

POLITECHNIKA KRAKOWSKA IM. TADEUSZA KOŚCIUSZKI

KARTA PRZEDMIOTU

obowiązuje studentów rozpoczynających studia w roku akademickim 2017/2018

Wydział Fizyki, Matematyki i Informatyki

Kierunek studiów: Informatyka

Profil: Ogólnoakademicki

Forma studiów: stacjonarne

Kod kierunku: I

Stopień studiów: II

Specjalności: Informatyka stosowana dla licencjatów

1 INFORMACJE O PRZEDMIOCIE

NAZWA PRZEDMIOTU	Inteligentne narzędzia informatyczne
NAZWA PRZEDMIOTU W JĘZYKU ANGIELSKIM	Intelligent informatics tools
KOD PRZEDMIOTU	WFMiI i oIIS D6 17/18
KATEGORIA PRZEDMIOTU	Przedmioty specjalnościowe
LICZBA PUNKTÓW ECTS	5.00
SEMESTRY	3

2 RODZAJ ZAJĘĆ, LICZBA GODZIN W PLANIE STUDIÓW

SEMESTR	WYKŁAD	ĆWICZENIA	LABORATORIUM	LABORATORIUM KOMPUTERO- WE	SEMINARIUM	PROJEKT
3	30	0	30	0	0	0

3 CELE PRZEDMIOTU

Cel 1 A) Zapoznanie studentów z metodologią związaną z pojęciami, modelami oraz stosowanymi obecnie metodami w celu analizy, klasyfikacji (lub grupowania) istotnych informacji zawartych w olbrzymich zbiorach danych. B) Zapoznanie studentów z preferowanymi zastosowaniami (i wadami) każdego z ważniejszych i efektywniejszych modeli oraz każdej z metod konstrukcji wybranego modelu do klasyfikacji (lub grupowania) oraz ważniejszymi możliwościami oceny jakości modelu w prognozowaniu przyszłych decyzji (klas czy grup). C)

Zapoznanie studentów z olbrzymim arsenałem możliwości wizualizacji najistotniejszych informacji ze zbiorów danych lub wizualizacji informacji otrzymanych z dokonanych przez siebie prognoz, tak, aby nie zostały utracone inne ważne informacje. Zwrócenie uwagi na specyficzne preferowane zastosowania każdej z poszczególnych metod wizualizacji informacji, wynikające z charakterystyki wzorów statystycznych i informatycznych, będących ich podstawą.

Cel 2 Przedstawienie studentom kryteriów służących do dokonywania najodpowiedniejszego dla danego problemu analizy danych wyboru metody konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup) oraz sposobów jego praktycznego zrealizowania i weryfikacji. Omówienie dostępnych miar jakości skonstruowanych modeli i ich najodpowiedniejszych zastosowań.

Cel 3 Zapoznanie studentów z rozwijaną przez największe światowe uczelnie - darmową platformą programistyczną R, która powstała w celu szybszego, łatwiejszego i efektywniejszego zastosowania odpowiednich funkcji spośród dostępnych w niej ponad 3520 gotowych pakietów (około 200 nowych przybywa co kilka miesięcy), realizujących najnowsze i najskuteczniejsze algorytmy związane z analizą, klasyfikacją, grupowaniem i wizualizacją informacji zgromadzonych w olbrzymich zbiorach danych. Platforma ta umożliwia także samodzielne programowanie w języku R.

Cel 4 Nabycie umiejętności pracy w małych zespołach.

4 WYMAGANIA WSTĘPNE W ZAKRESIE WIEDZY, UMIEJĘTNOŚCI I INNYCH KOMPETENCJI

1 Algebra liniowa, Statystyka matematyczna, Programowanie I i II (podstawy programowania, podstawowe typy danych, programowanie w C lub C++); Algorytmy i struktury danych (złożoność asymptotyczna, podstawowe struktury danych (stosy), programowanie dynamiczne).

5 EFEKTY KSZTAŁCENIA

EK1 Wiedza Student będzie potrafił wytłumaczyć pojęcia, modele oraz stosowane obecnie metody służące do analizy, klasyfikacji (lub grupowania) istotnych informacji zawartych w olbrzymich zbiorach danych. Student będzie potrafił wytłumaczyć słabe i mocne strony (predyspozycje) każdego z rozważanych na wykładach modeli oraz każdej z metod analizy i metod konstrukcji wybranego modelu do klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup), a także będzie potrafił wytłumaczyć swój wybór miary, służącej do zweryfikowania jakości dokonanej przez dany model prognozy klasyfikacji (czy grupowania) przyszłych podobnych informacji ze zbiorów danych. Student będzie posiadał wiedzę, jak dokonać najbardziej odpowiedniej dla danego problemu wizualizacji najistotniejszych informacji ze zbiorów danych lub wizualizacji informacji otrzymanych z dokonanych przez siebie prognoz.

EK2 Umiejętności Student będzie posiadał umiejętność najważniejszego dla danego problemu analizy danych wyboru metody konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup) oraz jego praktycznego zrealizowania i weryfikacji, stosując wybrane przez siebie miary jakości.

EK3 Umiejętności Student będzie posiadał umiejętność właściwego wyboru metody wizualizacji i umiejętność jej praktycznego zastosowania dla danego problemu zobrazowania wybranych informacji ze zbiorów danych. Studenci poznają rozwijaną przez największe światowe uczelnie - darmową platformę programistyczną R, powstałą w celu stworzenia możliwości wykonania efektywnej i precyzyjnej analizy, klasyfikacji, grupowania oraz doskonałej wizualizacji informacji zgromadzonych w olbrzymich zbiorach danych, wykorzystując dostępne w R gotowe pakiety (których w R jest już ponad 3520, a co kilka miesięcy przybywa około 200 nowych), realizujących najnowsze i najskuteczniejsze algorytmy i metody, rozwiązywane na uczelniach i w przemyśle. Studenci będą również posiadali umiejętność samodzielnego programowania w języku R.

EK4 Kompetencje społeczne Studenci poznają najnowsze inteligentne techniki informatyczne, stosowane obecnie na świecie przez większość dużych korporacji. Studenci będą często na Laboratoriach razem współpracować w małych zespołach.

6 TREŚCI PROGRAMOWE

LABORATORIUM		
LP	TEMATYKA ZAJĘĆ OPIS SZCZEGÓŁOWY BLOKÓW TEMATYCZNYCH	LICZBA GODZIN
L1	Instalacja środowiska programowego R i jego pakietów. Uzyskanie pomocy w R. Uzyskanie dostępu do danych z innych pakietów. Modyfikowanie zbioru danych. Wczytywanie i zapisywanie plików.	2
L2	Stosowanie poleceń języka R do zamiany typów danych, normalizacja danych, zastosowanie prostych wzorów statystycznych oraz ćwiczenia w celu poznania możliwości wizualizacji danych przy użyciu bogatego środowiska graficznego w R.	2
L3	Przykłady analizowania danych transakcyjnych i tworzenia reguł asocjacyjnych. Obliczanie wsparcia i wiarygodności reguł asocjacyjnych. Zastosowanie funkcji tworzących i analizujących reguły w środowisku programistycznym R (użycie pakietu ARULES).	2
L4	Przykłady zastosowania w R algorytmu k-najbliższych sąsiadów (alg. KNN w pakiecie CLASS) oraz algorytmu naiwnej metody wnioskowania bayesowskiego (funkcja naiveBayes() w pakiecie e1071).	2
L5	Przykłady tworzenia w środowisku programistycznym R sieci bayesowskich (użycie pakietu BNLEARN).	2
L6	Przykłady zastosowania w R algorytmów tworzenia drzew klasyfikacyjnych (alg. SPRINT, pakiet RPART, MAP TREE oraz PARTY).	2
L7	Przykłady zastosowania w R algorytmu tworzenia reguł decyzyjnych.	2
L8	Przykłady klasyfikacji danych przy użyciu wielowarstwowej sieci neuronowej poprzez zastosowanie funkcji nnet() dostępnej w pakiecie NNET (lub funkcji train() z pakietu AMORE) w środowisku programistycznym R oraz porównanie uzyskanych wyników z rezultatami otrzymanymi z funkcji knn() (tj. algorytmu k-najbliższych sąsiadów) z pakietu CLASS.	2
L9	Maszyny wektorów podpierających (metoda SVM i przykłady jej zastosowania w R - użycie funkcji svm() z pakietu E1071).	2
L10	Szacowanie jakości klasyfikatorów w R (obliczanie entropii, indeksu Giniego oraz błędu niepoprawnej klasyfikacji dla wcześniej stosowanych klasyfikatorów).	2
L11	Przykłady zastosowania metod bootstrapowych w R (użycie pakietu IPRED lub ADABAG, funkcja bagging() oraz funkcji bootstrap() z pakietu BOOTSTRAP).	2
L12	Przykłady zastosowania metody losowych lasów w R (użycie pakietu randomForest).	2
L13	Przykłady zastosowania metody boosting w R (użycie pakietu MBOOST).	2
L14	Przykłady zastosowania algorytmów grupowania danych opartych na podziałach (partitioning algorithms) w R (użycie podpakietów: PAM, CLARA, CLATIN, CLARANS dostępnych w pakiecie CLUSTER).	2

LABORATORIUM		
LP	TEMATYKA ZAJĘĆ OPIS SZCZEGÓŁOWY BLOKÓW TEMATYCZNYCH	LICZBA GODZIN
L15	Przykłady zastosowania w R hierarchicznych algorytmów aglomeracyjnych grupowania danych (podpakiet AGNES dostępny w pakiecie CLUSTER) i algorytmów deglomeracyjnych (podpakiet DIANA dostępny w pakiecie CLUSTER) oraz ulepszanego algorytmu hierarchicznego (pakiet BIRCH), a także algorytmów bazujących na analizie funkcji gęstości (pakiet DBSCAN).	2

WYKŁAD		
LP	TEMATYKA ZAJĘĆ OPIS SZCZEGÓŁOWY BLOKÓW TEMATYCZNYCH	LICZBA GODZIN
W1	Paradygmat inteligentnego, adaptacyjnego, prognozującego systemu uczącego się, jego charakterystyka oraz kryteria oceny jego jakości, skuteczności i efektywności działania.	2
W2	Modele uczenia się i ich elementy składowe i twierdzenia z nimi związane (np. The No Free Lunch Theorem). Postać danych, ich interpretacja i typy atrybutów. Przygotowywanie danych, ich normalizacja i umiejętność wstępnej ich wizualizacji.	2
W3	Odkrywanie regularności (wzorców) w danych (np. medycznych lub transakcyjnych). Tworzenie reguł asocjacyjnych i miary ich oceny (wsparcie i wiarygodność reguły, minimalny stopień wsparcia i wiarygodności). Macierze kolokacji.	2
W4	Omówienie metod klasyfikacji danych w oparciu o przykłady (instance based learning): a) metody k-najbliższych sąsiadów (k-Nearest Neighbours, k-NN); b) naiwnej metody wnioskowania bayesowskiego (Naive Bayesian method).	2
W5	Omówienie metod klasyfikacji danych w oparciu o przykłady (c.d.): c) metody tworzenia sieci bayesowskich (modele probabilistycznej zależności).	2
W6	Różnica pomiędzy metodami żądnego (eager) i leniwego (lazy) uczenia klasyfikowania danych. Przedstawienie metod leniwego uczenia klasyfikowania danych, takich jak: a) algorytm tworzenia drzew klasyfikacyjnych.	2
W7	Przedstawienie metod leniwego uczenia klasyfikowania danych (c.d.): b) algorytm tworzenia reguł decyzyjnych.	2
W8	Możliwości zastosowania sieci neuronowych do zadań klasyfikacji i grupowania danych.	2
W9	Maszyny wektorów podpierających (metoda SVM).	2
W10	Estymacja błędu predykcji: przykłady miar oceny jakości klasyfikatorów (entropia, indeks Giniego, błąd niepoprawnej klasyfikacji).	2
W11	Przedstawienie metod złożonych (Ensemble methods), stosowanych w celu poprawienia jakości klasyfikacji danych: a) metody bootstrapowe.	2

WYKŁAD		
LP	TEMATYKA ZAJĘĆ OPIS SZCZEGÓŁOWY BLOKÓW TEMATYCZNYCH	LICZBA GODZIN
W12	Przedstawienie metod złożonych (c.d.): b) metoda losowych lasów (Random Forests).	2
W13	Przedstawienie metod złożonych (c.d.): c) metoda boosting.	2
W14	Analiza skupień. Algorytmy grupowania danych oparte na podziałach (metoda k-średnich i k-medoidów).	2
W15	Hierarchiczne metody grupowania danych (hierarchical methods) aglomeracyjne i deglomeracyjne. Tworzenie hierarchicznej dekompozycji zbioru danych. Dendrogramy. Algorytmy bazujące na badaniu funkcji gęstości (density-based algorithms) i na analizie na lokalnych połączeniach.	2

7 NARZĘDZIA DYDAKTYCZNE

N1 Wykłady

N2 Prezentacje multimedialne

N3 Ćwiczenia laboratoryjne

N4 Praca w grupach

N5 Dyskusja

N6 Konsultacje

8 OBCIĄŻENIE PRACĄ STUDENTA

FORMA AKTYWNOŚCI	ŚREDNIA LICZBA GODZIN NA ZREALIZOWANIE AKTYWNOŚCI
Godziny kontaktowe z nauczycielem akademickim, w tym:	
Godziny wynikające z planu studiów	60
Konsultacje przedmiotowe	2
Egzaminy i zaliczenia w sesji	4
Godziny bez udziału nauczyciela akademickiego wynikające z nakładu pracy studenta, w tym:	
Przygotowanie się do zajęć, w tym studiowanie zalecanej literatury	24
Opracowanie wyników	10
Przygotowanie raportu, projektu, prezentacji, dyskusji	20
SUMARYCZNA LICZBA GODZIN DLA PRZEDMIOTU WYNIKAJĄCA Z CAŁEGO NAKŁADU PRACY STUDENTA	120
SUMARYCZNA LICZBA PUNKTÓW ECTS DLA PRZEDMIOTU	5.00

9 SPOSOBY OCENY

OCENA FORMUJĄCA

F1 Sprawozdanie z ćwiczenia laboratoryjnego

F2 Ćwiczenie praktyczne

F3 Odpowiedź ustna

F4 Kolokwium

OCENA PODSUMOWUJĄCA

P1 Średnia ważona ocen formujących

WARUNKI ZALICZENIA PRZEDMIOTU

W1 Ocena zaliczeniowa zależna będzie od uzyskania wystarczającej liczby punktów za: a) przysłane sprawozdania z ćwiczeń laboratoryjnych; b) aktywność podczas wykonywania ćwiczeń praktycznych w klasie; c) odpowiedzi ustne podczas zajęć; oraz za d) poprawne napisanie wcześniej zapowiedzianego kolokwium.

KRYTERIA OCENY

EFEKT KSZTAŁCENIA 1

NA OCENĘ 2.0	Student nie potrafi wytłumaczyć pojęć, omawianych na wykładach modeli i metod służących do analizy, klasyfikacji i grupowania informacji zawartych w zbiorach danych.
NA OCENĘ 3.0	Student potrafi wytłumaczyć pojęcia, omawiane na wykładach modele i metody służące do analizy, klasyfikacji i grupowania informacji zawartych w zbiorach danych.
NA OCENĘ 3.5	Student potrafi wytłumaczyć pojęcia, omawiane na wykładach modele i metody służące do analizy, klasyfikacji i grupowania informacji zawartych w zbiorach danych. Student potrafi też pokazać wady i zalety rozważanych modeli oraz metod analizy i konstrukcji wybranego modelu do klasyfikacji, grupowania i prognozowania oraz jego weryfikacji.
NA OCENĘ 4.0	Student potrafi wytłumaczyć pojęcia, omawiane na wykładach modele i metody służące do analizy, klasyfikacji i grupowania informacji zawartych w zbiorach danych. Student wie również, jak dokonać najbardziej odpowiedniej dla danego problemu wizualizacji najistotniejszych informacji ze zbiorów danych lub wizualizacji informacji otrzymanych z dokonanych przez siebie prognoz.
NA OCENĘ 4.5	Student potrafi wytłumaczyć pojęcia, omawiane na wykładach modele i metody służące do analizy, klasyfikacji i grupowania informacji zawartych w zbiorach danych. Student potrafi też pokazać wady i zalety rozważanych modeli. Student wie również, jak dokonać najbardziej odpowiedniej dla danego problemu wizualizacji najistotniejszych informacji ze zbiorów danych lub wizualizacji informacji otrzymanych z dokonanych przez siebie prognoz
NA OCENĘ 5.0	Student potrafi wytłumaczyć pojęcia, omawiane na wykładach modele i metody służące do analizy, klasyfikacji i grupowania informacji zawartych w zbiorach danych. Student potrafi też pokazać wady i zalety rozważanych modeli oraz metod analizy i konstrukcji wybranego modelu do klasyfikacji, grupowania i prognozowania oraz jego weryfikacji. Student wie również, jak dokonać najbardziej odpowiedniej dla danego problemu wizualizacji najistotniejszych informacji ze zbiorów danych lub wizualizacji informacji otrzymanych z dokonanych przez siebie prognoz.
EFEKT KSZTAŁCENIA 2	
NA OCENĘ 2.0	Student nie posiada umiejętności konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup), nie potrafi tego procesu konstrukcji wytłumaczyć oraz praktycznie zrealizować przy zastosowaniu pakietów w R.
NA OCENĘ 3.0	Student potrafi wytłumaczyć metodę konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup).
NA OCENĘ 3.5	Student posiada umiejętność konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup) oraz potrafi tą metodę konstrukcji modelu praktycznie zrealizować przy zastosowaniu pakietów w R.

NA OCENĘ 4.0	Student posiada umiejętność najwłaściwszego dla danego problemu analizy danych wyboru metody konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup) oraz potrafi tą metodę konstrukcji modelu praktycznie zrealizować przy zastosowaniu pakietów w R.
NA OCENĘ 4.5	Student posiada umiejętność najwłaściwszego dla danego problemu analizy danych wyboru metody konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup) oraz potrafi tą metodę konstrukcji modelu praktycznie zrealizować przy zastosowaniu pakietów w R. Student potrafi uzasadnić swoje wybory metod i modeli.
NA OCENĘ 5.0	Student posiada umiejętność najwłaściwszego dla danego problemu analizy danych wyboru metody konstrukcji modelu dokonującego klasyfikacji (lub grupowania) i prognozowania przyszłych decyzji (klas czy grup) oraz potrafi tą metodę konstrukcji modelu praktycznie zrealizować przy zastosowaniu pakietów w R i zweryfikować jakość działania tego modelu na zbiorze testowym, stosując odpowiednie miary jakości. Student potrafi uzasadnić swoje wybory metod i modeli.
EFEKT KSZTAŁCENIA 3	
NA OCENĘ 2.0	Student nie potrafi praktycznie zastosować omawianych na wykładach rodzajów metod wizualizacji danych oraz nie potrafi wykonać ważniejszych (omawianych na wykładach) poleceń w języku R.
NA OCENĘ 3.0	Student potrafi nie tylko wybrać właściwą metodę wizualizacji, ale również posiada umiejętność jej praktycznego poprawnego zastosowania dla danego problemu klasyfikacji (czy grupowania) informacji zawartych w danym zbiorze. Student zna niektóre omawiane na wykładach rodzaje metod wizualizacji danych. ich rodzaje metod wizualizacji danych.
NA OCENĘ 3.5	Student potrafi nie tylko wybrać właściwą metodę wizualizacji, ale również posiada umiejętność jej praktycznego poprawnego zastosowania dla danego problemu klasyfikacji (czy grupowania) informacji zawartych w danym zbiorze. Student potrafi zrealizować niektóre omawiane na wykładach rodzaje metod wizualizacji danych. Student również posiada umiejętność wykonywania ważniejszych poleceń (omawianych na wykładach) w języku R.
NA OCENĘ 4.0	Student potrafi nie tylko wybrać właściwą metodę wizualizacji, ale również posiada umiejętność jej praktycznego poprawnego zastosowania dla danego problemu klasyfikacji (czy grupowania) informacji zawartych w danym zbiorze. Student potrafi zrealizować niektóre omawiane na wykładach rodzaje metod wizualizacji danych. Student również posiada umiejętność samodzielnego programowania w języku R.
NA OCENĘ 4.5	Student potrafi nie tylko wybrać właściwą metodę wizualizacji, ale również posiada umiejętność jej praktycznego poprawnego zastosowania dla danego problemu klasyfikacji (czy grupowania) informacji zawartych w danym zbiorze. Student potrafi zrealizować większość omawianych na wykładach rodzajów metod wizualizacji danych, ich parametry oraz główne korzyści i cele zastosowań. Student również posiada umiejętność samodzielnego programowania w języku R.

NA OCENĘ 5.0	Student potrafi nie tylko wybrać właściwą metodę wizualizacji, ale również posiada umiejętność jej praktycznego poprawnego zastosowania dla danego problemu klasyfikacji (czy grupowania) informacji zawartych w danym zbiorze. Student umie wytłumaczyć swój wybór. Student potrafi zrealizować wszystkie omawiane na wykładach rodzaje metod wizualizacji danych, ich parametry oraz główne korzyści i cele zastosowań. Student również posiada umiejętność samodzielnego programowania w języku R.
EFEKT KSZTAŁCENIA 4	
NA OCENĘ 2.0	Student nie jest teoretycznie przygotowany do praktycznych ćwiczeń i nie angażuje się w pracę swojej grupy.
NA OCENĘ 3.0	Student jest bardzo słabo teoretycznie przygotowany do praktycznych ćwiczeń i mało angażuje się w pracę swojej grupy.
NA OCENĘ 3.5	Studenta często nie ma na Laboratoriach oraz z powodu mniejszego przygotowania z zadanego materiału nie zawsze potrafi dobrze współpracować w grupie.
NA OCENĘ 4.0	Student często stara się być aktywny, próbuje współpracować w grupie, ale z powodu mniejszego przygotowania z zadanego materiału, nie zawsze potrafi to uczynić.
NA OCENĘ 4.5	Student jest dobrze teoretycznie przygotowany do praktycznych ćwiczeń, często stara się być aktywny, ale nie umie dobrze współpracować w grupie.
NA OCENĘ 5.0	Student jest aktywny i stara się być zawsze dobrze przygotowany do Laboratoriów, potrafi współpracować w grupie, przyjmując w niej różne role, wykazując zawsze duże zaangażowanie.

10 MACIERZ REALIZACJI PRZEDMIOTU

EFEKT KSZTAŁCENIA	ODNIESIENIE DANEGO EFEKTU DO SZCZEGÓŁOWYCH EFEKTÓW ZDEFINIOWANYCH DLA PROGRAMU	CELE PRZEDMIOTU	TREŚCI PROGRAMOWE	NARZĘDZIA DYDAKTYCZNE	SPOSOBY OCENY
EK1	I2_W01 I2_W02 I2_W06 I2_U01 I2_U02 I2_U03 I2_U04 I2_U05 I2_U06 I2_U07 I2_U09 I2_U10 I2_U11	Cel 1	W1 W2 W3 W4 W5 W6 W7 W8 W9 W10 W11 W12 W13 W14 W15	N1 N2 N5 N6	F1 F2 F3 F4 P1

EFEKT KSZTAŁCENIA	ODNIESIENIE DANEGO EFEKTU DO SZCZEGÓŁOWYCH EFEKTÓW ZDEFINIOWANYCH DLA PROGRAMU	CELE PRZEDMIOTU	TREŚCI PROGRAMOWE	NARZĘDZIA DYDAKTYCZNE	SPOSOBY OCENY
EK2	I2_U01 I2_U02 I2_U03 I2_U04 I2_U05 I2_U06 I2_U07 I2_U09 I2_U10 I2_U11	Cel 2	L1 L2 L3 L4 L5 L6 L7 L8 L9 L10 L11 L12 L13 L14 L15 W1 W2 W3 W4 W5 W6 W7 W8 W9 W10 W11 W12 W13 W14 W15	N1 N2 N3 N4 N5 N6	F1 F2 F3 F4 P1
EK3	I2_U01 I2_U02 I2_U03 I2_U04 I2_U05 I2_U06 I2_U07 I2_U09 I2_U10 I2_U11	Cel 3	L1 L2 L3 L4 L5 L6 L7 L8 L9 L10 L11 L12 L13 L14 L15	N1 N2 N3 N4 N5 N6	F1 F2 F3 F4 P1
EK4	I2_U01 I2_U02 I2_U03 I2_U04 I2_U05 I2_U06 I2_U07 I2_U09 I2_U10 I2_U11 I2_K01 I2_K02 I2_K03 I2_K04	Cel 4	L1 L2 L3 L4 L5 L6 L7 L8 L9 L10 L11 L12 L13 L14 L15	N2 N3 N4 N5	F1 F2 F3

11 WYKAZ LITERATURY

LITERATURA PODSTAWOWA

[1] | **G. James, D. Witten, Trevor Hastie, Robert Tibshirani** — *An Introduction to Statistical Learning with Applications in R*, Stanford, CA, Springer. Wersja PDF książki jest dostępna pod stroną autora wraz z kodami źródłowymi: <http://www-bcf.usc.edu/gareth/ISL/book.html>, 2016, (kody źródłowe w języku R pod adresem: <http://www-bcf.usc.edu/gareth/ISL/code.html> ; utworzony przez tych autorów pakiet R'a: <https://cran.r-project.org/web/packages/ISLR/index.html>)

[2] | **Własne materiały w wersji elektronicznej** — *dostarczone studentom na pierwszych laboratoriach*, , 2016,

LITERATURA UZUPEŁNIAJĄCA

[1] | **Roger D. Peng** — *R Programming for Data Science, Exploratory data analysis with R*, Wersja PDF książki jest dostępna pod stroną autora wraz z kodami źródłowymi: <http://www.cs.upc.edu/robert/teaching/estadistica/rprogramming> 2015, Lean Publishing

[2] | **Teoretyczne wytłumaczenie działania wybranych ważniejszych algorytmów uczących się** — (*dostępnych w ekosystemie Apache SPARK w Chmurze*, mających interfejs w języku R, stale przez autorów uaktualnianych, online), 2016, <http://spark.apache.org/docs/latest/ml-lib-guide.html>

[3] | **Peter Harrington** — *Machine Learning in Action*, NY, Manning Inc., Wersja PDF książki dostępna jest pod stroną autora: <http://manning.com/pharrington/> a kody źródłowe: <https://github.com/pbharrin/machinelearninginaction>, 2012, lub pod stroną: http://www2.ift.ulaval.ca/chaib/IFT-4102-025/public_html/Fichiers/Machine_Learning_in_Action

12 INFORMACJE O NAUCZYCIELACH AKADEMICKICH

OSOBA ODPOWIEDZIALNA ZA KARTĘ

dr Barbara Borowik (kontakt: cnborowi@cyf-kr.edu.pl)

OSOBY PROWADZĄCE PRZEDMIOT

1 Dr Barbara Borowik (kontakt: cnborowi@cyf-kr.edu.pl)

13 ZATWIERDZENIE KARTY PRZEDMIOTU DO REALIZACJI

(miejscowość, data)

(odpowiedzialny za przedmiot)

(dziekan)

PRZYJMUJĘ DO REALIZACJI (data i podpisy osób prowadzących przedmiot)

.....