Karta modułu/przedmiotu

Wypełnia Zespół Kierunku							
	Nazwa modułu (bloku przedmiotów): **Blok przedmiotów wybieralnych**					Kod modułu: **M19**	
	Nazwa przedmiotu: **Przedmiot dyplomowy wybieralny Uczenie maszynowe**					Kod przedmiotu: ASK-M14, PBD-M14, GKM-M15	
	Nazwa jednostki organizacyjnej prowadzącej przedmiot / moduł: **INSTYTUT INFORMATYKI STOSOWANEJ im. Krzysztofa Brzeskiego**						
	Nazwa kierunku: **INFORMATYKA** (w zakresie: **Administracja systemów i sieci komputerowych, Projektowanie baz danych i oprogramowanie użytkowe, Grafika komputerowa i multimedia**)						
	Forma studiów: **stacjonarne**		Profil kształcenia: **PRAKTYCZNY**			Poziom kształcenia: **STUDIA I STOPNIA**	
	Rok / semestr: **4/8**		Status przedmiotu /modułu: **WYBIERALNY**			Język przedmiotu / modułu: **POLSKI**	
	Forma zajęć	wykład	ćwiczenia	laboratorium	projekt	seminarium	inne (wpisać jakie)
	Wymiar zajęć (godz.)	**15**		**30**			

Koordynator przedmiotu / modułu	dr Katarzyna Wasielewska
Prowadzący zajęcia	dr Katarzyna Wasielewska
Cele kształcenia przedmiotu / modułu	Celem przedmiotu jest rozwinięcie wiedzy i umiejętności wykorzystania metod uczenia maszynowego w praktyce.
Wymagania wstępne	Zaliczone przedmioty: Sztuczna inteligencja

EFEKTY UCZENIA SIĘ		
Nr efektu uczenia się/ grupy efektów	Opis efektu uczenia się	Kod kierunkowego efektu uczenia się
Wiedza		
01	Zna i potrafi scharakteryzować rodzaje uczenia maszynowego	K_W21
02	Zna teoretyczne podstawy metod uczenia maszynowego	K_W21
03	Zna praktyczne zastosowania technik uczenia maszynowego	K_W15
Umiejętności		
04	Potrafi zebrać i opracować dane wykorzystywane do procesu uczenia	K_U18, K_U24
05	Potrafi dobrać i zastosować odpowiednią metodę uczenia maszynowego do danego problemu	K_U17, K_U26
06	Potrafi interpretować wyniki uczenia maszynowego	K_U08, K_U16
Kompetencje społeczne		
07	Rozwiązuje problemy i myśli twórczo	K_K04

08	Przestrzega zasad związanych z wykorzystaniem baz danych	K_K02

TREŚCI PROGRAMOWE

Wykład

1. Wprowadzenie, podstawy uczenia maszynowego, rodzaje i zastosowania
2. Uczenie maszynowe z nadzorem – wprowadzenie. Problemy regresji i klasyfikacji
3. Zasady generalizacji modelu. Over-fitting, under-fitting, podział danych na treningowe i testowe, cross-validation
4. Funkcje kosztu, regularyzacja, algorytm Gradient Descent
5. Regresja logistyczna, metryki błędu klasyfikacji
6. Klasyfikatory Naive Bayes
7. SVMs. Nieliniowość.
8. Drzewa decyzyjne
9. Metoda bagging
10. Metoda boosting
11. Uczenie maszynowe bez nadzoru
12. Redukcja wymiarowości danych
13. Praktyczne zastosowania uczenia maszynowego

Laboratorium

1. Wprowadzenie do analizy danych, analiza statystyczna danych, wizualizacja danych
2. Wprowadzenie do uczenia maszynowego z nadzorem. Zastosowanie algorytmu K-Nearest Neighbour (KNN) do problemu klasyfikacji
3. Model regresji liniowej w uczeniu z nadzorem
4. Algorytm Gradient Descent i jego zastosowanie w regresji liniowej
5. Regresja logistyczna w praktyce
6. Klasyfikator Naive Bayes
7. Klasyfikacja przy pomocy algorytmu SVMs (ang. Support Vector Machines)
8. Implementacja algorytmu drzewa decyzyjnego
9. Bagging, Random Forrest
10. Boosting
11. Klasteryzacja
12. Redukcja wymiarowości danych za pomocą analizy głównych składowych
13. Realizacja projektu finalnego

Na zaliczenie przedmiotu należy wykonać zadanie projektowe i implementację uczenia maszynowego dla wybranego problemu.

Implementacje są wykonywane w języku Python.
Udział zagadnień praktycznych – 100%

Literatura podstawowa	1. M. Szeliga, Praktyczne uczenie maszynowe, wyd. PWN, 2019 2. A. Geron, Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow, wyd. Helion, 2018
Literatura uzupełniająca	1. M. Kirk, Python w uczeniu maszynowym, Promise, 2018 2. Ch. Albon, Uczenie maszynowe w Pythonie. Receptury, wyd. Helion, 2019
Metody kształcenia	wykład informacyjny, doświadczenia w laboratorium

Metody weryfikacji efektów uczenia się		Nr efektu uczenia się/grupy efektów
Wykład – egzamin		01, 02, 03
Laboratorium – zadania praktyczne, końcowe zadanie projektowe		04, 05, 06, 07, 08
Formy i warunki zaliczenia	Zaliczenie laboratorium: ocenę z zadania końcowego, wykonanie poszczególnych zadań na laboratorium i aktywność. Wykład: egzamin w formie testu Na ocenę końcową składa się ocena z egzaminu i ocena z laboratorium. Wynik z egzaminu stanowi 40% oceny końcowej, a laboratorium – 60%. W przypadku uzyskania z laboratorium oceny minimum 4.0, istnieje możliwość zwolnienia z egzaminu. Wówczas oceną końcową będzie ocena z laboratorium. Koordynator przedmiotu może zaliczyć przedmiot na podstawie projektu z dziedziny uczenia maszynowego zrealizowanego w ramach koła naukowego.	

NAKŁAD PRACY STUDENTA		
Rodzaj działań/zajęć	Liczba godzin	
	Ogółem	W tym zajęcia powiązane z praktycznym przygotowaniem zawodowym
Udział w wykładach	15	
Samodzielne studiowanie	13	
Udział w ćwiczeniach audytoryjnych i laboratoryjnych, warsztatach, seminariach	30	30
Samodzielne przygotowywanie się do zajęć	35	35
Przygotowanie projektu / eseju / itp.		
Przygotowanie się do egzaminu / zaliczenia	5	
Udział w konsultacjach	2	
Inne		
ŁĄCZNY nakład pracy studenta w godz.	100	65
Liczba punktów ECTS za przedmiot	**4 ECTS**	
Liczba punktów ECTS przypisana do dyscypliny naukowej	**Informatyka techniczna i telekomunikacja 4 ECTS**	

Liczba punktów ECTS związana z zajęciami praktycznymi	**2,6 ECTS**
Liczba punktów ECTS za zajęcia wymagające bezpośredniego udziału nauczycieli akademickich	**47** **1,9 ECTS**