



Co-funded by
the European Union

FAAI:

Przyszłość tkwi w stosowanej sztucznej
inteligencjiProjekt Erasmus+ 2022-1-PL01-KA220-HED-
000088359

01.09.2022 – 31.08.2024

Badanie 3: Przegląd projektów naukowych w zakresie stosowanej sztucznej inteligencji: najnowocześniejsza analiza dla WP2





**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

13.05.2023

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: Zebrano i przeanalizowano ankiety dotyczące 63 projektów zebranych przez organizacje partnerskie z 5 krajów, dotyczących nauczania sztucznej inteligencji. Koordynatorami projektu byli przedstawiciele 19 krajów. Do ciekawszych wyników należy stwierdzenie, że ponad połowa projektów dotyczyła modułów uczenia głębokich sieci neuronowych, a większość zadań uczenia maszynowego, które zostały rozwiązane, dotyczyła przetwarzania obrazu, klasyfikacji, regresji, klastryzacji i przetwarzania języka naturalnego. Wśród wykorzystywanych bibliotek AI dominowały TensorFlow, Keras, scikit-learn i CUDA. Językami programowania były Python i C++. Większość odpowiedzi została przeanalizowana i zwizualizowana w formie wykresów.

Słowa kluczowe: projekty AI, wyniki ankiet, rekomendacje

1. Wprowadzenie

Kwestionariusz był częścią badań w związku z celami projektu 2022-1-PL01-KA220-HED-000088359 "The Future is in Applied Artificial Intelligence" (FAAI) w ramach programu Erasmus+. Projekt ten ma na celu połączenie uniwersytetów i przedsiębiorstw oraz dostarczenie innowacyjnych rozwiązań w celu rozwoju ekspertów w dziedzinie sztucznej inteligencji. Pytania w tym opracowaniu miały na celu zbadanie potrzeb i oczekiwań projektów naukowych w celu zaproponowania szkoleń specjalistów w dziedzinie Applied AI. Respondenci musieli wypełnić pola dotyczące ich doświadczeń i opinii dotyczących Applied AI. Mniej niż połowa pól była obowiązkowa (osiem z dwudziestu jeden), o czym świadczy gwiazdka po pytaniu. Praktycznie większość pól nieobowiązkowych wypełnili jednak respondenci. Teren projektu to: <http://faai.ath.edu.pl/>

2. Gromadzenie i analiza danych


Dane zostały pozyskane przez pięć instytucji partnerskich, naukowców i ich kolegów z innych instytucji.

Łącznie zebrano 63 ankiety. W badaniu uzyskano 11 (17,46%) ankiet od respondentów z Polski (1 respondent), 21 (33,33%) od respondentów bułgarskich (5 różnych respondentów), 10 (15,87%) od respondentów słowackich (6 różnych respondentów), 11 (17,46%) od respondentów serbskich (3 różnych respondentów) i 10 (15,87%) od respondentów z Czarnogóry (6 różnych respondentów). Ogółem liczba respondentów wyniosła 21.

3. Wyniki

3.1. Adres e-mail respondentów

Pierwsze pytanie ankiety dotyczy adresów e-mail respondentów. Analizie poddano wszystkie pięć krajów uczestniczących w projekcie. Numery 63 ankiet wypełniło 21 respondentów rozmieszczonych w następujący sposób: Polska 1 / 21 (4,76%), Bułgaria 5 / 21 (23,81%), Słowacja 6 / 21 (28,6%), Serbia 3 / 21 (14,28%), Czarnogóra 6 / 21 (28,6%). Wyniki przedstawiono poniżej.

**Opis danych:**

Z danych badawczych wynika, że respondenci ze Słowacji i Czarnogóry byli najbardziej zróżnicowani.

Dyskusja:

Chociaż preferowane jest posiadanie zróżnicowanych respondentów, aby zapewnić szeroki zasięg obszaru, ma to również wady, na przykład gdy odpowiedź na pytanie "Jaki istniejący program naukowy w dziedzinie sztucznej inteligencji..." w kwestionariuszu było Tak. Mniejsza liczba dedykowanych respondentów redukuje liczbę bezsensownych odpowiedzi do minimum.

Główne wnioski:

- Mimo że Bułgaria uzyskała większość odpowiedzi (patrz następny wykres), kwestionariusze z Czarnogóry i Słowacji miały bardziej zróżnicowane pochodzenie, co zmniejszyło stronniczość w badaniach, co powinno zwiększyć możliwość uogólnienia wyników badań.

3.2. Organizacja partnerska

Drugie pytanie ankiety dotyczy tego, skąd pochodzą respondenci. Przeanalizowano wszystkie pięć krajów uczestników projektu. Numery 63 kwestionariuszy zostały rozłożone w następujący sposób: UBB/Polska 11 / 63 (17,46%), ULSIT / Bułgaria 21 / 63 (33,33%), UCM/Słowacja 10 / 63 (15,87%), UNi/Serbia 11 / 63 (17,46%), UoM/Czarnogóra 10 / 63 (15,87%). Wyniki przedstawiono poniżej.

**Opis danych:**

Z danych wynika, że Bułgaria dostarczyła dwa razy więcej respondentów niż inne organizacje partnerskie.

Dyskusja:


Biorąc pod uwagę liczbę mieszkańców, najwięcej odpowiedzi udzieliła jednostka miarowo-górska.

Główne wnioski:

- Mimo że Bułgaria uzyskała najwięcej odpowiedzi, Czarnogóra ma stosunkowo największy wpływ na mieszkańców.

3.3. Jaki jest kraj koordynatora projektu?

Trzecie pytanie ankiety dotyczy tego, skąd pochodzą koordynatorzy projektu. Analizie poddano wszystkie kraje. Numery 63 ankiet zostały rozłożone w następujący sposób: Polska 11 / 63 (17.46%), Bułgaria 7 / 63 (11.11%), Słowacja 10 / 63 (15.87%), Serbia 8 / 63 (12.7%), Czarnogóra 5 / 63 (7.94%), Stany Zjednoczone 5 / 63 (7.94%), Wielka Brytania 0 / 63 (0%), Niemcy 3 / 63 (4.76%), Francja 1 / 63 (1.59%), Włochy 2 / 63 (3,17%), Hiszpania 0 / 63 (0%), Inne 11 / 63 (17,46%). Druga odpowiedź obejmowała Włochy, Estonię, Irlandię, Szwajcarię, Grecję, Norwegię, Portugalię, Grecję, Irlandię, Indie, - nieokreślone. Wyniki przedstawiono poniżej.

**Opis danych:**

Z danych badawczych wynika, że większość koordynatorów projektów znalazła Polska.

Dyskusja:

Ponownie, gdy weźmie się pod uwagę liczbę mieszkańców, Montenegro w ujęciu względnym dostarczyło większość koordynatorów projektów.

Główne wnioski:

- Stosunkowo wiele krajów zostało uwzględnionych tylko przez jednego koordynatora projektu, w związku z czym zasięg na całym świecie był stosunkowo dobry, mimo że kraje uczestniczące zapewniły większość koordynatorów.

3.4. Jaki istniejący program naukowy w dziedzinie sztucznej inteligencji został znaleziony?

Czwarte pytanie ankiety dotyczy podstawy, skąd pochodzi projekt. Niestety, pytanie nie było jasne dla wielu respondentów, więc odpowiedzi wahały się od "tak", "deep learning", "NA", adresu e-mail, aż po nazwę projektu. Rzeczywiste źródło wsparcia zostało wskazane jedynie w 22 z 63 ankiet, z czego większość, bo 8 odpowiedzi, pochodziło z polskiego NCN, 4 przypadki Erasmusa i 3 przypadki Polskiego Programu Operacyjnego Inteligentny Rozwój. Ponieważ większość odpowiedzi nie była trafna, odpowiedzi nie były analizowane głębiej.

3.5. Nazwa projektu

Piąte pytanie ankiety dostarczyło następujących 63 odpowiedzi:

Cyfrowy znak wodny dźwięku
Wizualna inspekcja złożonych zespołów mechanicznych opartych na sieciach syjamskich dla chmur punktów 3D
Praktyczne szkolenie z uczenia maszynowego
Klasyfikacja obiektów audiowizualnych i rozpoznawanie zdarzeń dźwiękowych poprzez wspólne szkolenie bez nadzoru
Inżynieria inteligentnych produktów i usług (SPaSE)
Zaawansowana analityka danych w biznesie – ADA,
Wdrożenie nowoczesnych metod Inteligentnego Sterowania w ramach modułu studiów Systemy sterowania
Szkolenie ECVET dla operatorów inteligentnych budynków z obsługą IoT
AgAR - Uniwersalny autonomiczny robot rolniczy
Rozwój nowych technologii informacyjno-komunikacyjnych wykorzystujących zaawansowane technologie matematyczne, mających zastosowanie w medycynie, energetyce, e-administracji, telekomunikacji i ochronie dziedzictwa narodowego
ATUVIS - System Kontroli Wizualnej Podwozia Pociągów Autonomicznych
Innowacje w programach nauczania w zakresie przyjaznego dla klimatu rozwoju obszarów miejskich w oparciu o ekologię i efektywność energetyczną z sektorem nieakademickim (SmartWB)
SMART-Smart Automatyzacja transportu kolejowego
SMART2 – zaawansowany zintegrowany system wykrywania przeszkód i wtargnięć na tor do inteligentnej automatyzacji transportu kolejowego
RoboShepherd - zautomatyzowany system hodowli i wypasu zwierząt
Usprawnienie systemów wykrywania i rozpoznawania tablic rejestracyjnych z wykorzystaniem głębokiego uczenia.
Wykrywacz fałszywych wiadomości
Głębokie uczenie do klasyfikacji obrazów w Pythonie za pomocą CNN
Samochody autonomiczne
Clearview AI
Platforma dla inteligencji usytuowanej
Sztuczny nos
CoModGAN: uzupełnianie obrazów oparte na sztucznej inteligencji
Wydajne rozpoznawanie twarzy przy użyciu regularnego, adaptacyjnego, nielokalnego kodowania rzadkiego
System pozycjonowania ciała: GPS dla przestrzeni somatosensorycznej
AI4DI
ChemLife
POWSTAĆ
BEZSENS
ChipSztuczna inteligencja
KLASYFIKACJA WIDEO Z WYKORZYSTANIEM TECHNIKI GŁĘBOKIEGO UCZENIA
PRZEWIDYWANIE ZDARZEŃ DROGOWYCH W FILMACH DROGOWYCH Z WYKORZYSTANIEM GŁĘBOKIEGO UCZENIA
GENEROWANIE PODPISÓW POD OBRAZAMI PRZY UŻYCIU TECHNIKI GŁĘBOKIEGO UCZENIA
INTELIGENTNA RYBA
CZAPLA

Nr projektu BG05M2OP001-1.002-0023 - Centrum Kompetencyjne "Inteligentne systemy i technologie mechatroniczne, ekologiczne i energooszczędne "50. Projekt nr 777720 Komisji Europejskiej H2020 Cyber-Fizyczne Systemy Rehabilitacji Społecznej w Edukacji Specjalnej (CybSPEED)"

Przydatna alokacja zasobów przetwarzania brzegowego na potrzeby autonomicznej jazdy

Zaawansowane metody wyboru cech dla danych o dużych wymiarach

Inteligentne zarządzanie siecią komórkową 5G w oparciu o kompleksowe uczenie z głębokim uczeniem

LINIOWA OCENA POROWATOŚCI ELEKTROD AKUMULATORA LITOWO-JONOWEGO PRZY UŻYCIU ALGORYTMÓW UCZENIA MASZYNOWEGO

ANALIZA WPŁYWÓW ŚRODOWISKA NA URZĄDZENIA ENERGETYKI

METODAMI SZTUCZNEJ INTELIGENCJI I CHMURY OBLICZENIOWEJ (ARIEN)

Agentowe modelowanie rozkładu widma w kognitywnych sieciach radiowych

INTELIGENTNE ZARZĄDZANIE PRZEPIĘCIEM PRACY W CHMURZE NA POTRZEBY DYNAMICZNEGO WDRAŻANIA APLIKACJI ZOPTYMALIZOWANYCH POD KĄTEM METRYK (ICONTROL)

Inteligentne dynamiczne zarządzanie dostępem do widma dla przyszłych kognitywnych sieci komunikacyjnych

DisAI: Poprawa doskonałości naukowej KInIT w zakresie sztucznej inteligencji i technologii językowych w celu zwalczania dezinformacji

AI4Europe: ujednolicona platforma na rzecz rozwoju europejskich badań akademickich i przemysłowych w dziedzinie sztucznej inteligencji

ZDOLNY

Nethone ATO - sztuczna inteligencja, biometria i zaawansowane profilowanie dla innowacyjnej ochrony kont użytkowników w bankowości elektronicznej

Data Fund 1 - fundusz zależkowy specjalizujący się w technologii big data z głównymi obszarami zainteresowań: branża finansowa (fintech), bezpieczeństwo IT, technologia, SaaS, Internet of Things, Sztuczna inteligencja

Sztuczna inteligencja w badaniach podologicznych usprawni procesy leczenia pacjentów

Zastosowania głębokich i rekurencyjnych sieci neuronowych w akustycznym modelowaniu mowy

Głęboka ekstrakcja zapewniająca niezawodne rozpoznawanie mowy

Sztuczna inteligencja spotyka się z katalizą asymetryczną: nowa ścieżka optymalizacji i odkrywania katalizatorów

HOMER: Zorientowana na człowieka automatyczna obróbka

Nieskończoność w rozumowaniu na temat danych i wiedzy

Metody hipersieci w Meta-Learningu

Głębokie, samoorganizujące się grafy neuronowe

BonsAPP

Platforma sztucznej inteligencji na żądanie

Robotics4EU – Robotyka z udziałem społeczeństwa i dla społeczeństwa – Zwiększanie powszechnego stosowania robotyki w Europie

XMANAI - Wytlumaczalna sztuczna inteligencja produkcyjna

REGULAITE

Główne wnioski

Ich analiza dostarcza następujących odpowiedzi:

Najczęściej powtarzające się tematy to:

Deep Learning: kilka projektów koncentruje się na rozpoznawaniu obrazu i mowy, klasyfikacji obiektów, uzupełnianiu obrazów, wykrywaniu i rozpoznawaniu tablic rejestracyjnych oraz przewidywaniu wypadków drogowych przy użyciu technik głębokiego uczenia.

Inteligentne systemy: wiele projektów ma na celu opracowanie inteligentnych systemów, takich jak autonomiczne roboty dla rolnictwa i hodowli zwierząt, GPS dla przestrzeni somatosensorycznej, inżynieria inteligentnych produktów i usług, inteligentna automatyzacja transportu kolejowego, zarządzanie przepływem pracy w chmurze oraz dynamiczne zarządzanie dostępem do widma dla kognitywnych sieci komunikacyjnych.

Uczenie maszynowe: niektóre projekty są związane z praktycznym szkoleniem z zakresu uczenia maszynowego, analizą danych w biznesie oraz alokacją zasobów przetwarzania brzegowego na potrzeby autonomicznej jazdy.

Sztuczna inteligencja (AI): istnieje kilka projektów skoncentrowanych na sztucznej inteligencji, takich jak sztuczna inteligencja w badaniach podologicznych, sztuczna inteligencja w technologiach językowych oraz ujednolicona platforma na rzecz wspierania europejskich badań akademickich i przemysłowych w dziedzinie sztucznej inteligencji. Niestety, nie sprecyzowano dokładniejszego opisu rzeczywistych metod sztucznej inteligencji.

Computer Vision: projekty związane z widzeniem komputerowym obejmują wizualną inspekcję zespołów mechanicznych opartych na sieciach syjamskich dla chmur punktów 3D oraz klasyfikację wideo z wykorzystaniem technik głębokiego uczenia.

IoT i inteligentne budynki: niektóre projekty są związane z rozwojem inteligentnych budynków z wykorzystaniem IoT, szkoleniami ECVET dla operatorów inteligentnych budynków z obsługą IoT oraz centrum kompetencyjnym w zakresie inteligentnych systemów i technologii mechatronicznych, ekologicznych i energooszczędnych.


Rozpoznawanie mowy: niektóre projekty koncentrują się na rozpoznawaniu mowy, na przykład zastosowania głębokich i rekurencyjnych sieci neuronowych w akustycznym modelowaniu mowy oraz głębokiej ekstrakcji w celu niezawodnego rozpoznawania mowy.

Modelowanie oparte na agentach: jeden projekt wykorzystuje modelowanie oparte na agentach do dystrybucji widma w kognitywnych sieciach radiowych.

Chmura obliczeniowa: chmura obliczeniowa jest wykorzystywana w niektórych projektach do zarządzania przepływem pracy w chmurze i analizy wpływu środowiska na urządzenia energetyczne.

3.6. Kto jest głównym partnerem (koordynatorem) w tym programie naukowym? Nazwa firmy, wspólnoty, organizacji państwowej lub naukowej, uczelni?

Szóste pytanie ankiety dotyczy nazwiska głównego koordynatora. Numery 63 kwestionariuszy zostały rozdzielone w następujący sposób: Uniwersytet 34, Akademia Nauk 6, Inne 24. Wyniki przedstawiono poniżej.



Opis danych:

Z danych badawczych wynika, że większość koordynatorów projektów zapewniły uniwersytety lub wydziały, a następnie różne instytuty i firmy.

Dyskusja:

Ponieważ respondenci pochodzili z uczelni wyższych, logiczne jest, że główny koordynator większości projektów pochodził z uczelni wyższych, wyniki mogą być różne, gdy firmy udzielają odpowiedzi.

Główne wnioski:

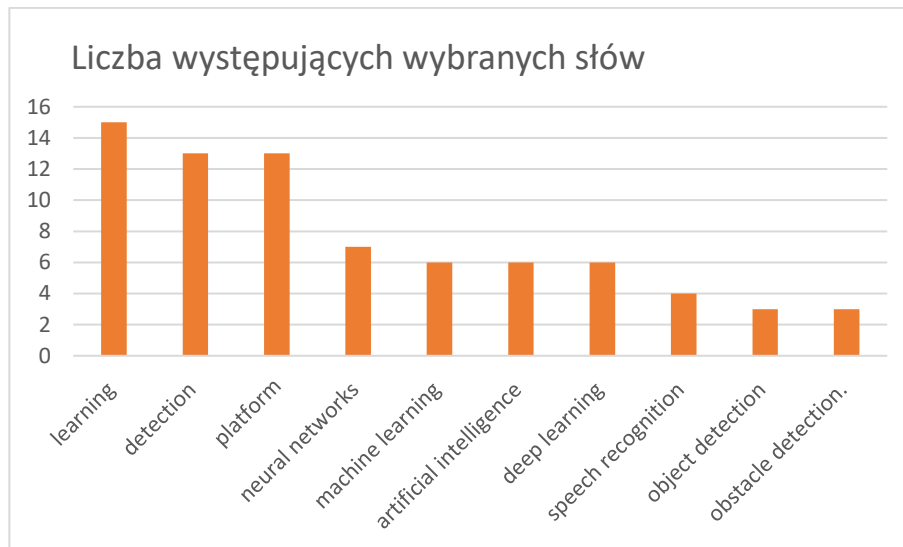
- Firmy biorące udział w programie były dość zróżnicowane, tylko Microsoft został wymieniony więcej razy (3 razy), inne uczestniczące firmy wahały się od Massachusetts General Hospital po FBI.

3.7. Cel projektu

Siódme pytanie ankiety dotyczy celu projektu. Cele 63 kwestionariuszy obejmowały głównie następujące tematy z liczby słów:

- 15 (1%) Nauka
- 13 (1%) platforma
- 7 (2%) sieci neuronowych
- 6 (2%) uczenie maszynowe
- 6 (2%) sztuczna inteligencja
- 6 (2%) głębokie uczenie

4 (1%) rozpoznawanie mowy
3 (1%) wykrywanie obiektów
3 (1%) wykrywanie przeszkód.



Opis danych:

Ze szczegółowego opisu celów najczęściej występują powyższe słowa kluczowe.

Dyskusja:

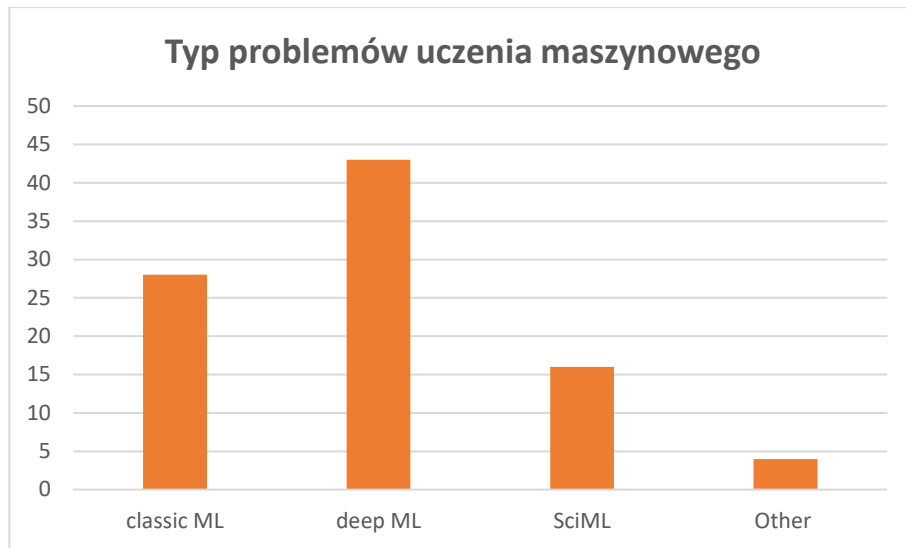
Spośród metod, które są najczęściej spotykane, popularne cele obejmują rozpoznawanie mowy, wykrywanie obiektów i wykrywanie przeszkód.

Główne wnioski:

- Wiele projektów dotyczy opracowania platformy do dalszego wykorzystania, ale większość bezpośrednich zastosowań dotyczy uczenia maszynowego, czyli głębokich sieci neuronowych, głównie do rozwiązywania problemów związanych z przetwarzaniem wizualnym i problemami robotyki.

3.8. Rodzaj problemów związanych z uczeniem maszynowym

Ósme pytanie ankiety dotyczy rodzaju problemów związanych z uczeniem maszynowym. Numery 63 kwestionariuszy zostały rozłożone w następujący sposób: klasyczne ML 28/59 (47,46%), głębokie ML 43 / 59 (72,88%), SciML 16 / 59 (27,12%), Inne 4 / 59 (6,78%). Druga odpowiedź obejmowała 2 n/d, 1 wytłumaczalną sztuczną inteligencję i 1 sztuczną sieć neuronową (ANN). Wyniki przedstawiono poniżej.

**Opis danych:**

Z danych badawczych wynika, że 59 z 64 projektów dotyczy uczenia maszynowego.

Dyskusja:

Prawie dwie trzecie projektów wykorzystuje głębokie uczenie maszynowe. Ponieważ SciML może obejmować również sieci neuronowe, zaangażowanie sieci neuronowych w projekty jest jeszcze większe.

Główne wnioski:

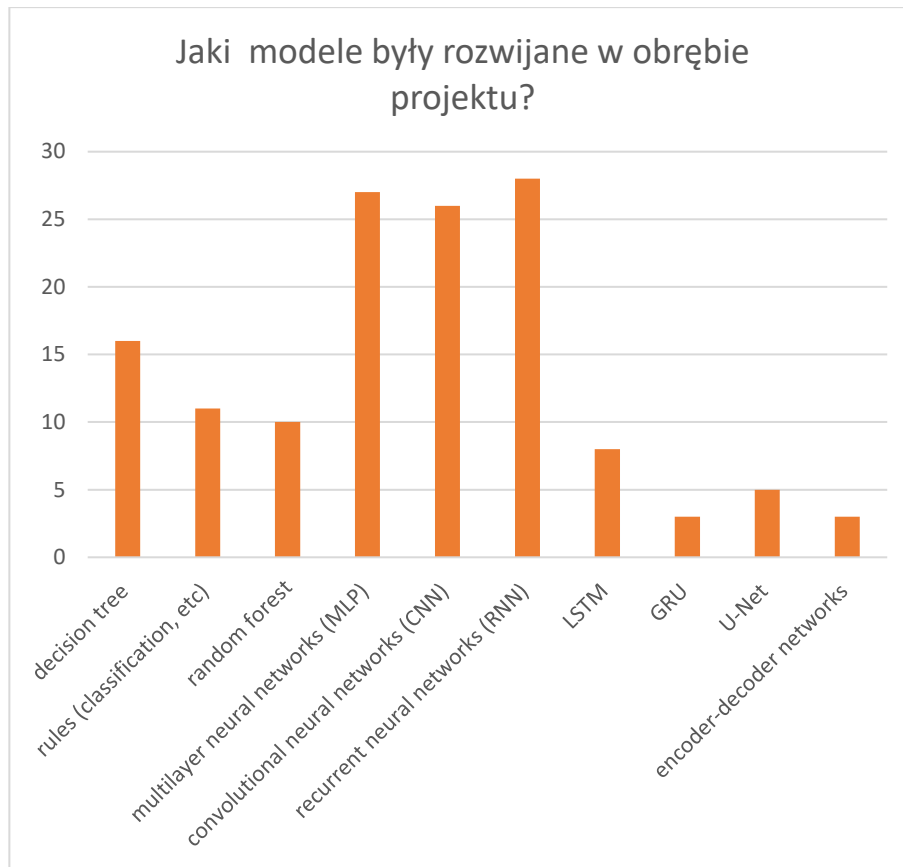
- Uczenie maszynowe, czyli głębokie sieci neuronowe, dominują w projektach.

3.9. Jakie modele zostały opracowane (zbadane) w ramach projektów?

Dziewiąte pytanie ankiety dotyczy modeli. Spośród 63 kwestionariuszy 53 zawierało następujące metody uczenia maszynowego:

1. Drzewo decyzyjne 16 / 53 (30,19%)
2. Zasady (klasyfikacja, kojarzenie itp.) 11 / 53 (20,75%)
3. Losowy las 10 / 53 (18,87%)
4. wielowarstwowe sieci neuronowe (MLP) 27 / 53 (50,94%)
5. konwolucyjne sieci neuronowe (CNN) 26 / 53 (49,06%)
6. rekurencyjne sieci neuronowe (RNN) 28 / 53 (52,83%)
7. LSTM 8 / 53 (15,09%)
8. GRU 3 / 53 (5,66%)
9. U-Net 5 / 53 (9,43%)
10. Sieci koder-dekoder 3 / 53 (5,66%)

Wyniki przedstawiono poniżej.

**Opis danych:**

Z danych badawczych wynika, że 53 z 64 projektów wykorzystuje jedną z wybranych metod uczenia maszynowego, z których 37 zawierało reguły i decyzje oparte na drzewach, podczas gdy większość zawierała jakiś rodzaj sieci, głównie wielowarstwowych, konwolucyjnych i rekurencyjnych.

Dyskusja:

Z liczb jasno wynika, że większość projektów wykorzystywała więcej niż dwie metody.

Główne wnioski:

- Zazwyczaj projekty nie wykorzystują tylko jednej metody uczenia maszynowego.


3.10. Jakie zadania ML zostały rozwiązane (zbadane) w wyniku realizacji projektu?

Dziesiąte pytanie ankiety dotyczy zadań ML. Spośród 63 ankiet 55 dotyczyło następujących zadań ML:

1. Regresja 20/55 (36,36%)
2. Klasyfikacja 29 / 55 (52,73%)
3. Klasteryzacja 18 / 55 (32,73%)
4. Podpisy pod obrazami 6 / 55 (10,91%)
5. Przetwarzanie języka naturalnego 15 / 55 (27,27%)
6. Rozpoznawanie mowy 12 / 55 (21,82%)
7. Klasyfikacja obrazu 17 / 55 (30,91%)
8. Segmentacja obrazu 12 / 55 (21,82%)
9. Inne 9 / 55 (16,36%)

Inne obejmują wykrywanie obiektów na obrazach, projektowanie sterowane przez sztuczną inteligencję i późniejszą walidację eksperymentalną, przewidywanie trajektorii ewolucji profilu behawioralnego użytkownika w czasie, interfejs czujników zainstalowany zarówno na platformie robotycznej, jak i w infrastrukturze drogowej, Analogowe macierze poprzeczek umożliwiają energooszczędne przetwarzanie sygnałów synaptycznych z liniowym skalowaniem na rozmiar sieci neuronowej, System pozycjonowania ciała (BPS), Klasyfikacja chmur punktów 3D i dwukrotnie nie dotyczy.

Wyniki przedstawiono poniżej.



Opis danych:

Z danych badawczych wynika, że 55 z 64 projektów dotyczy jednego z wybranych zadań uczenia maszynowego, w większości przypadków dotyczyło to więcej niż dwóch zadań.

Dyskusja:

Z liczb jasno wynika, że większość projektów wykorzystywała więcej niż dwie metody.

Główne wnioski:


- Rozwiązano zadania związane z klasyfikacją, regresją, klastrowaniem, językiem i obrazem.

3.11. Rozpoczęcie projektu

Jedenaste pytanie ankiety dotyczy rozpoczęcia projektu. Spośród 63 kwestionariuszy 56 dostarczyło następujących danych:

Rok	Liczba projektów
2023	4
2022	12
2021	10
2020	6
2019	8
2018	8
2017	1
2016	4
2015	1
2014	1
2013	0
2012	0
2011	1

Wyniki przedstawiono poniżej.



Opis danych:

Z danych badawczych wynika, że w ciągu ostatnich 5 lat rozpoczęto 46 z 56 projektów.

Dyskusja:

Projekty z ankiet są stosunkowo nowe.

Główne wnioski:


- Kwestionariusze opisywały istotne nowe projekty.

3.12. Zakończenie projektu

Jedenaste pytanie ankiety dotyczy zakończenia projektu. Spośród 63 kwestionariuszy 56 dostarczyło następujących danych:

Rok	Liczba projektów
2016	1
2018	1
2019	3
2020	2
2021	2
2022	12
2023	19
2024	3
2025	6
2026	3
2027	1
2028	1

Wyniki przedstawiono poniżej.



Opis danych:

Z danych badawczych wynika, że do tej pory zakończono 21 z 56 projektów.

Dyskusja:

Projekty z ankiet w większości nie są jeszcze ukończone.

Główne wnioski:

- Ankiety opisywały głównie projekty będące jeszcze w toku.

3.13. Hiperłącze do organizacji

Z liczby 63 kwestionariuszy 51 podało hiperłącze do organizacji.

3.14. Hiperłącze do projektu

Spośród 63 kwestionariuszy 54 dostarczyło hiperłącze do projektu.


3.15. Osiągnięte rezultaty projektu

Spośród 63 ankiet 52 zawierały opisy osiągniętych wyników. Ponieważ jednak większość projektów nie została jeszcze ukończona, osiągnięte rezultaty polegały głównie na opublikowanych artykułach lub opisach usprawnień. Nie wspomniano o żadnym patencie ani działającym rozwiązaniu na poziomie przemysłowym.

3.16. Wykorzystane biblioteki (frameworki) sztucznej inteligencji

Szesnaste pytanie ankiety dotyczy wykorzystywanych bibliotek AI. Z liczby 63 kwestionariuszy 48 udzieliło odpowiedzi: TensorFlow 25 / 48 (52.08%), keras 16 / 48 (33.33%), scikit-ucz się 16 / 48 (33.33%), Pozostałe 13 / 48 (27.08%). Drugi obejmował 4x CUDA, kiedyś Pytorch, bibliotekę Open source Computer Vision (OpenCV) i open3D, oraz 6x N/A.

Wyniki przedstawiono poniżej.



Opis danych:

Według danych badawczych największą popularnością cieszy się TensorFlow.

Dyskusja:


Spośród 48 odpowiedzi, 42 korzystały z otwartego oprogramowania, pozostałe nie zostały określone.

Główne wnioski:

- Większość przypadków korzysta z otwartych bibliotek oprogramowania.

3.17. Jakie języki programowania zostały użyte?

Siedemnaste pytanie ankiety dotyczy używanych języków programowania. Z liczby 63 kwestionariuszy odpowiedzi udzieliły 52: Python 42 / 52 (80,77%), R 9 / 52 (17,31%), Java 17 / 52 (32,69%), C++ 25 / 52 (48,08%), Inne 8 / 52 (15,38%). Drugi obejmował JavaScript, JSON, C, LabView G, ROS i 3 x N/A. Wyniki przedstawiono poniżej.

**Opis danych:**

Według danych badawczych najpopularniejszy jest Python, a następnie C++.

Dyskusja:

Spośród 52 odpowiedzi, 42 używały Pythona, jednak wielokrotnie używano więcej niż jednego języka.

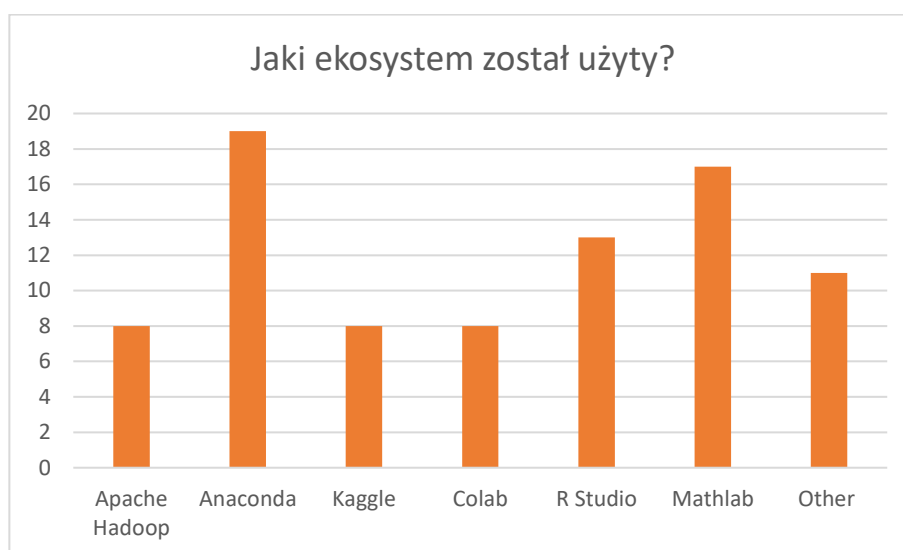
Główne wnioski:

- Python jest najbardziej popularny.

3.18. Jaki ekosystem został wykorzystany?

Osiemnaście pytanie ankiety dotyczy wykorzystywanego ekosystemu. Z liczby 63 ankiet 49 udzieliło odpowiedzi: Apache Hadoop 8 / 49 (16.33%), Anaconda 19 / 49 (38.78%), Kaggle 8 / 49 (16.33%), Colab 8 / 49 (16.33%), R Studio 13 / 49 (26.53%), Matlab 17 / 49 (34,69%), inne 11 / 49 (22,45%). Drugi obejmował Node-RED, CUDA, OpenModelica, LabView, 2x ROS, 5 x N/A.

Wyniki przedstawiono poniżej.



Opis danych:

Według danych badawczych najpopularniejsza jest Anaconda, a następnie Matlab.

Dyskusja:


Spośród 49 odpowiedzi, 19 używało Anakondy, jednak wielokrotnie użyto więcej niż jednego ekosystemu.

Główne wnioski:

- Najpopularniejsza jest anakonda.

3.19. Liczba uczestników projektu

Dziewiętnaste pytanie ankiety dotyczy liczby uczestników. Odpowiedzi udzieliło 48 z 63 kwestionariuszy. Histogram przedstawiono poniżej.

**Opis danych:**

Z danych badawczych wynika, że w większości projektów bierze udział od 1 do 6 uczestników.

Dyskusja:

Największą popularnością cieszą się małe projekty.

Główne wnioski:

- 10 projektów ma tylko jednego uczestnika, z drugiej strony jeden projekt ma 50 uczestników.

20. Nazwy i linki do każdego partnera w projekcie

Spośród 63 ankiet 46 zawierało nazwy i powiązania partnerów.

21. RODO: Wypełniając i przesyłając niniejszy formularz, potwierdzasz, że masz ukończone 18 lat i wyrażasz zgodę na przetwarzanie danych osobowych (e-mail) podanych przez Ciebie za pośrednictwem formularza w związku z celami projektu 2022-1-PL01-KA220-HED-000088359 "The Future is in Applied Artificial Intelligence" (FAAI) w ramach programu Erasmus+.

Z liczby 63 ankiet wszystkie zsumowane.

4. Wnioski

W dziedzinie sztucznej inteligencji kluczowa jest analiza kompetencji, umiejętności twardych i miękkich, które studenci powinni posiadać, aby odnieść sukces w tej szybko rozwijającej się branży. Jednym z ważnych aspektów tej analizy jest treść modułów szkoleniowych, które

powinny być zaprojektowane tak, aby odzwierciedlały najważniejsze obszary uczenia maszynowego, na które jest obecnie zapotrzebowanie na rynku pracy.

Na podstawie przeprowadzonej analizy kwestionariuszy projektowych widać, że znaczna część treści szkoleń AI powinna być poświęcona tematom głębokiego uczenia się sieci neuronowych. Dlatego instruktorzy powinni przeznaczyć około połowy treści kursu na ten obszar, aby upewnić się, że uczestnicy dobrze rozumieją ten krytyczny aspekt uczenia maszynowego.

Ponadto projekty były w dużym stopniu skoncentrowane na problemach związanych z uczeniem maszynowym, w szczególności w przetwarzaniu obrazów, klasyfikacji, regresji, klastryzacji i przetwarzaniu języka naturalnego. W związku z tym studenci powinni być zorientowani na te obszary, aby upewnić się, że są wyposażeni w umiejętności niezbędne do sprostania rzeczywistym wyzwaniom w branży.

Warto również zauważyć, że w projektach nie wspomniano o reprezentacji wiedzy i wnioskowaniu, strategiach planowania i wyszukiwania, systemach eksperckich i logice rozmytej. Dlatego instruktorzy nie powinni poświęcać dużo czasu na prezentowanie tych obszarów kursantom, a ich zastosowania powinny być zminimalizowane w treści kursu.

Co więcej, biblioteki sztucznej inteligencji, które zostały wykorzystane w projektach, były głównie open source, w tym TensorFlow, Keras, scikit-learn i CUDA. W związku z tym studenci nie powinni być zachęceni do korzystania z rozwiązań biznesowych typu close-source, takich jak IBM, w swoich projektach lub ćwiczeniach. Należy podkreślić, że rozwiązania open source dominują obecnie w dziedzinie sztucznej inteligencji, a studenci powinni być szkoleni w zakresie efektywnego korzystania z nich.

Wreszcie, ważne jest, aby wybrać odpowiedni język programowania do szkolenia studentów, a Python wyróżnia się jako najbardziej odpowiedni język do tego celu. Python to bardzo wszechstronny język z szeroką gamą bibliotek i narzędzi, które sprawiają, że jest idealnym wyborem do tworzenia aplikacji AI. Dlatego instruktorzy powinni nadać priorytet nauczaniu Pythona i upewnić się, że uczniowie mają solidne podstawy w tym języku, zanim przejdą do bardziej zaawansowanych tematów z zakresu sztucznej inteligencji.

Podsumowując, kompetencje, umiejętności twarde i umiejętności miękkie wymagane do osiągnięcia sukcesu w branży sztucznej inteligencji stale ewoluują. Obowiązkiem nauczycieli jest analizowanie aktualnych trendów i wymagań w branży oraz projektowanie kursów, które zapewniają uczniom umiejętności niezbędne do odniesienia sukcesu w tej dziedzinie. Nadając priorytet modułom uczenia się głębokich sieci neuronowych, problemom uczenia maszynowego, rozwiązaniom open source i językowi programowania Python, uczniowie mogą być wyposażeni w umiejętności radzenia sobie z rzeczywistymi wyzwaniami w branży sztucznej inteligencji.