niektórych modułów. I tak np. edukacja wybranej wcześniej kompetencji "Rozpoznać oddech i użyteczność mechanicznych metod uczenia się" została

wzmocniona realizacją modułów: M1 (Podstawy zasad zastosowania AI w nauce i nowoczesnych rozwiązaniach biznesowych) oraz M3 (Prowadzenie badań związanych z zasadniczym zastosowaniem sztucznej inteligencji). W ten sposób każdą kompetencję można zdobyć, realizując określone tematy i moduły. Tabele 13 - 24 pokazują macierz krzyżową "moduły-tematy" dla każdej z 12 kompetencji. Tabele te zawierają wartość '1'

**TABELA 10.** Macierz krzyżowa dla relacji "moduł kompetencji", która ma zostać zaimplementowana w projektowanym kursie AAI

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
C <sub>1</sub>	1	1	1	0	1	0	0	0	0	0	0	1
C <sub>2</sub>	0	1	0	0	1	0	0	0	0	0	0	1
C <sub>3</sub>	0	1	0	0	1	0	0	0	0	0	0	1
C <sub>4</sub>	0	1	1	0	1	0	0	0	0	0	0	1
C <sub>5</sub>	1	0	1	0	0	0	0	0	0	0	0	0
C <sub>6</sub>	0	1	0	1	1	1	1	1	1	1	1	1
C <sub>7</sub>	1	0	1	0	0	1	1	1	1	1	1	0
C <sub>8</sub>	1	0	0	1	0	1	1	1	1	1	1	0
C <sub>9</sub>	0	0	0	1	0	1	1	1	1	1	1	0
C <sub>10</sub>	0	0	0	1	0	1	1	1	1	1	1	0
C <sub>11</sub>	0	0	0	0	0	1	1	1	1	1	1	0
C <sub>12</sub>	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%

**RYSUNEK 15.** Priorytety dla języków programowania w stosunku do serwera dedykowanego lub rozwiązania chmurowego: pełna decyzja

	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%

**RYSUNEK 16.** Priorytety języków programowania w stosunku do serwera dedykowanego lub rozwiązania chmurowego: decyzja z punktu widzenia rynku pracy





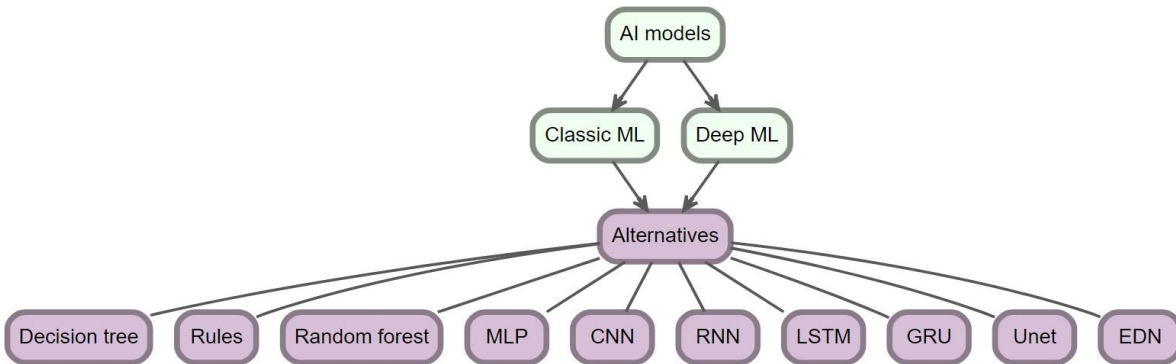
Co-funded by the European Union

	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%

RYSUNEK 17. Priorytety języków programowania w stosunku do serwera dedykowanego lub rozwiązania chmurowego: decyzja z punktu widzenia pracodawców

	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%

RYSUNEK 18. Priorytety dla języków programowania w odniesieniu do serwera dedykowanego lub rozwiązania chmurowego: decyzja z punktu widzenia dobrych praktyk w AAI



RYSUNEK 19. Model do podejmowania decyzji na modelu AI względem klasycznego lub głębokiego uczenia maszynowego

	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%

RYSUNEK 20. Model do podejmowania decyzji na modelu AI w odniesieniu do klasycznego lub głębokiego uczenia maszynowego: całkowita decyzja

	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%

**RYSUNEK 21.** Model podejmowania decyzji na modelu AI w stosunku do klasycznego lub głębokiego uczenia maszynowego: decyzja ze względu na wymagania rynku pracy

	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%

**RYSUNEK 22.** Model podejmowania decyzji na modelu AI w stosunku do klasycznego lub głębokiego uczenia maszynowego: pracodawca jako decydent

	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%

**RYSUNEK 23.** Model podejmowania decyzji na modelu AI w odniesieniu do klasycznego lub głębokiego uczenia maszynowego: decyzja z punktu widzenia wymagań dobrych praktyk

kiedy kształcenie danej kompetencji będzie możliwe dzięki realizacji zarówno wybranego modułu, jak i wybranego tematu, oraz "0", gdy realizacja danego tematu nie nadaje się do realizacji określonego wybranego modułu. Tabele 13 - 24 przedstawione tutaj są macierze utworzone przez mnożenie tematów przez wektor modułów. Na przykład dla tabeli 13: Kompetencje: Opisanie głównych obszarów sztucznej inteligencji i kontekstów, w których możliwe będzie zastosowanie metod sztucznej inteligencji poprzez ukończenie tematu 1 (*TI* – Historia sztucznej inteligencji i modele oparte na logice) oraz modułów (*M1* – Podstawowe zasady zastosowania sztucznej inteligencji w nauce i nowoczesnych rozwiązaniach biznesowych; *M2* - Moduły wbudowane IBM, Microsoft, Google, AWS itp.; *M3* – Prowadzenie badań związanych z praktycznym zastosowaniem sztucznej inteligencji; *M12* - Zastosowanie innych modułów AI). Analogicznej interpretacji można dokonać analizując pozostałe tabele.

## DYSKUSJA

### WYMAGANIA RYNKU PRACY

Rynek pracy w zakresie sztucznej inteligencji jest dynamiczny i ewoluuje. Od różnych umiejętności programistycznych po znajomość wzorców projektowych lub posiadanie określonych wymagań edukacyjnych. Poniższe rozdziały pokazują



Co-funded by  
the European Union

rozmieszczenie i informacje o niezbędnych wymaganiach, które jednostka musi mieć, aby być konkurencyjnym w dziedzinie AAI.

#### 1) Wymagane języki programowania

Znajomość umiejętności programowania wiąże się z konkretnym językiem programowania potrzebnym w stosowanych technikach sztucznej inteligencji. Tabela 11 zawiera informacje o tym, które języki programowania są najbardziej potrzebne w stosowanej sztucznej inteligencji.

**TABLE 11. Required programming languages**

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

Zgodnie z oczekiwaniami, Python jest językiem programowania, który jest najbardziej potrzebny w dziedzinach stosowanej sztucznej inteligencji. To pokazuje, że większość kursów powinna koncentrować się na dostarczaniu szczegółowego programu nauczania języka programowania Python i bibliotek, które są odpowiednie dla tej dziedziny. Odsetek ten wynika z prostoty Pythona i ogromnego ekosystemu, który można wykorzystać w różnych domenach.

Pozostałe języki programowania są w dość podobnej skali, z wybranym językiem programowania R na poziomie 28,38%, co pokazuje nam, że znaczna część kompetencji jest zorientowana na obliczenia i analizę statystyczną oraz wizualizację ze względu na obszerny zbiór bibliotek i pakietów statystycznych.

Wyniki pokazują również, że inne wymagane języki programowania to Java, C# i C++.

#### 2) Wymagania edukacyjne

Tabela 12 przedstawia dane o tym, jakie wymagania edukacyjne należy spełnić, aby móc pracować w AAI.

Wymagania edukacyjne w zakresie stosowanej sztucznej inteligencji zazwyczaj obejmują solidne podstawy matematyki, a dokładniej statystyki i analizy statystycznej oraz informatyki. Z danych wynika, że licencjat z informatyki jest często

TABELA 12. Wymagania edukacyjne

Degree	Percentage
Bachelor degree - computer science-related field	33.78%
Master degree - computer science-related field	29.73%
No education level, skills only	27.03%
Other	9.46%

minimalny wymóg, któremu towarzyszy tytuł magistra, oba stopnie naukowe w dziedzinach związanych z informatyką.

Chociaż doktorat w tych dziedzinach zapewnia głębszą wiedzę i specjalizację, badania pokazują, że ogólnie rzecz biorąc, doktorat nie jest koniecznym poziomem wykształcenia. Ważniejsze jest posiadanie umiejętności, co oznacza, że zarówno uczniowie, jak i kursy powinny wymuszać ciągłą naukę i certyfikaty oraz być na bieżąco w dziedzinie AAI.

### 3) Wymagane kompetencje

Jednym z najważniejszych zbiorów wiedzy na rynku pracy jest skupienie się na niezbędnych kompetencjach potrzebnych do zastosowania sztucznej inteligencji. Ogólnie rzecz biorąc, kompetencja odnosi się do wiedzy, umiejętności i zdolności, które ekspert musi posiadać, aby pracować w dziedzinie stosowanej sztucznej inteligencji.

Z badania wynika, że wybór odpowiednich klas metod uczenia maszynowego i zastosowanie ich do konkretnych problemów jest najbardziej dominującą wymaganą kompetencją, z wynikiem 59,46%. Jest to oczekiwane, biorąc pod uwagę fakt, że jednym z najważniejszych zadań jest znalezienie najlepszego sposobu przetwarzania podanych danych. Pokazuje to, że eksperci muszą mieć kompleksową wiedzę na temat głównych obszarów sztucznej inteligencji i kontekstów, w których można ją zastosować.

Z wynikiem odpowiednio 48,65% i 41,89%, porównywanie metod uczenia maszynowego i reprezentowanie informacji w formalizmie logicznym to kolejne dwie najważniejsze kompetencje. Można wywnioskować, że porównywanie metod ML jest bezpośrednio związane z doбором odpowiedniej metody do konkretnego problemu, nie więc dziwnego, że ta konkurencja jest bardzo potrzebna. Umiejętność przedstawiania informacji za pomocą formalizmów logicznych lub probabilistycznych oraz stosowania odpowiednich metod umożliwia ekspertom skuteczne modelowanie i manipulowanie wiedzą.

Kompetencje, które mają znaczący wpływ, to stosowanie odpowiednich metodologii szkoleniowych i testowych podczas wdrażania algorytmów uczenia maszynowego, a także rozpoznawanie zakresu i użyteczności metod uczenia maszynowego w wieku około 40 lat

Znajomość wymaganych kompetencji w zakresie stosowanej sztucznej inteligencji to bardzo ważne badanie. Dostarcza wielu przydatnych informacji, które



**Co-funded by  
the European Union**

mogą być ukierunkowane na rozwój programu nauczania, rozwój umiejętności lub przygotowanie do kariery. W obszarze opracowywania programów nauczania zrozumienie wymaganych kompetencji pomaga instytucjom w projektowaniu i rozwijaniu aktualnych programów. Dostosowanie kompetencji do programu nauczania jest niezbędnym krokiem w kierunku odniesienia sukcesu w wybranej dziedzinie.

#### *WYMAGANIA OD PRACODAWCÓW*

Wyniki ankiety, która bada potrzeby i doświadczenia pracodawców w dziedzinie stosowanej sztucznej inteligencji, podkreślają kilka ważnych wniosków dotyczących wymaganych umiejętności twardych, umiejętności miękkich i wykształcenia uniwersyteckiego w zakresie stosowanej sztucznej inteligencji, uczenia maszynowego (ML), nauki o danych i Big Data. Jeśli chodzi o umiejętności twarde, kompetencją najbardziej cenioną przez pracodawców jest umiejętność rozpoznawania problemów związanych z algorytmicznością i stroniczością danych, a także prywatnością i integralnością danych. Ponadto firmy podkreślają znaczenie kompetencji, takich jak opisywanie głównych obszarów sztucznej inteligencji, identyfikowanie wskaźników wydajności do oceny algorytmów uczenia maszynowego oraz rozpoznawanie zakresu i użyteczności metod uczenia maszynowego. Aby sprostać tym wymaganiom, firmy powinny skupić się na zapewnieniu szkoleń i możliwości rozwoju w celu zwiększenia umiejętności i zdolności osób, które wykazują słabsze kompetencje. Dla pracowników zajmujących się sztuczną inteligencją i nauką o danych ważne jest, aby szanować historię tej dziedziny i rozumieć korzyści i ograniczenia zarówno oparte na logice, jak i na prawdopodobieństwie reprezentacje wiedzy. Powinni również wykazać się zaangażowaniem w stosowanie uczenia maszynowego jako części procesu zorientowanego na cel dla klientów i skrupulatnie porównywać wyuczone modele. Wybór i ocena algorytmów są uważane za kluczowe dla zapewnienia jakości wyuczonych modeli, a podejścia do oceny etycznej z wysokim zaufaniem są niezbędne. Dbłość o szczegóły jest podkreślana w technikach uczenia się bez nadzoru w celu eksploracji, zrozumienia, podsumowania i wizualizacji danych. Jeśli chodzi o wykorzystanie modeli ML, klasyczne techniki ML i deep ML są szeroko stosowane przez firmy. Podczas gdy tradycyjne modele uczenia maszynowego, takie jak drzewa decyzyjne i wielowarstwowe perceptrony (MLP), są powszechnie używane i badane, modele głębokiego uczenia, takie jak konwolucyjne sieci neuronowe (CNN) i rekurencyjne sieci neuronowe (RNN), są bardzo popularnym wyborem. Ankieta ujawnia również najczęstsze zadania związane ze sztuczną inteligencją i uczeniem maszynowym w firmach, przy czym najwyżej plasuje się klasyfikacja i regresja. Klasyfikacja obrazów, klasteryzacja i podpisy obrazów są również powszechne, podczas gdy zadania takie jak rozpoznawanie mowy i segmentacja obrazów otrzymują znaczne wskaźniki odpowiedzi. Jeśli chodzi o języki programowania, Python jest najbardziej wymagany językiem do pracy ze

sztuczną inteligencją i uczeniem maszynowym, a następnie C++. Java, R i C# również mają znaczenie w tej dziedzinie. TensorFlow jest najczęściej używanym frameworkiem AI, a następnie Keras i scikit-learn. Inne frameworki, takie jak PyTorch, Apache TVM, AMD HIP, OpenAI i Matlab, są używane w mniejszym stopniu. Anaconda, Apache Hadoop i Matlab to popularne ekosystemy, co wskazuje na skupienie się na kompleksowych narzędziach uczenia maszynowego, dużych zbiorach danych i złożonych algorytmach. Pracodawcy priorytetowo traktują kompetencje związane z innowacyjnością, adaptacją, studiami wykonalności oraz nowoczesnymi metodami psychologii i pedagogiki dla pracowników akademickich/analizy danych. Krytyczne myślenie, komunikacja oraz biegłość w posługiwaniu się narzędziami i technologią to wysoko cenione umiejętności miękkie. Planowanie i organizowanie, podstawy biznesowe i umiejętności współpracy są również uważane za niezbędne. Ponadto pracodawcy podkreślają znaczenie takich kompetencji, jak dobór odpowiednich struktur danych i algorytmów, wizualizacja analizy AI czy wdrażanie rozwiązań opartych na chmurze obliczeniowej. Wyniki pokazują, że umiejętności techniczne w zakresie sztucznej inteligencji i nauki o danych są kluczowe, ale niewystarczające do osiągnięcia sukcesu w tej dziedzinie. Pracodawcy cenią sobie dodatkowe kompetencje, w tym umiejętność rozwiązywania problemów, doświadczenie praktyczne, architekturę oprogramowania, umiejętności prezentacji, krytyczne myślenie, zdolność adaptacji, a w niektórych przypadkach wiedzę specyficzną dla danej dziedziny. Skuteczna komunikacja, zarówno z klientami, jak i w zespołach wewnętrznych, jest uważana za niezbędną. Badanie wskazuje, że kompetencje wymagane przez firmy z obszaru AI i Data Science są zróżnicowane, co odzwierciedla interdyscyplinarny charakter tej dziedziny. O ile wiedza teoretyczna specjalistów ds. sztucznej inteligencji jest na ogół dobra, o tyle umiejętności praktyczne często wymagają poprawy. Zrozumienie wymagań biznesowych, określenie praktycznych aspektów rozwoju oraz umiejętność pracy nad problemami o różnej skali to kluczowe kompetencje. Pracodawcy mają mieszane opinie na temat jakości absolwentów kierunków informatycznych, ale doceniają ich biegłość techniczną i solidne przygotowanie. Umiejętności praktyczne i kreatywność są uważane za kluczowe, podczas gdy umiejętności współpracy są niezbędne w pracy zespołowej. Podczas gdy rynek pracy dla młodszych specjalistów IT jest uważany za wystarczający, znalezienie specjalistów średniego lub wyższego szczebla może być wyzwaniem. Zdania na temat zapotrzebowania na specjalistów AI są podzielone, a część pracodawców wskazuje na znaczną lukę na rynku pracy. Większość firm jest umiarkowanie zadowolona z poziomu przygotowania absolwentów studiów magisterskich w obszarze AI, co wskazuje na pole do poprawy. Firmy na ogół pozytywnie podchodzą do podnoszenia kwalifikacji swoich obecnych pracowników, umożliwiając im studiowanie sztucznej inteligencji na poziomie magisterskim. Podsumowując, badanie dostarcza cennych informacji na temat potrzeb i oczekiwań pracodawców w zakresie Applied AI. Podkreśla znaczenie szerokiego zakresu kompetencji, w tym umiejętności twardych, umiejętności miękkich i wiedzy interdyscyplinarnej. Ciągła nauka, praktyczne doświadczenie, skuteczna komunikacja i umiejętność rozwiązywania problemów są kluczem do sukcesu w tej szybko rozwijającej się dziedzinie.





Co-funded by  
the European Union

Ogólnie rzecz biorąc, badanie rzuciło światło na wymagania pracodawców dotyczące umiejętności i kompetencji w zakresie stosowanej sztucznej inteligencji i nauki o danych. Odkrycia mogą pomóc w ulepszeniu programów szkoleniowych i edukacyjnych, aby sprostać potrzebom pracodawców w dziedzinie stosowanej sztucznej inteligencji.

#### WYMAGANIA STAWIANE STUDENTOM

Duży odzew ze strony studentów, magistrantów i absolwentów informatyki w dziedzinie systemów informatycznych i technologii (ponad 1000 uczestników ankiety internetowej), głównie z krajów partnerskich, świadczy o ogromnym zainteresowaniu tych grup docelowych stosowaną sztuczną inteligencją. Młodzi studenci uważają, że treści AAI będą ważne dla ich dalszej kariery i pokazują wyraźną potrzebę odpowiednich kursów.

Większość studentów była zainteresowana ankietą na temat AAI, ale brak wiedzy o jakimkolwiek odpowiednim kursie na ich uczelni świadczy o dobrych podstawach projektu FAAI i rosnącym zapotrzebowaniu na kursy dotyczące AAI. Wyraźnie zaznaczono, że kurs rozwojowy powinien opierać się w dużej mierze na praktycznym wdrożeniu z pracą laboratoryjną, projektami studenckimi i stażami. Instytucje szkolnictwa wyższego powinny skupić się na wdrażaniu treści AAI do programów studiów poprzez wprowadzanie innowacji do istniejących kursów lub wprowadzanie zupełnie nowych kursów. Ulepszanie komponentów materiałowych (sprzęt, laboratoria) jest czynnikiem drugorzędym, ale również ważnym. Stworzenie strony internetowej prezentującej badania z zakresu AAI powinno być kolejnym priorytetem dla uczelni partnerskich. Jest to skuteczny sposób rozpowszechniania wyników i angażowania studentów i innych grup docelowych w tematy AAI. Fakt, że prawie wszyscy studenci kierunków informatycznych wyrazili zainteresowanie lub byli neutralnie nastawieni do studiowania kursu AAI, jest zgodny z założeniem projektu, że w regionie europejskim istnieje niedobór AAI i innych umiejętności cyfrowych. W związku z tym podkreśla potrzebę nowych inicjatyw w celu odpowiedniego włączenia tych umiejętności do programu nauczania, rozwoju nauczycieli, praktyk oceniania i treści nauczania.

Zaprojektowane kursy AAI muszą być silnie zorientowane na programistów, ponieważ stanowią one ogromną siłę docelową dla rozwoju kompetencji i umiejętności cyfrowych w obszarze Stosowanej Sztucznej Inteligencji. Pracownicy sektora IT najczęściej wymagają od swoich pracowników tytułu licencjata, więc najbardziej logicznym wyborem do umieszczenia kursów AAI byłyby studia licencjackie lub w ramach niektórych programów specjalizacyjnych. Z drugiej strony musimy pamiętać, że kursy te zwykle wymagają już zdobytej wiedzy w terenie, podczas gdy bardziej podstawowe kursy są oczywiście pożądane przez populację docelową.

Rozwijanie umiejętności miękkich staje się coraz ważniejsze w dzisiejszym środowisku pracy. Młodzi ludzie zdają sobie sprawę z ich znaczenia, podobnie jak



ich pracodawcy. Każde projektowane szkolenie powinno również skupiać się na rozwijaniu umiejętności miękkich, w szczególności tych związanych z pracą zespołową, komunikacją i zarządzaniem czasem. Kreatywność, Rozwiązywanie problemów, Zdolność do uczenia się i stosowania zdobytej wiedzy również powinny być wysoko cenione podczas tworzenia kursu. Najcenniejsze kompetencje specjalisty w zakresie AAI to: Stosowanie odpowiednich metodologii szkoleniowych i testowych podczas wdrażania algorytmów uczenia maszynowego, Rozpoznawanie zakresu i użyteczności metod uczenia maszynowego, Dobór odpowiednich metod uczenia maszynowego (klas) dla konkretnych problemów oraz Porównywanie i kontrastowanie metod uczenia maszynowego.

Szkolenia FAAI i wytyczne dotyczące ich projektowania muszą również uwzględniać požądane przez respondentów przyszłe zawody (zgodnie z listą europejskich ram kompetencji IT) i być dostosowane konkretnie do tych najpopularniejszych, takich jak Software Development, Project Manager, Systems Administrator i Database Administrator.

#### WYMAGANIA WOBEC NAUCZYCIELI AKADEMICKICH

Kompetencje edukatorów odgrywają kluczową rolę w wyposażaniu ich w umiejętności i wiedzę potrzebną do skutecznego nauczania i promowania AAI. Ponieważ dziedzina ta szybko się rozwija, konieczne staje się zidentyfikowanie i nadanie priorytetu kompetencjom wymaganym do aktualizowania nauczycieli i dostarczania uczniom cennych instrukcji. Kluczowe kompetencje, które powinny być podkreślane wśród naukowców w odniesieniu do AAI obejmują następujące kwestie.

Konieczne jest, aby nauczyciele włączyli kwestie *etyczne* do programu nauczania, ponieważ sztuczna inteligencja staje się coraz bardziej zintegrowana z różnymi dziedzinami. Nauczyciele muszą wyposażyć uczniów w umiejętność krytycznej oceny etycznych implikacji i potencjalnych konsekwencji podejmowania decyzji przez sztuczną inteligencję. Wiąże się to z zachęcaniem do dyskusji na temat uprzedzeń, uczciwości, przejrzystości, odpowiedzialności oraz szerszego społecznego i etycznego wymiaru technologii sztucznej inteligencji.

Pracownicy naukowcy powinni posiadać solidną wiedzę na temat podstawowych *pojęć technicznych i metodologii stosowanej* sztucznej inteligencji. Obejmuje to wiedzę na temat algorytmów uczenia maszynowego, modelowania statycznego, wstępnego przetwarzania i analizy danych, języków programowania oraz powszechnie używanych bibliotek w rozwoju sztucznej inteligencji. Ponadto biegłość w takich dziedzinach, jak widzenie komputerowe, przetwarzanie języka naturalnego i głębokie uczenie się, ma kluczowe znaczenie, ponieważ są to podstawowe elementy stosowanej sztucznej inteligencji.

Sztuczna inteligencja to *multidyscyplinarna dziedzina*, która przecina się z różnymi dziedzinami, takimi jak informatyka, matematyka, kognitywistyka i etyka. Należy zachęcać nauczycieli akademickich do przyjęcia interdyscyplinarnego podejścia do edukacji w zakresie sztucznej inteligencji, wypełniając lukę między wiedzą techniczną a jej zastosowaniem w rzeczywistych kontekstach. Wiąże się to ze wspieraniem współpracy i uwzględnianiem różnych perspektyw z innych




Co-funded by  
the European Union

dyscyplin, umożliwiając studentom holistyczne rozwiązywanie złożonych wyzwań związanych ze sztuczną inteligencją. Rozwijanie umiejętności *krytycznego myślenia i rozwiązywania problemów* ma kluczowe znaczenie w edukacji stosowanej w zakresie sztucznej inteligencji. Naukowcy powinni kłaść nacisk na umiejętność analizowania i oceny modeli i algorytmów sztucznej inteligencji, identyfikowania ograniczeń i potencjalnych uprzedzeń oraz proponowania innowacyjnych rozwiązań problemów związanych ze sztuczną inteligencją. Pielęgnując zdolności analityczne i logicznego rozumowania uczniów, nauczyciele umożliwiają im stanie się skutecznymi praktykami sztucznej inteligencji i naukowcy.

Skuteczne *umiejętności komunikacji i współpracy* są niezbędne dla nauczycieli w dziedzinie stosowanej sztucznej inteligencji. Nauczyciele akademicy powinni być w stanie formułować złożone koncepcje sztucznej inteligencji w jasny i przystępny sposób, wspierając zaangażowanie i zrozumienie wśród studentów o różnym poziomie wykształcenia technicznego. Ponadto promowanie współpracy w społeczności akademickiej i poza nią, na przykład poprzez partnerstwa branżowe, zachęca do dzielenia się wiedzą, nawiązywania kontaktów i ekspozycji na rzeczywiste zastosowania sztucznej inteligencji.

Biorąc pod uwagę szybki postęp w technologiach sztucznej inteligencji, akademia powinna posiadać *zdolność adaptacji i zaangażowanie w uczenie się przez całe życie*. Powinni być na bieżąco z najnowszymi osiągnięciami, pojawiającymi się trendami i najlepszymi praktykami w tej dziedzinie. Wiąże się to z ciągłym doskonaleniem zawodowym, uczestnictwem w konferencjach i warsztatach, uczestnictwem w społecznościach zajmujących się sztuczną inteligencją oraz zasięgiem wskazówek ekspertów branżowych. Przyjmując nastawienie na rozwój, nauczyciele akademicy mogą skutecznie przygotować studentów do stale zmieniającego się krajobrazu stosowanej sztucznej inteligencji.

Nauczyciele akademicy są odpowiedzialni za wspieranie *etycznego przywództwa* i służenie jako wzór do naśladowania dla swoich studentów. Demonstrując etyczne zachowanie, promując uczciwość i podtrzymując



standardy zawodowe, nauczyciele inspirowują uczniów do przyjmowania etycznych praktyk w swoich przedsięwzięciach związanych ze sztuczną inteligencją. Nauczyciele powinni zaszczerpieć poczucie odpowiedzialności społecznej, podkreślając znaczenie sztucznej inteligencji dla poprawy społeczeństwa i zachęcając uczniów do wykorzystania sztucznej inteligencji w celu uzyskania pozytywnego wpływu.

Podsumowując, kompetencje wymagane od nauczycieli akademickich w dziedzinie stosowanej sztucznej inteligencji wykraczają poza biegłość techniczną. Kładzenie nacisku na względy etyczne, przyjęcie podejścia interdyscyplinarnego, pielęgnowanie umiejętności krytycznego myślenia i rozwiązywania problemów, wspieranie skutecznej komunikacji i współpracy, uwzględnianie zdolności adaptacyjnych i uczenia się przez całe życie oraz promowanie etycznego przywództwa może umożliwić nauczycielom zapewnienie kompleksowej i wpływowej edukacji w zakresie sztucznej inteligencji. Pielęgnowując te kompetencje wśród naukowców, możemy zapewnić, że przyszłe pokolenia będą wyposażone w wiedzę i umiejętności potrzebne do poruszania się po etycznych, technicznych i społecznych zawiłościach stosowanej sztucznej inteligencji.

#### *SYNTETYCZNA ANALIZA ANKIET*

Podsumowując, analiza chmury słów dotycząca obowiązków zawodowych, celów projektu, wyników projektu oraz celów rzeczywistego studium przypadku



Co-funded by  
the European Union

AAI ujawniła spójne motywy. Chmura słów sprzężenia została przedstawiona na rysunku 24.

Znaczenie "systemów" opartych na "danych" i generowania "modeli" poprzez "maszynę" i "sztuczność", "inteligencję" i "uczenie się" było powszechne we wszystkich chmurach słów. Dodatkowo położono nacisk na "energetyczne" wykorzystanie i "głębokie" rozwiązania. Powszechnie wymieniano obszary zastosowań, takie jak "sieć", "medycyna", "biznes" i "konserwacja". Analizując chmurę słów, oczywiste jest, że idealny system, który ma zostać stworzony, powinien posiadać cechy wyróżniające.

acterystyki, takie jak "wydajność", "jakość" i "dokładność". Co więcej, konieczne jest, aby niektóre rozwiązania uzupełniały istniejące. Wreszcie, "zarządzanie" i "monitorowanie" to również ważne słowa kluczowe z analizowanego systemu. W ten sposób należy przedstawić cykl życia stworzonego rozwiązania. Wyniki przedstawiły spostrzeżenia na temat głównych obowiązków i obowiązków na stanowiskach pracy, celów i wyników projektu oraz celów rzeczywistego studium przypadku.

#### *ANALIZA AHP ZALEŻNOŚCI TENSOROWEJ OD "MODUŁU-KOMPETENCJI-TREŚCI"*

Jak wykazano, AHP może być wykorzystywane do szkolenia w edukacji opartej na kompetencjach, pomagając w ustalaniu priorytetów i podejmowaniu decyzji dotyczących różnych aspektów kursu. Zastosowanie AHP w tym kontekście pomogło nam w wykonaniu następujących czynności. Definiując cel, ustaliśmy ostateczny cel szkolenia. Może to być opracowanie konkretnych kompetencji w zakresie AAI.

Określając kryteria, które przyczyniają się do osiągnięcia celu, w kształceniu opartym na kompetencjach kryteria te mogą obejmować takie czynniki, jak adekwatność treści do pożądaných kompetencji, jasność i skuteczność metod nauczania, strategie oceny stosowane do pomiaru osiągnięć w zakresie kompetencji, dostosowanie do standardów branżowych lub wymagań zawodowych.

Za pomocą generowania alternatyw określamy różne alternatywy lub opcje projektowania kursu szkoleniowego na temat AAI. Alternatywy te mogą obejmować różne podejścia instruktażowe, metodologie nauczania, metody oceny, kolejność tematów, czas trwania kursu lub włączenie ćwiczeń praktycznych lub rzeczywistych przypadków.

Stosując AHP w projektowaniu kursów szkoleniowych AAI, możemy systematycznie oceniać i ustalać priorytety różnych czynników, brać pod uwagę wiele perspektyw i podejmować bardziej świadome decyzje, które są zgodne z celami i wymaganiami CBE.

1) Priorytety kompetencji z punktu widzenia AI ML

Metoda analitycznego procesu hierarchicznego (AHP) może być stosowana do

określania priorytetów wśród kompetencji związanych ze sztuczną inteligencją i uczeniem maszynowym w kontekście rynku pracy, naukowców, studentów i pracodawców jako decydentów. AHP to ustrukturyzowane podejście, które pomaga decydentom porównywać i ustalać priorytety różnych kryteriów w oparciu o ich względne znaczenie.

Korzystając z metody AHP, decydenci mogą systematycznie oceniać i przypisywać wagi kompetencjom. Wyniki z rysunków 9-13 można następnie wykorzystać do kierowania procesami decyzyjnymi związanymi z kompetencjami AI i ML, takimi jak opracowywanie programów nauczania, decyzje o zatrudnieniu czy programy edukacyjne, z uwzględnieniem perspektyw przedstawicieli rynku pracy, nauczycieli akademickich, studentów i pracodawców.

### 2) Języki programowania dla AAI – kurs szkoleniowy

Różne języki programowania mają różną obsługę bibliotek i struktur AI, takich jak Python z Tensor-Flow i PyTorch, co znacznie upraszcza tworzenie sztucznej inteligencji. Języki takie jak Python i R mają tętniące życiem społeczności AI, oferujące obfite zasoby do nauki i rozwiązywania problemów. Niektóre języki oferują elastyczność i ekspresyjność, jak prostota i czytelność Pythona, podczas gdy inne, takie jak Lisp lub Haskell, mają wbudowaną obsługę programowania funkcyjnego, co jest korzystne dla niektórych technik sztucznej inteligencji. Wybór języka programowania może zależeć od wymagań wydajnościowych, przy czym języki takie jak C++ lub Java oferują lepszą wydajność niż języki interpretowane. Potrzeby w zakresie integracji i wdrażania mogą również wpływać na wybór języka, na przykład przy użyciu języka JavaScript w aplikacjach internetowych. Popularność Pythona w społeczności AI sprawia, że jest on szeroko stosowany w przemyśle, środowisku akademickim i badaniach.

Należy zauważyć, że konkretne priorytety programowania języków związanych z kursami szkoleniowymi dotyczącymi sztucznej inteligencji mogą się różnić w zależności od kontekstu, postępu technologicznego oraz zmieniających się potrzeb rynku pracy i pracodawców (zob. rys. 15-18). W związku z tym najbardziej aktualne i kompleksowe wyniki uzyskano z najnowszych badań lub ankiet przeprowadzonych przez ekspertów ds. sztucznej inteligencji, instytucje badawcze lub organizacje branżowe specjalizujące się w sztucznej inteligencji i językach programowania. Kryteria, które są ważne dla oceny przydatności języków programowania dla kursów szkoleniowych dotyczących sztucznej inteligencji, mogą obejmować takie czynniki, jak wydajność, skalowalność, wsparcie społeczności, biblioteki i frameworki, łatwość użytkowania, ekosystem, przyjęcie w branży oraz kompatybilność z rozwiązaniami dedykowanymi serwerom i rozwiązaniami chmurowymi.

### 3) Modele AI w ramach Classic ML i Deep ML

Z punktu widzenia klasycznego uczenia maszynowego decydenci powinni priorytetowo traktować badanie podstawowych modeli, takich jak regresja liniowa, regresja logistyczna i drzewa decyzyjne, ponieważ są one szeroko stosowane na rynku pracy, poszukiwane przez pracodawców i reprezentują dobre praktyki w zakresie sztucznej inteligencji. Z punktu widzenia Deep ML decydenci powinni



Co-funded by  
the European Union

skupić się na badaniu głębokich sieci neuronowych, konwolucyjnych sieci neuronowych (CNN) i rekurencyjnych sieci neuronowych (RNN), ponieważ modele te zyskały znaczące znaczenie na rynku pracy, są wysoko cenione przez pracodawców i uważane za niezbędne do nadążania za aktualnymi najlepszymi praktykami w zakresie sztucznej inteligencji.

#### REPREZENTACJA KURSU OPARTA NA TENSORZE

Poprzez analizę tabeli zawierającej międzymacierzową kompetencję tematyczną można zauważyć, że kompetencja powstała w wyniku realizacji największej liczby tematów jest kompetencją  $C_4$ . Aby go rozwijać, konieczne jest wdrożenie niemal wszystkich tematów ( $T_1$ - $T_{12}$ ) z wyjątkiem tematu  $T_8$ .

Biorąc pod uwagę kompetencje modułów międzymacierzowych, można zauważyć, że wzmocnienie kompetencji  $C_6$  powinno odbywać się poprzez realizację prawie wszystkich modułów ( $M_1$ - $M_{12}$ ) z wyjątkiem  $M_1$  i  $M_3$ .

Z analizy przedstawionej w tabelach 13–24 wynika, że moduły i tematy mają istotne powiązania. Wyniki wskazują na następujące powiązania między kompetencjami a komponentami (tematami) edukacyjnymi:

- Kompetencja  $C_1$  może być rozwijana poprzez wdrożenie  $T_1$  wraz z modułami  $M_1$ ,  $M_2$ ,  $M_3$  i  $M_{12}$ .
- Aby kultywować kompetencję  $C_2$ , zaleca się realizację  $T_1$  w połączeniu z modułami  $M_2$ ,  $M_5$  i  $M_{12}$ .
- Do kształcenia kompetencji  $C_3$  zaleca się podjęcie  $T_1$ ,  $T_5$ ,  $T_{12}$  oraz wykorzystanie modułów  $M_2$  i  $M_8$ .
- Kompetencja  $C_4$  może być skutecznie nauczana poprzez realizację  $T_2$ ,  $T_3$ ,  $T_4$ ,  $T_{12}$  i większości modułów, z wyjątkiem  $M_8$ .
- Aby zdobyć kompetencję  $C_5$ , konieczne jest zaangażowanie się w  $T_1$ ,  $T_3$  i wykorzystują moduły od  $M_6$  do  $M_{12}$ .
- Rozwój kompetencji  $C_6$  wymaga wdrożenia  $T_2$ ,  $T_4$  do  $T_{12}$ , a także wykorzystania modułów  $M_6$  do  $M_{12}$ .
- Kompetencja  $C_7$  może być skutecznie szkolona poprzez realizację  $T_1$ ,  $T_3$ ,  $T_6$  do  $T_{11}$  oraz poprzez wykorzystanie modułów od  $M_6$  do  $M_{12}$ .
- W celu kształcenia kompetencji  $C_8$  zaleca się podjęcie  $T_1$ ,  $T_3$ ,  $T_4$ ,  $T_6$  do  $T_{11}$  i wykorzystanie modułów od  $M_6$  do  $M_{12}$ .
- Kompetencję  $C_9$  można nabyć poprzez  $T_4$ ,  $T_6$  przez  $T_{11}$  i wykorzystując moduły od  $M_6$  do  $M_{12}$ .
- Aby rozwinąć kompetencję  $C_{10}$ , zaleca się podjęcie  $T_4$ ,  $T_6$  do  $T_{11}$  i wykorzystaj moduły od  $M_6$  do  $M_{12}$ .
- Rozwój kompetencji  $C_{11}$  wymaga wdrożenia  $T_6$  do  $T_{11}$  i wykorzystania większości modułów, z wyjątkiem  $M_8$ .
- W kształceniu kompetencji  $C_{12}$  zaleca się wdrożenie poziomów od  $T_6$  do  $T_{11}$  oraz wykorzystanie modułów  $M_6$ ,  $M_7$  i  $M_9$  do  $M_{12}$ .



## KONKLUZJA

W ramach badania z powodzeniem opracowano kompleksowe podejście do projektowania kursu szkoleniowego na temat AAI w kontekście szkolnictwa wyższego. Podejście to opiera się na podejściach pedagogicznych opartych na dowodach i jest zgodne z zasadami edukacji opartej na kompetencjach i pedagogiki innowacyjnej.

W ramach badania przeprowadzono dokładny przegląd AAI poprzez grupowanie słów kluczowych, uwzględniając dane z ankiet, ofert pracy, istniejących kursów szkoleniowych dotyczących sztucznej inteligencji, projektów naukowych i rzeczywistych przypadków. Analiza informacji tekstowych za pomocą chmur słów dostarczyła cennych spostrzeżeń.

W badaniu zastosowano podejście oparte na tensorach do prezentacji kursu AAI opartego na kompetencjach, zapewniając holistyczną reprezentację kompetencji w odniesieniu do treści kursu i modułów edukacyjnych. Takie podejście pozwala na uporządkowane i kompleksowe zrozumienie wymaganych umiejętności i wiedzy w AAI.

Poprzez rozwiązanie problemów związanych z podejmowaniem decyzji przy użyciu techniki AHP, w ramach badań zidentyfikowano konkretne wymagania liczbowe i priorytety dla kursu, co jeszcze bardziej poprawiło jego konstrukcję i skuteczność.

Wyniki badania podkreślają znaczenie dostosowania kursu szkoleniowego do potrzeb i preferencji grupy docelowej. Dzięki wykorzystaniu spostrzeżeń z ankiet, doświadczeń edukacyjnych, projektów naukowych i wymagań biznesowych, opracowany kurs szkoleniowy z zakresu sztucznej inteligencji zapewnia osiągnięcie pożądaných kompetencji i efektów uczenia się.

Implikacje tych badań są istotne dla instytucji szkolnictwa wyższego, które chcą zaprojektować skuteczne kursy szkoleniowe w zakresie AAI. Podejście przedstawione w niniejszym opracowaniu zapewnia ramy dla opracowywania kursów, które spełniają wymagania szybko rozwijającej się dziedziny sztucznej inteligencji, a jednocześnie zaspokajają specyficzne potrzeby studentów i wymagania branży.

Ogólnie rzecz biorąc, praca ta przyczynia się do rozwoju opartych na dowodach podejść pedagogicznych w dziedzinie edukacji opartej na sztucznej inteligencji, w szczególności w kontekście szkolnictwa wyższego. Opracowany kurs szkoleniowy w zakresie stosowanej sztucznej inteligencji oferuje kompleksowe i oparte na kompetencjach doświadczenie edukacyjne, sprzyjając nabywaniu odpowiednich umiejętności i wiedzy potrzebnych do rozwiązywania rzeczywistych problemów związanych ze sztuczną inteligencją.

## DODATEK A

### KOMPETENCJE MIĘDZY MACIERZAMI

Tabele 13-24 przedstawiają relację "temat-moduł" z punktu widzenia odpowiednich kompetencji.





**TABLE 13.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją C1

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
T <sub>1</sub>	1	1	1	0	0	0	0	0	0	0	0	1
T <sub>2</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>3</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>4</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>5</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>6</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>7</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>8</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>9</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>10</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>11</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>12</sub>	0	0	0	0	0	0	0	0	0	0	0	0

**TABLE 14.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją C2

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
T <sub>1</sub>	0	1	0	0	1	0	0	0	0	0	0	1
T <sub>2</sub>	0	1	0	0	1	0	0	0	0	0	0	1
T <sub>3</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>4</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>5</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>6</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>7</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>8</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>9</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>10</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>11</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>12</sub>	0	0	0	0	0	0	0	0	0	0	0	0

**TABLE 15.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją C3

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
T <sub>1</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>2</sub>	0	1	0	0	0	0	0	1	0	0	0	0
T <sub>3</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>4</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>5</sub>	0	1	0	0	0	0	0	1	0	0	0	0
T <sub>6</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>7</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>8</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>9</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>10</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>11</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>12</sub>	0	1	0	0	0	0	0	1	0	0	0	0

**TABLE 16.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją C4

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
T <sub>1</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>2</sub>	1	1	1	1	1	1	1	0	1	1	1	1
T <sub>3</sub>	1	1	1	1	1	1	1	0	1	1	1	1
T <sub>4</sub>	1	1	1	1	1	1	1	0	1	1	1	1
T <sub>5</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>6</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>7</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>8</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>9</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>10</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>11</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>12</sub>	1	1	1	1	1	1	1	0	1	1	1	1

**TABLE 17.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją C4

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
T <sub>1</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>2</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>3</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>4</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>5</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>6</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>7</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>8</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>9</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>10</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>11</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>12</sub>	0	0	0	0	0	0	0	0	0	0	0	0

**TABLE 18.** Cross-matrix for the relation "topic-module" according to the competence C<sub>6</sub>

	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	M <sub>4</sub>	M <sub>5</sub>	M <sub>6</sub>	M <sub>7</sub>	M <sub>8</sub>	M <sub>9</sub>	M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>
T <sub>1</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>2</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>3</sub>	0	0	0	0	0	0	0	0	0	0	0	0
T <sub>4</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>5</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>6</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>7</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>8</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>9</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>10</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>11</sub>	0	0	0	0	0	1	1	1	1	1	1	1
T <sub>12</sub>	0	0	0	0	0	1	1	1	1	1	1	1



**TABLE 22.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją 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

**TABLE 23.** Macierz krzyżowa dla relacji "temat-moduł" zgodnie z kompetencją C11

	$M_1$	$M_2$	$M_3$	$M_4$	$M_5$	$M_6$	$M_7$	$M_8$	$M_9$	$M_{10}$	$M_{11}$	$M_{12}$
$T_1$	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	0	0	0	0	0	0	0
$T_5$	0	0	0	0	0	0	0	0	0	0	0	0
$T_6$	1	1	1	1	1	1	1	0	1	1	1	1
$T_7$	1	1	1	1	1	1	1	0	1	1	1	1
$T_8$	1	1	1	1	1	1	1	0	1	1	1	1
$T_9$	1	1	1	1	1	1	1	0	1	1	1	1
$T_{10}$	1	1	1	1	1	1	1	0	1	1	1	1
$T_{11}$	1	1	1	1	1	1	1	0	1	1	1	1
$T_{12}$	0	0	0	0	0	0	0	0	0	0	0	0

**TABLE 24.** Cross-matrix for the relation "topic-module" according to the competence C12

	$M_1$	$M_2$	$M_3$	$M_4$	$M_5$	$M_6$	$M_7$	$M_8$	$M_9$	$M_{10}$	$M_{11}$	$M_{12}$
$T_1$	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	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	1	1	0	1	1	1	1
$T_7$	0	0	0	0	0	1	1	0	1	1	1	1
$T_8$	0	0	0	0	0	1	1	0	1	1	1	1
$T_9$	0	0	0	0	0	1	1	0	1	1	1	1
$T_{10}$	0	0	0	0	0	1	1	0	1	1	1	1
$T_{11}$	0	0	0	0	0	1	1	0	1	1	1	1
$T_{12}$	0	0	0	0	0	0	0	0	0	0	0	0

## REFERENCJE

- [1] Faai job hub – the future is in applied artificial intelligence 2022-1-pl01- ka220-hed-000088359. <https://faai.ath.edu.pl/>. (Accessed on 07/04/2023).
- [2] Chaomei Chen, Fidelia Ibekwe-SanJuan, and Jianhua Hou. The structure and dynamics of cocitation clusters: A multiple-perspective cocitation analysis. *Journal of the American Society for Information Science and Technology*, 61(7):1386–1409, March 2010.
- [3] Fabiano Bini, Andrada Pica, Laura Azzimonti, Alessandro Giusti, Lorenzo Ruinelli, Franco Marinuzzi, and Pierpaolo Trimboli. Artificial intelligence in thyroid field—a comprehensive review. *Cancers*,



Co-funded by  
the European Union

- 13(19):4740, September 2021.
- [4] Farzad V. Farahani, Krzysztof Fiok, Behshad Lahijanian, Waldemar Karwowski, and Pamela K. Douglas. Explainable AI: A review of applications to neuroimaging data. *Frontiers in Neuroscience*, 16, December 2022.
  - [5] Onur Dogan, Sanju Tiwari, M. A. Jabbar, and Shankru Guggari. A systematic review on AI/ML approaches against COVID-19 outbreak. *Complex & Intelligent Systems*, 7(5):2655–2678, July 2021.
  - [6] Vijay Kumar, Dilbag Singh, Manjit Kaur, and Robertas Damaševičius. Overview of current state of research on the application of artificial intelligence techniques for COVID-19. *PeerJ Computer Science*, 7:e564, May 2021.
  - [7] Zhuoqing Chang, Shubo Liu, Xingxing Xiong, Zhaohui Cai, and Guoqing Tu. A survey of recent advances in edge-computing-powered artificial intelligence of things. *IEEE Internet of Things Journal*, 8(18):13849–13875, September 2021.
  - [8] Muddasar Naem, Syed Tahir Hussain Rizvi, and Antonio Coronato. A gentle introduction to reinforcement learning and its application in different fields. *IEEE Access*, 8:209320–209344, 2020.
  - [9] Rohan Gupta, Devesh Srivastava, Mehar Sahu, Swati Tiwari, Rashmi K. Ambasta, and Pravir Kumar. Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Molecular Diversity*, 25(3):1315–1360, April 2021.
  - [10] Jingyi Zhao and Guifang Fu. Artificial intelligence-based family health education public service system. *Frontiers in Psychology*, 13, May 2022.
  - [11] Bui Hoang Bac, Hoang Nguyen, Nguyen Thi Thanh Thao, Vo Thi Hanh, Le Thi Duyen, Nguyen Tien Dung, Nguyen Khac Du, and Nguyen Huu Hiep. Estimating heavy metals absorption efficiency in an aqueous solution using nanotube-type halloysite from weathered pegmatites and a novel Harris Hawks optimization-based multiple layers perceptron neural network. *Engineering with Computers*, 38(S5):4257–4272, July 2021.
  - [12] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *Nature*, 521(7553):436–444, May 2015.
  - [13] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition, 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, and Demis Hassabis. Human-level control through deep reinforcement learning. *Nature*, 518(7540):529–533, February 2015.
  - [15] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
  - [16] Jürgen Schmidhuber. Deep learning in neural networks: An overview. *Neural Networks*, 61:85–117, January 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, and Li Fei-Fei. ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3):211–252, April 2015.
  - [18] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6):84–90, May 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, and Demis Hassabis. Mastering the game of go with deep neural networks and tree search. *Nature*, 529(7587):484–489, January 2016.
  - [20] Joelle Elmaleh and Venky Shankaraman. Improving student learning in an introductory programming course using flipped classroom and competency framework. In *2017 IEEE Global Engineering Education Conference (EDUCON)*, pages 49–55, 2017.
  - [21] Manus Ross, Corey A. Graves, John W. Campbell, and Jung H. Kim. Using support vector machines to classify student attentiveness for the development of personalized learning systems. In *2013 12th International Conference on Machine Learning and Applications*, volume 1, pages 325–328, 2013.
  - [22] Shah Neyamat Ullah. Examples of authentic assessments in engineering education. In *2020 IEEE Global Engineering Education Conference (EDUCON)*, pages 894–897, 2020.

- [23] Jose Louie Mark Z. Ano, Geoffrey A. Solano, John Arthur P. Hernan, and Ronalyn Grace Francisco. Warp: A workflow-aware instructional platform for competency-based learning. In *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pages 1–4, 2019.
- [24] Arman Raj, Vandana Sharma, Seema Rani, Tanya Singh, Ankit Kumar Shanu, and Ahmed Alkhayat. Demystifying and analysing metaverse towards education 4.0. In *2023 3rd International Conference on Innovative Practices in Technology and Management (ICIPTM)*, pages 1–6, 2023.
- [25] Promoting competency-based learning | sertifier. <https://sertifier.com/blog/promoting-competency-based-learning/>. (Accessed on 06/30/2023).
- [26] Michael Schumm, Saskia Joseph, Irmgard Schroll-Decker, Michael Niemetz, and Jürgen Mottok. Required competences in software engineering: Pair programming as an instrument for facilitating life-long learning. In *2012 15th International Conference on Interactive Collaborative Learning (ICL)*, pages 1–5, 2012.
- [27] Davy Tsz Kit Ng, Min Lee, Roy Jun Yi Tan, Xiao Hu, J. Stephen Downie, and Samuel Kai Wah Chu. A review of AI teaching and learning from 2000 to 2020. *Education and Information Technologies*, 28(7):8445–8501, December 2022.
- [28] Thomas K. F. Chiu, Helen Meng, Ching-Sing Chai, Irwin King, Savio Wong, and Yeung Yam. Creation and evaluation of a pretertiary artificial intelligence (AI) curriculum. *IEEE Transactions on Education*, 65(1):30–39, February 2022.
- [29] Becky Allen, Andrew Stephen McGough, and Marie Devlin. Toward a framework for teaching artificial intelligence to a higher education audience. *ACM Transactions on Computing Education*, 22(2):1–29, November 2021.
- [30] Computing competencies for undergraduate data science curricula. [https://www.acm.org/binaries/content/assets/education/curricula-recommendations/dstf\\_cdsc2021.pdf](https://www.acm.org/binaries/content/assets/education/curricula-recommendations/dstf_cdsc2021.pdf). (Accessed on 07/05/2023).
- [31] Matthew L. Jockers. *Text Analysis with R for Students of Literature*. Springer International Publishing, 2014.
- [32] Cristian Felix, Steven Franconeri, and Enrico Bertini. Taking word clouds apart: An empirical investigation of the design space for keyword summaries. *IEEE Transactions on Visualization and Computer Graphics*, 24(1):657–666, January 2018.
- [33] Stamatis Giannoulakis and Nicolas Tsapatsoulis. Topic identification via human interpretation of word clouds: The case of instagram hashtags. In *IFIP Advances in Information and Communication Technology*, pages 283–294. Springer International Publishing, 2021.
- [34] Shaher H. Zyoud and Daniela Fuchs-Hanusch. A bibliometric-based survey on ahp and topsis techniques. *Expert Systems with Applications*, 78:158–181, 2017.
- [35] M. Raissi, P. Perdikaris, and G.E. Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378:686–707, February 2019.
- [36] Geoffrey Hinton, Li Deng, Dong Yu, George Dahl, Abdel rahman Mohamed, Navdeep Jaitly, Andrew Senior, Vincent Vanhoucke, Patrick Nguyen, Tara Sainath, and Brian Kingsbury. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6):82–97, November 2012.