

## Uczenie maszynowe - przedmioty specjalnościowe

**WYDZIAŁ:** Wydział Elektroniki, Telekomunikacji i Informatyki  
**KIERUNEK:** Informatyka  
**SPECJALNOŚĆ:** Uczenie maszynowe  
**poziom kształcenia:** II stopnia  
**profil:** ogólnoakademicki  
**forma studiów:** stacjonarne

nazwa zajęć	forma zaliczenia	liczba godzin						liczba punktów ECTS
		w	ć	l	p	s	razem	
<b>Semestr 1</b>								
Zaawansowane przygotowanie danych w uczeniu maszynowym	Z	15	0	0	15	0	30	2
Metody sztucznej inteligencji	Z	15	0	30	0	0	45	3
Etyka w uczeniu maszynowym	Z	15	0	0	0	15	30	2
Uczenie maszynowe	E	30	0	15	0	0	45	3
Uczenie maszynowe w badaniach Ziemi	Z	15	0	15	0	0	30	2
Przedmiot uzupełniający dla specjalności Uczenie maszynowe							45	3

<b>Semestr 2</b>								
Sieci samouczące się	Z	15	0	30	0	0	45	3
Uczenie głębokie	E	30	0	15	0	0	45	4
Odkrywanie wiedzy i systemy rekomendacyjne	Z	30	0	15	15	0	60	4
Przetwarzanie multimediów w systemach decyzyjnych	Z	15	0	30	0	0	45	3
Głębokie przetwarzanie tekstu i sygnału mowy	Z	15	0	30	0	0	45	3

<b>Semestr 3</b>								
Zaawansowane architektury sieci neuronowych	Z	15	0	0	30	0	45	3
Optymalizacja struktur i obliczeń w sieciach neuronowych	Z	15	0	15	15	0	45	3

<b>Zaawansowane przygotowanie danych w uczeniu maszynowym</b>		Wymiar (godz.)
<b>Wykłady</b>		
1	Wprowadzenie do algorytmów uczenia maszynowego jako „czarnej skrzynki”	1
2	Rodzaje danych wejściowych oraz wyjściowych w uczeniu maszynowym	1
3	Źródła danych, dobre praktyki kontaktów z klientem/użytkownikiem dostarczającym dane	1
4	Selekcja i etykietowanie danych – teoria, typowe praktyki i narzędzia wspomagające	2
5	Przetwarzanie wstępne, normalizacja i augmentacja danych treningowych	2
6	Przygotowanie zbiorów danych uczących, walidacyjnych i testowych	1
7	Metodyka oceny jakości systemów bazujących na uczeniu maszynowym	1
8	Ocena jakości podczas treningu: strata, zbieżność, przetrenowanie, obciążenie a wariancja	2
9	Metryki oceny jakości: klasyfikacja, regresja, detekcja itp.	2
10	Powszechne błędy, dobre praktyki podczas analizy wyników treningu i testowania	1
11	Pomiar jakości w kontekście optymalizacji hiperparametrów oraz walidacji krzyżowej	1
<b>Projekt</b>		
1	Wybór tematu projektu, określenie możliwości i celów	1
2	Zapoznanie i konfiguracja środowiska deweloperskiego i testowego	1
3	Budowa zbioru surowych danych	1
4	Etykietyzacja zbioru danych	2
5	Przetwarzanie wstępne, normalizacja, augmentacja danych	2
6	Budowa zbioru treningowego, walidacyjnego i testowego	1
7	Określenie metryk do pomiaru jakości	1
8	Przeprowadzenie treningu i testowania dla zbioru oryginalnego z wykorzystaniem określonych metryk	2
9	Przeprowadzenie treningu i testowania dla zbioru ulepszanego z wykorzystaniem określonych metryk	2
10	Przeprowadzenie treningu i testowania dla zbioru błędnego z wykorzystaniem określonych metryk	1
11	Analiza wyników, ostateczna ocena jakości algorytmów	1

<b>Metody sztucznej inteligencji</b>		Wymiar (godz.)
<b>Wykłady</b>		
1	Analizy dyskryminacyjne	1
2	Walidacja krzyżowa i bootstrap	1
3	Logika rozmyta FL	1
4	Zbiory przybliżone RS	2
5	Hybrydy FL i RS	1
6	Algorytmy genetyczne	2
7	Ukryte modele markowa	1
8	Logiki wielowartościowe	1
9	Teoria dowodu Dempstera-Shafera	1
10	Rozwinięcie drzew decyzyjnych: bagging, adaptive boosting, kaskady klasyfikatorów (np. kaskada Haara)	1
11	Mieszanki gaussowskie (GMM)	1
12	Regresja brzegowa i lasso	1
13	Statystyczne testowanie hipotez	1
<b>Laboratoria</b>		
1	Analizy dyskryminacyjne	2
2	Walidacja krzyżowa i bootstrap	2
3	Logika rozmyta FL	2
4	Zbiory przybliżone RS	2
5	Hybrydy FL i RS	2
6	Algorytmy genetyczne	4
7	Ukryte modele markowa	2
8	Logiki wielowartościowe	2
9	Teoria dowodu Dempstera-Shafera	2
10	Drzewa decyzyjne	2
11	Rozwinięcie drzew decyzyjnych, kaskady klasyfikatorów (np. kaskada Haara)	2
12	Mieszanki gaussowskie (GMM)	2
13	Regresja brzegowa i lasso	2
14	Statystyczne testowanie hipotez	2

<b>Etyka w uczeniu maszynowym</b>		Wymiar (godz.)
<b>Wykłady</b>		
1	Etyka w projektach informatycznych i inżynierskich	2
2	Rodzaje licencji w publicznych zbiorach danych	1
3	Rejestracja danych wrażliwych osób (wizerunek, głos) w świetle RODO	1
4	"Cyfrowe nierówności". Niezbilansowane zbiory danych (dataset bias, methods for dealing with class imbalance, long-tail recognition, rozpoznawanie "mniejszościowych" klas).	1
5	Bezpieczeństwo w AI (metody oszacowania niepewności, błędne detekcje, model robustness).	1
6	Prywatność w AI. Algorytmy zapewniające "prywatność" dla użytkowników dostarczających dane (differential privacy, federated learning).	1
7	Odpowiedzialność w uczeniu nadzorowanym, nienadzorowanym i zastosowaniach modeli wstępnie wytrenowanych	1
8	Wyjaśnialność i interpretowalność decyzji sztucznej inteligencji	2
9	Zaufanie do sztucznej inteligencji (trustworthy AI)	1
10	Odpowiedzialne zarządzanie danymi: integralność, autentyczność i wiarygodność danych	2
11	Respektowanie, rozumienie i przyswajanie norm w uczeniu maszynowym (modele teoretyczne, behawioralne i hybrydowe)	2
<b>Seminaria</b>		
1-15		15

<b>Uczenie maszynowe</b>		Wymiar (godz.)
<b>Wykłady</b>		
1	Wprowadzenie do uczenia maszynowego (czym jest uczenie maszynowe, klasyfikacje metod uczenia maszynowego)	1
2	Metody pozyskiwania i przygotowywania danych: oczyszczanie danych, transformacje danych, standaryzacja i normalizacja danych	1
3	Metody pozyskiwania i przygotowywania danych: integracja i redukcja danych	1
4	Metody redukcji wielowymiarowości (m.in. PCA, ICA, itp.)	2
5	Metody reprezentacji danych dla potrzeb uczenia maszynowego	1
6	Proces pozyskiwania wiedzy z danych	1
7	Metody generacji charakterystyk uogólniających	1
8	Metody indukcji reguł i parametry oceny reguł	2
9	Metody klasyfikacji (wprowadzenie) i metody oceny jakości klasyfikacji (miary, itp.)	1
10	Metody klasyfikacji nadzorowanej (drzewa decyzyjne, lasy losowe)	2
11	Metody klasyfikacji nadzorowanej (od Bayesa do klasyfikacji minimalnoodległościowej)	2
12	Metody klasyfikacji nadzorowanej (SVM)	1
13	Metody klasyfikacji nienadzorowanej (k-means, ISO-DATA, itp.)	2
14	Metody optymalizacji – charakterystyka	1
15	Metody optymalizacji – metody gradientowe	2
16	Regresja liniowa	1
17	Regresja logistyczna	2
18	Sztuczne sieci neuronowe – wprowadzenie, perceptron, uczenie	2
19	Sztuczne sieci neuronowe – MLP, funkcje aktywacji, uczenie cz.1.	2
20	Sztuczne sieci neuronowe – MLP cz.2.	2
<b>Laboratoria</b>		
1	Klasyfikacja nadzorowana – wykorzystanie i porównanie różnych klasyfikatorów wraz z oceną ich jakości	3
2	Klasyfikacja nienadzorowana - wykorzystanie i porównanie różnych klasyfikatorów wraz z oceną ich jakości	3
3	Regresja liniowa i logistyczna	3
4	Metoda gradientu prostego, perceptron	3
5	Sztuczne sieci neuronowe	3

<b>Uczenie maszynowe w badaniach Ziemi</b>		Wymiar (godz.)
<b>Wykłady</b>		
1	Metody teledetekcyjne w badaniach Ziemi. Obrazowanie satelitarne, sondowanie sonarowe	2
2	Przykłady zastosowań sztucznej inteligencji i uczenia maszynowego w badaniach Ziemi.	1
3	Metody AI i ML wykorzystywane w badaniach Ziemi	1
4	Charakterystyka danych obrazowych pochodzących z teledetekcji	1
5	Źródła satelitarnych danych teledetekcyjnych	1
6	Metodyka opracowywania modeli klasyfikacji i regresji dla danych teledetekcyjnych	2
7	Weryfikacja modeli dla danych teledetekcyjnych	1
8	Współczesne najlepsze praktyki w uczeniu maszynowym dla teledetekcji	2
9	Charakterystyka danych sonarowych. Etapy i metody ich wstępnego przetwarzania	2
10	Uczenie maszynowe w badaniu ekosystemów morskich	2
<b>Laboratoria</b>		
1	Wprowadzenie do laboratorium. Omówienie treści zajęć i zasad pracy 1	1
2	Przetwarzanie danych teledetekcyjnych różnego typu 2	2
3	Klasyfikacja i regresja pikselowa 2	2
4	Klasyfikacja pikselowa z informacją z pikseli sąsiadujących 2	2
5	Zaawansowane modele ML dla danych teledetekcyjnych cz. 1 2	2
6	Zaawansowane modele ML dla danych teledetekcyjnych cz. 2 2	2
7	Dane sonarowe i ich przetwarzanie 2	2
8	ML w badaniu i klasyfikacji dna morskiego 2	2

Sieci samouczące się		Wymiar (godz.)
	Wykłady	
1	Omówienie zasad prowadzenia wykładu i laboratorium. Omówienie katalogu pojęć i podstaw matematycznych niezbędnych do przyswojenia zagadnień poruszanych podczas wykładu.	1
2	Omówienie koncepcji uczenia ze wzmacnianiem. Różnice i możliwości w stosunku do metod nadzorowanych i nienadzorowanych. Przykłady typowych zastosowań i ograniczenia.	1
3	Podstawy uczenia ze wzmacnianiem. Wprowadzenie pojęć wykorzystywanych w uczeniu ze wzmacnianiem. Wprowadzenie do zasad gromadzenia doświadczenia i wiedzy w uczeniu ze wzmacnianiem.	1
4	Omówienie procesu decyzyjnego Markova	1
5	Omówienie maksymalnego zwrotu (Return) i oczekiwanego zwrotu (Value function)	1
6	Omówienie równania Bellmana	1
7	Omówienie procesu uczenia ze wzmacnianiem. Prediction problem vs Control problem.	1
8	Techniki uczenia ze wzmacnianiem cz. I. Dylemat Explore-Exploit. Metoda Epsilon-Greedy. Przykłady zastosowań i ograniczenia.	1
9	Techniki uczenia ze wzmacnianiem cz. II. Metoda Monte Carlo. Metody Temporal-Difference. Metoda Q-Learning. Przykłady zastosowań i ograniczenia.	1
10	Definicja zagadnienia praktycznego do rozwiązania z wykorzystaniem uczenia ze wzmacnianiem.	1
11	Dobór optymalnego modelu uczenia ze wzmacnianiem do rozwiązywanego zagadnienia praktycznego. Definicja agenta, środowiska i epizodu. Definicja stanu i akcji. Definicja nagrody.	1
12	Dobór optymalnego modelu sztucznej sieci neuronowej do rozwiązywanego zagadnienia praktycznego. Rodzaje warstw w sieciach neuronowych. Rodzaje architektur sieci neuronowych. Funkcje aktywacji. Funkcje straty. Dane wejściowe i wyjściowe.	1
13	Przypomnienie problemów uczenia sztucznych sieci neuronowych (przeuczanie, brak postępów). Zasady i techniki doboru optymalnej wielkości modelu. Zasady i techniki niwelujące problem przeuczania i poprawiające zdolność sieci neuronowej do generalizacji (Regularyzacja. Dropout).	1
14	Podsumowanie. Omówienie i porównanie wyników projektów laboratoryjnych.	1
15	Trendy i osiągnięcia światowe (DeepMind. OpenAI). Alternatywne metody samouczenia.	1
	Laboratoria	
1-15		30

<b>Uczenie głębokie</b>		Wymiar (godz.)
	Wykłady	
1	Wprowadzenie do uczenia głębokiego	1
2	Operacja splotu i jej znaczenie	1
3	Warstwy splotowe i ich wersje	2
4	Splotowe sieci neuronowe (rodzaje warstw, uczenie)	2
5	Klasyfikacja z wykorzystaniem sieci splotowych	2
6	Problemy z uczeniem sieci głębokich (przeuczenie, zanikający gradient, itp.)	1
7	Metody przeciwdziałania problemom związanym z uczeniem sieci głębokich (regularyzacja, augmentacja, dropout, early stopping, itp.)	2
8	Uczenie z przeniesieniem (transfer learning)	2
9	Modele RNN	2
10	Rozwój modeli RNN (m.in. LSTM itd.)	2
11	Zastosowaniem modeli RNN w NLP	2
12	Modele generacyjne	2
13	Autoenkodery	2
14	Zastosowanie modeli generacyjnych	1
15	Uczenie ze wzmocnieniem	2
16	Uczenie ze wzmocnieniem z wykorzystaniem modeli głębokich cz.1	2
17	Uczenie ze wzmocnieniem z wykorzystaniem modeli głębokich cz.2	2
	Laboratoria	
1	Uczenie sieci splotowych	3
2	Wykorzystanie sieci splotowych i rozwiązywanie problemów	3
3	Uczenie modeli RNN	3
4	Modele generacyjne	3
5	Uczenie ze wzmocnieniem	3

<b>Odkrywanie wiedzy i systemy rekomendacyjne</b>		Wymiar (godz.)
	Wykłady	
1	Eksploatacja i przygotowanie danych	2
2	Klasyfikacja	2
3	Grupowanie	1
4	Metody zespołowe (ensemble learning)	1
5	Inne metody eksploracyjnej analizy danych	1
6	Analiza szeregów czasowych	2
7	Wykrywanie anomalii	2
8	Podstawy analizy tekstu	2
9	Rodzaje i identyfikacja fałszywych wiadomości (fake news)	2
10	Definicja i rodzaje systemów rekomendacyjnych	1
11	Problemy występujące w systemach rekomendacyjnych	1
12	Wspólna filtracja (Collaborative Filtering)	3
13	Systemy rekomendacji oparte na treści (Content-based Recommender Systems)	1
14	Modelowanie użytkownika	1
15	Kontekstowe systemy rekomendacji	2
16	Sieci i rekomendacje w sieciach	2
17	Inne rodzaje systemów rekomendacji	1
18	Uczenie maszynowe rankingu (Learning to Rank)	1
19	Ocena systemów rekomendacji	2
	Laboratoria	
1	Wprowadzenie	1
2	Klasyfikacja, grupowanie i metody zespołowe	2
3	Analiza szeregów czasowych	2
4	Wykrywanie anomalii	2
5	Podstawy analizy tekstu	2
6	Wspólna filtracja i ocena systemów rekomendacyjnych	2
7	Kontekstowe systemy rekomendacji	2
8	Rekomendacje w sieciach	2



<b>Przetwarzanie multimediów w systemach decyzyjnych</b>		Wymiar (godz.)
	Wykłady	
1	Wzmacniane drzewa decyzyjne w zastosowaniach	2
2	Przegląd algorytmów uczących się metryk dystansu	3
3	Uczenie wielozadaniowe w widzeniu komputerowym	2
4	Detekcja obiektów (detekcja obiektów, keypoints detection, detekcja 3D). Zastosowania w pojazdach autonomicznych i / lub w medycynie.	1
5	Semantyczna segmentacja (semantic segmentation, instance segmentation). Zastosowania w pojazdach autonomicznych i / lub w medycynie.	1
6	IoT jako źródło danych dla ML/AI	1
7	ML/AI w podejściu chmurowym, usługi ML/AI oferowane przez dostawców	1
8	Praktyczne aspekty stosowania algorytmów uczenia maszynowego (krytyka współczesnych algorytmów uczenia maszynowego, przykłady błędnych predykcji, bezpieczeństwo w AI)	1
9	ML/AI w obszarze automotive, wykorzystanie multimedialnych źródeł informacji do autonomizacji pojazdów - samochodów i urządzeń agro.	2
10	Zastosowania uczenia maszynowego w biometrii	1
	Laboratoria	
1	Omówienie zasad laboratorium, stosowanych praktyk, źródeł danych, narzędzi	2
2	Wzmacniane drzewa decyzyjne w zastosowaniach	4
3	Algorytmy uczące się metryk dystansu	4
4	Uczenie wielozadaniowe w widzeniu komputerowym	4
5	Detekcja obiektów (detekcja obiektów, keypoints detection, detekcja 3D). Zastosowania w pojazdach autonomicznych.	2
6	Semantyczna segmentacja (semantic segmentation, instance segmentation). Zastosowania w medycynie.	2
7	Intepretowalność metod sztucznej inteligencji. Metody wizualizacji decyzji sieci neuronowych.	2
9	ML/AI w podejściu chmurowym, usługi ML/AI oferowane przez dostawców	4
10	Zastosowania uczenia maszynowego w biometrii	4

<b>Głębokie przetwarzanie tekstu i sygnału mowy</b>		Wymiar (godz.)
	Wykłady	
1	Sygnały cyfrowe, reprezentacje, parameryzacja, przetwarzanie.	3
2	Tor foniczny, elementy akustyki mowy	2
3	NLP z wykorzystaniem sieci GPT-2 i GPT-3	1
4	Użycie syntezy mowy opartych o głębokie uczenie typu Tacotron-2 do syntezy mowy	1
5	Synteza mowy w asystentach głosowych, zastosowania eCommerce i eHealth	2
6	Rozpoznawanie mówców z wykorzystaniem głębokiego uczenia	2
7	Detekcja zmanipulowanych treści (Deep Fakes detection, Fake News detection)	2
8	Tłumaczenie maszynowe, generowanie autosugestii, klonowanie głosu	1
9	Detekcja spamu, określanie sentymentu, parsowanie wiadomości, generowanie streszczeń	1
	Laboratoria	
1	Sygnały cyfrowe, reprezentacje, parameryzacja, przetwarzanie.	4
2	Podstawy akustyki mowy, akwizycja sygnału, urządzenia foniczne, tor cyfrowy	4
3	NLP z wykorzystaniem sieci GPT-2 lub GPT-3	4
4	Użycie syntezy mowy opartych o głębokie uczenie typu Tacotron-2 do syntezy mowy	4
5	Rozpoznawanie mówców z wykorzystaniem głębokiego uczenia	2
6	Detekcja zmanipulowanych treści (Deep Fakes detection, Fake News detection)	2
7	Synteza mowy w asystentach głosowych w praktyce	4

<b>Zaawansowane architektury sieci neuronowych</b>		Wymiar (godz.)
	Wykłady	
1	Sieć neuronowa jako graf obliczeniowy – budulce i mechanizmy podstawowe – powtórka	2
2	Przełomowe architektury sieci splotowych – LeNet5, AlexNet, InceptionNet, ResNet	2
3	Warstwy normalizacji: Batch Normalization, Layer Normalization, inne	2
4	Architektury lekkie: MobileNets, ShuffleNet, EfficientNet etc. (GhostNet, TinyNet)	1
5	Przetwarzanie sekwencji i sieci rekurencyjne w wariacie bazowym	1
6	Komórki LSTM, GRU	1
7	Warianty sieci rekurencyjnych do zadań typu many-to-one, one-to-many i many-to-many (seq2seq)	1
8	Architektury do pretrainingu wektorów reprezentujących słowa typu Word2Vec (CBOW, Skip-Gram, FastText)	2
9	Mechanizmy uwagi i architektura Transformer	2
10	Zastosowania Transformerów: ELMo, BERT, GPT	1
	Projekt	
1-15		30

<b>Optymalizacja struktur i obliczeń w sieciach neuronowych</b>		Wymiar (godz.)
	Wykłady	
1	Przerzedzanie sieci neuronowych	2
2	Uczenie maszynowe z zaszumionymi etykietami	2
3	Metody redukcji rozmiaru sieci i przyspieszania obliczeń (overparametrization in neural networks, model quantization, model pruning, knowledge distillation)	2
4	Efektywne architektury sieci neuronowych (specjalizowane architektury, Neural architectural search, Jetson).	2
5	Metody uczenia maszynowego przy ograniczonym zbiorze danych. (Self-supervised learning, transfer learning, zaawansowane augmentacje danych, unsupervised pretraining, licencje na zbiory danych)	1
6	Oszacowanie niepewności w sieciach neuronowych (metody kalibracji sieci neuronowych, test-time dropout, model ensembling, Bayesian networks)	1
7	Zdolności generalizacyjne sieci neuronowych. (model robustness, adversarial examples, out-of-distribution detection, metoda transferu stylów, zaawansowane augmentacje danych)	1
8	Destylacja wiedzy z sieci neuronowych	1
9	Dyskretyzacja modelu sieci neuronowych	1
10	Modele neuronowe pozbawione wag i z współdzieleniem wag	1
11	Sieci kapsułowe (capsule nets)	1
	Laboratoria	
1	Przerzedzanie sieci neuronowych	3
2	Uczenie maszynowe z zaszumionymi etykietami	2
3	Metody redukcji rozmiaru sieci i przyspieszania obliczeń (overparametrization in neural networks, model quantization, model pruning, knowledge distillation)	2
4	Efektywne architektury sieci neuronowych (specjalizowane architektury, Neural architectural search, Jetson)	2
5	Metody uczenia maszynowego przy ograniczonym zbiorze danych. (Self-supervised learning, transfer learning, zaawansowane augmentacje danych, unsupervised pretraining, licencje na zbiory danych)	2
6	Oszacowanie niepewności w sieciach neuronowych (metody kalibracji sieci neuronowych, test-time dropout, model ensembling, Bayesian networks)	2
7	Zdolności generalizacyjne sieci neuronowych. (model robustness, adversarial examples, out-of-distribution detection, metoda transferu stylów, zaawansowane augmentacje danych)	2