

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Analiza szeregów czasowych i prognozowanie
Nazwa w języku angielskim:	Time series analysis and forecasting	
Język wykładowy:	polski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Matematyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		obowiązkowy
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr Agnieszka Siłuszyk
Imię i nazwisko prowadzących zajęcia:		dr Agnieszka Siłuszyk
Założenia i cele przedmiotu:		Celem przedmiotu jest zapoznanie studentów z metodami analizy szeregów czasowych oraz prognozowania z uwzględnieniem metod wnioskowania statystycznego
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	podstawowe zasady dekompozycji szeregu czasowego	K_W01, K_W02, K_W10
W_02	podstawy analizy spektralnej oraz metody filtracji	K_W01, K_W02, K_W10
W_03	pojęcia stacjonarności szeregu czasowego	K_W01, K_W02, K_W10
W_04	sposoby pozyskiwania danych z różnorodnych źródeł	K_W013
W_05	metody szacowania wartości średniej, wariancji, odchylenia standardowego i prawdopodobieństwa	K_W05, K_W06
W_06	elementy wnioskowania statystycznego; zna klasyfikację testów statystycznych	K_W05, K_W06

W_07	zagadnienie analizy regresji prostej, wnioskowania z liniowej funkcji regresji prostej oraz zagadnienie nieliniowej funkcji regresji prostej	K_W02, K_W06
W_08	analizę szeregów czasowych; analizę dynamiki zjawisk przy pomocy indeksów statystycznych	K_W05, K_W06
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	posługiwać się podstawowymi technikami i narzędziami wykorzystywanymi w analizie szeregów czasowych	K_U09, K_U10, K_U11
U_02	przeprowadzić rzeczywistą analizę szeregu czasowego	K_U05, K_U06, K_U11
U_03	omówić metody związane z szacowaniem wartości średniej, wariancji, odchylenia standardowego i prawdopodobieństwa	K_U07, K_U08, K_U11
U_04	zinterpretować zagadnienia i metody stosowania testów statystycznych oraz indeksów statystycznych	K_U07, K_U08, K_U11
U_05	przeprowadzić prognozę dla bezpośrednich obserwacji wykorzystując do tego analizę regresji, elementy wnioskowania statystycznego oraz analizę szeregów czasowych	K_U14, K_U16
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	kierowania się regułami, normami i zasadami zgodnymi z etyką zawodową	K_K04
K_02	krytycznej oceny swojej wiedzy i odbieranych treści, rozumie potrzebę dalszego kształcenia, uwzględniając trendy w przetwarzaniu i analizie danych	K_K01, K_K02
K_03	do myślenia i działania w sposób samodzielny i przedsiębiorczy; wykazuje się inicjatywą	K_K03
K_04	ponoszenia odpowiedzialności za własne decyzje zapadające na podstawie eksplorowanych danych	K_K04
K_05	ponoszenia odpowiedzialności za własne decyzje w procesie prognostycznym	K_K04
Forma i typy zajęć: wykłady (15 godz.), ćwiczenia (45 godz.)		
Wymagania wstępne i dodatkowe:		
Wiedza z zakresu podstaw rachunku prawdopodobieństwa i statystyki.		
Treści modułu kształcenia:		

1. Szereg czasowy. Składowe i dekompozycja szeregu czasowego. Klasyczne metody dekompozycji szeregu czasowego w formie addytywnej i multiplikatywnej na trend, wahania sezonowe, składnik cykliczny oraz składnik czysto stochastyczny
2. Wyodrębnianie i analiza trendu. Mechaniczne metody wygładzania.
3. Sezonowość. Wyodrębnianie i analiza składników sezonowych.
4. Domena częstotliwości, spektrum szeregu czasowego, analiza spektralna szeregu czasowego, metody filtracji szeregu
5. Proces stochastyczny, proces deterministyczny, silna i słaba stacjonarność szeregów czasowych, błędzenie losowe (z dryfem/z trendem), biały szum.
6. Elementy estymacji parametrów. Szacowanie wartości średniej, wariancji, odchylenia standardowego i prawdopodobieństwa.
7. Elementy wnioskowania statystycznego. Klasyfikacja i wykorzystanie testów statystycznych (parametrycznych i nieparametrycznych).
8. Elementy analizy regresji. Zagadnienie analizy regresji prostej, wnioskowanie z liniowej funkcji regresji prostej, nieliniowe funkcje regresji prostej.
9. Analiza szeregów czasowych. Analiza dynamiki zjawisk przy pomocy indeksów statystycznych.

Literatura podstawowa:

1. A. Luszniwicz, T. Słaby Statystyka z pakietem komputerowym Statistica. Teoria i zastosowania, Warszawa, Wyd. C.H.Beck, 2001
2. A. Stanisław Przystępny kurs statystyki, Kraków 2007
3. S. Brandt, Analiza danych – metody statystyczne i obliczeniowe, Warszawa, WNT, 1998.
4. M. Rabiej, Statystyka z programem Statistica, Helion, 2012

Literatura dodatkowa:

1. Tsay, R. S. Analysis of Financial Time Series, Wiley, 2002
2. Box, G. E. and G. M. Jenkins (1994) Time Series Analysis, Prentice Hall
3. Brockwell, P. J. and R. A. Davis (1996) Introduction to Time Series and Forecasting, Springer-Verlag
4. Hamilton, James D. (1994) Time Series Analysis, Princeton University Press

Planowane formy/działania/metody dydaktyczne:

Wykłady prowadzone technikami multimedialnymi: prezentacja + przykłady, ćw. lab rozwiązywanie zadań. Zadania rachunkowe realizowane w pakietach Statistica, Matlab, Excel

Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:

Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_08, U_01 – U_05, K_01_K_05	Wszystkie efekty będą sprawdzone podczas kolokwium oraz egzaminu końcowego.

Forma i warunki zaliczenia:

Zaliczenie przedmiotu odbywa się na podstawie kolokwium oraz egzaminu końcowego (forma pisemna lub ustna). Warunkiem zaliczenia przedmiotu jest uzyskanie co najmniej 51% ogólnej liczby punktów z kolokwium oraz z egzaminu.

Kryterium oceny:

51-60% ogólnej liczby punktów– ocena dst
 61-70% ogólnej liczby punktów– ocena dst+
 71-80% ogólnej liczby punktów– ocena db
 81-90% ogólnej liczby punktów– ocena db+
 91-100% ogólnej liczby punktów– ocena bdb

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	30 godz.
Udział w konsultacjach z przedmiotu	3 godz.
Samodzielne przygotowanie się do ćwiczeń	17 godz.
Samodzielne przygotowanie się do kolokwίων	25 godz.
Przygotowanie się do egzaminu i obecność na egzaminie	20 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Przetwarzanie danych w Chmurze
Nazwa w języku angielskim:	Cloud Computing	
Język wykładowy:	polski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Informatyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		fakultatywny
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr Artur Niewiadomski
Imię i nazwisko prowadzących zajęcia:		dr Artur Niewiadomski
Założenia i cele przedmiotu:		Celem przedmiotu jest rozszerzenie wiedzy i umiejętności studentów o mechanizmy przetwarzania danych w chmurach obliczeniowych. Do realizacji tych celów zostaną wykorzystane dwie najpopularniejsze platformy: Microsoft Azure oraz Amazon Web Services.
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	rodzaje chmur obliczeniowych, zasady ich działania oraz narzędzia i usługi dostarczane przez liderów rynku	K_W01, K_W07
W_02	sposoby przechowywania, przetwarzania i analizy danych w chmurze	K_W01, K_W07, K_W09, K_W11
W_03	mechanizmy bezpieczeństwa i skalowania wydajności aplikacji w chmurze	K_W01, K_W07
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	monitorować i zarządzać aplikacjami w chmurze Azure i Amazon Web Services	K_U15, K_U16

U_02	posługiwać się najnowszymi technologiami chmurowymi	K_U11, K_U13
U_03	wykorzystać środowisko chmurowe do przechowywania, przetwarzania i analizy danych	K_U11, K_U14, K_U16
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	kreatywnego działania i poszukiwania optymalnych rozwiązań projektowych przy uwzględnieniu ryzyka i uwarunkowań biznesowych	K_K02, K_03
Forma i typy zajęć:		wykłady (30 godz.), ćwiczenia (30 godz.)
Wymagania wstępne i dodatkowe:		
Opanowany materiał z zakresu podstaw programowania, języka Python, baz danych i technologii internetowych		
Treści modułu kształcenia:		
1. Wirtualizacja i sieci wirtualne 2. Komunikacja i przechowywanie danych w chmurze 3. Wprowadzenie do Microsoft Azure 4. Podstawowe usługi Azure 5. Zarządzanie zasobami Azure, automatyzacja 6. Uczenie maszynowe i sztuczna inteligencja w Azure 7. Narzędzia analityczne Azure 8. Wprowadzenie do Amazon Web Services 9. Podstawowe usługi AWS 10. Zarządzanie zasobami AWS, automatyzacja 11. Uczenie maszynowe i sztuczna inteligencja w AWS 12. Narzędzia analityczne AWS		
Literatura podstawowa:		
1. Amazon Web Services w akcji. A. Wittig, M. Wittig. Wydanie II. Helion 2020 2. Cloud Analytics with Microsoft Azure, 2nd Edition. H. Altaiar, J. Lee, M. Peña, Packt Publishing 2021		
Literatura dodatkowa:		
1. Chmura Azure : praktyczne wprowadzenie dla administratora : implementacja, monitorowanie i zarządzanie ważnymi usługami i komponentami IaaS/PaaS / Mustafa Toroman, Helion 2020 2. Mastering Azure Analytics. Architecting in the Cloud with Azure Data Lake, HDInsight, and Spark. O'Reilly 2017 3. Materiały elektroniczne udostępniane w ramach AWS Academy oraz Azure for Education		
Planowane formy/działania/metody dydaktyczne:		
Wykład tradycyjny wspomagany technikami multimedialnymi, ćwiczenia laboratoryjne wspomagane technikami multimedialnymi. Zamieszczanie na stronach internetowych problemów i zadań ćwiczeniowych.		
Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:		

Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_03	Efekty będą sprawdzane na bieżąco podczas zajęć, oraz na kolokwium zaliczeniowym. Student będzie odpowiadał na pytania związane z funkcjonowaniem chmury obliczeniowej, zarządzaniem zasobami chmurowymi, aspektami bezpieczeństwa i skalowalności w chmurze oraz usług związanych z przechowywaniem, integracją i przetwarzaniem danych. Przykładowe pytania: – Scharakteryzuj modele IaaS, PaaS, SaaS. – Scharakteryzuj usługi związane z przechowywaniem danych dostępne w Azure oraz AWS. – Scharakteryzuj wybrane usługi związane z analizą danych oferowane przez Azure i AWS. – Porównaj usługi i narzędzia sztucznej inteligencji dostępne w Azure oraz AWS
U_01- U_03	Efekty będą sprawdzane systematycznie podczas zajęć laboratoryjnych
K_01	Efekt będzie weryfikowany w oparciu o odpowiedzi na pytania zadawane w czasie zajęć laboratoryjnych i wykładów.

Forma i warunki zaliczenia:

Moduł kończy się zaliczeniem na ocenę w formie ustnego kolokwium. Do zaliczenia mogą przystąpić osoby, które uzyskały zaliczenie laboratorium. Na zaliczenie laboratorium składają się oceny cząstkowe uzyskane na regularnych zajęciach z nauczycielem akademickim, za które student może zdobyć maksymalnie 60 punktów. Zajęcia laboratoryjne będą zaliczone po uzyskaniu powyżej 30 punktów.

Podczas kolokwium ustnego można uzyskać do 40 punktów, student uzyskuje zaliczenie w przypadku uzyskania powyżej 20 punktów.

Ocena końcowa z przedmiotu, w zależności od sumy uzyskanych punktów (maksymalnie 100 pkt) jest następująca (w nawiasach ocena wg skali ECTS):

0 – 50 pkt: niedostateczna (F),

51 – 60 pkt: dostateczna (E),

61 – 70 pkt: dostateczna plus (D),

71 – 80 pkt: dobra (C),

81 – 90 pkt: dobra plus (B),

91 – 100 pkt: bardzo dobra (A).

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	30 godz.
Udział w konsultacjach z przedmiotu	4 godz.
Samodzielne przygotowanie się do ćwiczeń laboratoryjnych, prace domowe	35 godz.

Samodzielne przygotowanie się do kolokwίων	26 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Programowanie w Chmurze
Nazwa w języku angielskim:	Cloud Programming	
Język wykładowy:	polski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Informatyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		fakultatywny
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr Artur Niewiadomski
Imię i nazwisko prowadzących zajęcia:		dr Artur Niewiadomski
Założenia i cele przedmiotu:		Celem przedmiotu jest rozszerzenie wiedzy i umiejętności studentów o mechanizmy związane z programowaniem aplikacji chmurowych. Do realizacji tych celów zostaną wykorzystane dwie najpopularniejsze platformy: Microsoft Azure oraz Amazon Web Services.
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	rodzaje chmur obliczeniowych, zasady ich działania oraz narzędzia i usługi dostarczane przez liderów rynku	K_W01, K_W07
W_02	sposoby przechowywania i przetwarzania danych oraz programowanie aplikacji chmurowych	K_W01, K_W07, K_W09, K_W11
W_03	mechanizmy bezpieczeństwa i skalowania wydajności aplikacji w chmurze	K_W01, K_W07
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	monitorować i zarządzać aplikacjami w chmurze Azure i Amazon Web Services	K_U15, K_U16

U_02	posługiwać się najnowszymi technologiami chmurowymi	K_U11, K_U12
U_03	programować aplikacje chmurowe	K_U09, K_U10, K_U14, K_U16
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	kreatywnego działania i poszukiwania optymalnych rozwiązań projektowych przy uwzględnieniu ryzyka i uwarunkowań biznesowych	K_K02, K_K03
Forma i typy zajęć:		wykłady (30 godz.), ćwiczenia (30 godz.)
Wymagania wstępne i dodatkowe:		
Opanowany materiał z zakresu podstaw programowania, języka Python, baz danych i technologii internetowych.		
Treści modułu kształcenia:		
1. Wirtualizacja i sieci wirtualne 2. Docker i Kubernetes 3. Komunikacja i przechowywanie danych w chmurze 4. Wprowadzenie do Microsoft Azure 5. Podstawowe usługi Azure 6. Zarządzanie zasobami Azure, automatyzacja, skalowanie 7. Uczenie maszynowe i sztuczna inteligencja w Azure 8. Programowanie w modelu PaaS oraz FaaS w chmurze Azure 9. Wprowadzenie do Amazon Web Services 10. Podstawowe usługi AWS 11. Zarządzanie zasobami AWS, automatyzacja, skalowanie 12. AWS Lambda 13. Uczenie maszynowe i sztuczna inteligencja w AWS		
Literatura podstawowa:		
1. Amazon Web Services w akcji. A. Wittig, M. Wittig. Wydanie II. Helion 2020 2. Usługi Microsoft Azure. Programowanie aplikacji. Z. Fryźlewicz, Ł. Leśniczek, Promise 2020		
Literatura dodatkowa:		
1. Chmura Azure : praktyczne wprowadzenie dla administratora : implementacja, monitorowanie i zarządzanie ważnymi usługami i komponentami IaaS/PaaS / Mustafa Toroman, Helion 2020 2. Mastering Azure Analytics. Architecting in the Cloud with Azure Data Lake, HDInsight, and Spark. O'Reilly 2017 3. Materiały elektroniczne udostępniane w ramach AWS Academy oraz Azure for Education		
Planowane formy/działania/metody dydaktyczne:		
Wykład tradycyjny wspomagany technikami multimedialnymi, ćwiczenia laboratoryjne wspomagane technikami multimedialnymi. Zamieszczanie na stronach internetowych problemów i zadań ćwiczeniowych.		
Sposoby weryfikacji efektów uczenia się osiąganých przez studenta:		

Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_03	Efekty będą sprawdzane na bieżąco podczas zajęć, oraz na kolokwium zaliczeniowym. Student będzie odpowiadał na pytania związane z funkcjonowaniem chmury obliczeniowej, zarządzaniem zasobami chmurowymi, aspektami bezpieczeństwa i skalowalności w chmurze oraz usług związanych z przechowywaniem, integracją i przetwarzaniem danych. Przykładowe pytania: – Scharakteryzuj modele IaaS, PaaS, SaaS. – Scharakteryzuj usługi związane z przechowywaniem danych dostępne w Azure oraz AWS. – Scharakteryzuj wybrane usługi związane z uczeniem maszynowym oferowane przez Azure i AWS. – Porównaj Azure Functions z AWS Lambda.
U_01- U_03	Efekty będą sprawdzane systematycznie podczas zajęć laboratoryjnych.
K_01	Efekt będzie weryfikowany w oparciu o odpowiedzi na pytania zadawane w czasie zajęć laboratoryjnych i wykładów.

Forma i warunki zaliczenia:

Moduł kończy się zaliczeniem na ocenę w formie ustnego kolokwium. Do zaliczenia mogą przystąpić osoby, które uzyskały zaliczenie laboratorium. Na zaliczenie laboratorium składają się oceny cząstkowe uzyskane na regularnych zajęciach z nauczycielem akademickim, za które student może zdobyć maksymalnie 60 punktów. Zajęcia laboratoryjne będą zaliczone po uzyskaniu powyżej 30 punktów.

Podczas kolokwium ustnego można uzyskać do 40 punktów, student uzyskuje zaliczenie w przypadku uzyskania powyżej 20 punktów.

Ocena końcowa z przedmiotu, w zależności od sumy uzyskanych punktów (maksymalnie 100 pkt) jest następująca (w nawiasach ocena wg skali ECTS):

0 – 50 pkt: niedostateczna (F),

51 – 60 pkt: dostateczna (E),

61 – 70 pkt: dostateczna plus (D),

71 – 80 pkt: dobra (C),

81 – 90 pkt: dobra plus (B),

91 – 100 pkt: bardzo dobra (A).

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	30 godz.
Udział w konsultacjach z przedmiotu	4 godz.
Samodzielne przygotowanie się do ćwiczeń laboratoryjnych, prace domowe	35 godz.

Samodzielne przygotowanie się do kolokwίων	26 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Data Mining w MatLabie
Nazwa w języku angielskim:	Data Mining in MatLab	
Język wykładowy:	angielski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Informatyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		fakultatywny
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr Anna Wawrzyńczak-Szaban
Imię i nazwisko prowadzących zajęcia:		dr Anna Wawrzyńczak-Szaban
Założenia i cele przedmiotu:		Celem przedmiotu jest zapoznanie studentów z pojęciami i metodami data mining (eksploracji danych) oraz ich praktycznego zastosowania i analizy w środowisku MatLab
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	podstawowe zagadnienia związane z eksploracją danych	K_W10
W_02	założenia poszczególnych modeli data mining oraz potrafi je zastosować do konkretnego zagadnienia	K_W07, K_W11
W_03	możliwości praktycznego wykorzystania eksploracji danych w różnych dziedzinach życia	K_W12
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	analizować i przygotować odpowiedni zbiór danych do wybranej metody data mining	K_U11, K_U13
U_02	tworzyć wybrane modele eksploracji danych w środowisku MatLab	K_U11, K_U14

U_03	wykorzystać poznane metody do rozwiązywania problemów klasyfikacji i predykcji. Potrafi dokonać ich estymacji oraz zwizualizować i zinterpretować wyniki	K_U14, K_U15, K_U16, K_U17
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	krytycznej oceny otrzymywanych wyników oraz rozumie konsekwencje źle przeprowadzonych analiz	K_K01
K_02	przygotowania sprawozdania przedstawiającego najważniejsze informacje pozyskane z eksploracji danych	K_K02, K_K03
Forma i typy zajęć:		wykłady (30 godz.), ćwiczenia laboratoryjne (45 godz.)
Wymagania wstępne i dodatkowe:		
Umiejętność samodzielnego programowania w środowisku MatLab. Wiedza z zakresu statystyki.		
Treści modułu kształcenia:		
1. Wstęp do Data Mining. Co to jest data mining? Cele stosowania data miningu. Technologie pokrewne. Etapy procesu eksploracji danych. Metody reprezentacji informacji. 2. Wstępne przetwarzanie danych i analiza statystyczna. Czyszczenie, transformacja, redukcja danych. Analiza głównych składowych. Analiza czynnikowa. Analiza regresji. Korelacja kanoniczna. 3. Reprezentacja wiedzy w data mining. Miary ciekawości. Reprezentowanie danych wejściowych i interpretacja danych wyjściowych. Techniki wizualizacji. 4. Algorytmy eksploracji danych: Reguły asocjacyjne. Wzorce składowe. Wydajne generowanie zestawów przedmiotów i reguł. Analiza korelacji. Generowanie reguł – algorytm A priori. Analiza koszykowa. 5. Algorytmy eksploracji danych: Klasyfikacja. Drzewa decyzyjne. Algorytm SVM. Kryteria oceny klasyfikatorów. 6. Algorytmy eksploracji danych: Predykcja. Klasyfikacja statystyczna (bayesowska). Sieci bayesowskie. Modele liniowe. 7. Analiza skupień. Aglomeracja. Miary odległości. Grupowanie obiektów i cech. Grupowanie metodą k-średnich. Grupowanie metodą EM		
Literatura podstawowa:		
1. MathWorks, Statistics and Machine Learning Toolbox User Guide, (2016) 2. Larose D. T., Metody i modele eksploracji danych, PWN, Warszawa (2008) 3. Morzy T., Eksploracja danych, Metody i algorytmy, PWN, Warszawa (2013)		
Literatura dodatkowa:		
1. Witten I. H., Ian H., Data Mining: Practical Machine Learning Tools and Techniques, Second Edition, Morgan Kaufmann, New York (2005) 2. Cichosz P., Systemy uczące się, WNT, Warszawa (2000) 3. Anna Wawrzynczak, Piotr Kopka , Approximate Bayesian Computation for Estimating Parameters of Data-Consistent Forbush Decrease Model, Entropy 2018, 20(8), 622; doi:10.3390/e20080622		
Planowane formy/działania/metody dydaktyczne:		

Wykład tradycyjny. Laboratoria wspomagane technikami komputerowymi. Zamieszczanie na stronach internetowych problemów i zadań laboratoryjnych

Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:

Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_03	Efekty sprawdzane będą na kolokwium zaliczeniowym.
U_01 - U_03	Efekty będą na bieżąco sprawdzane na zajęciach laboratoryjnych, podczas stosowania wiedzy w praktyce.
K_01 - K_02	Efekty będzie weryfikowany na bieżąco, w oparciu o posiadaną wiedzę i umiejętności w czasie zajęć laboratoryjnych.

Forma i warunki zaliczenia:

Moduł kończy się zaliczeniem z oceną. Ocena końcowa jest sumą punktów uzyskanych na podstawie tematów wykonanych samodzielnie przez studenta na zajęciach laboratoryjnych oraz punktów z pisemnego kolokwium zaliczeniowego na ostatnim wykładzie. Za zajęciach laboratoryjnych można uzyskać maksymalnie 150pkt, a za kolokwium – maksymalnie 50pkt. Łącznie 200pkt. Zaliczenie zajęć następuje w przypadku uzyskania co najmniej 76pkt za zadania wykonane podczas ćwiczeń laboratoryjnych oraz co najmniej 26pkt z kolokwium.

Ocena końcowa modułu (po zaliczeniu wszystkich składowych) w zależności od sumy uzyskanych punktów jest następująca (w nawiasach ocena wg skali ECTS):

- 0-100 pkt – ndst (F)
- 101- 120 pkt – dst (E)
- 121-140 pkt – dst+ (D)
- 141-160 pkt – db (C)
- 161-180 pkt – db+ (B)
- 181-200 pkt – bdb (A)

Warunek uzyskania zaliczenia przedmiotu: co najwyżej dwie nieusprawiedliwione nieobecności na ćwiczeniach i spełnienie każdego z niżej opisanych warunków

- uzyskanie co najmniej 76 punktów z ćwiczeń laboratoryjnych
- uzyskanie co najmniej 26 punktów z kolokwium

Poprawy: Jednorazowa poprawa kolokwium w sesji. Jednorazowe poprawy do 2 ćwiczeń laboratoryjnych w trakcie semestru.

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	45 godz.
Udział w konsultacjach z przedmiotu	5 godz.
Samodzielne przygotowanie się do ćwiczeń	20 godz.

Samodzielne przygotowanie się do kolokwίων	26 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Data Mining w Statistica
Nazwa w języku angielskim:	Data Mining in Statistica	
Język wykładowy:	angielski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Matematyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		fakultatywny
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr hab. Agnieszka Gil – Świdarska, prof. uczelni
Imię i nazwisko prowadzących zajęcia:		dr hab. Agnieszka Gil – Świdarska, prof. uczelni dr Agnieszka Siłuszyk
Założenia i cele przedmiotu:		Celem przedmiotu jest zapoznanie studentów z pojęciami i zagadnieniami stosowanymi w technikach eksploracji i analizy danych; z klasyfikacją technik, z modelowaniem matematycznym i jego założeniami oraz metodami stosowanymi w technikach data mining
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	podstawowe pojęcia związane z dziedziną eksploracji danych, jak również metody eksploracji danych	K_W01, K_W11
W_02	sposoby pozyskiwania danych z różnorodnych źródeł	K_W09
W_03	podstawowe typy reguł asocjacyjnych, zna podstawowe techniki klasyfikacji	K_W07, K_W10
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	korzystać z graficznych technik eksploracji danych	K_U05
U_02	posługiwać się podstawowymi technikami i narzędziami wykorzystywanymi w eksploracji danych	K_U09, K_U10

U_03	przeprowadzić rzeczywistą eksplorację danych na dużych zbiorach danych	K_U14, K_U16
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	krytycznej oceny swojej wiedzy i odbieranych treści, rozumie potrzebę dalszego kształcenia	K_K01
K_02	formułowania pytań oraz opinii na temat eksploracji danych w naukach o życiu, jak również w naukach społecznych	K_K02
K_03	pracy w zespole; rozumie konieczność systematycznej pracy nad projektami związanymi z data mining	K_K03
Forma i typy zajęć:		wykłady (30 godz.), ćwiczenia laboratoryjne (45 godz.)
Wymagania wstępne i dodatkowe:		
Matematyka, rachunek prawdopodobieństwa, statystyka		
Treści modułu kształcenia:		
1. Wprowadzenie. Wybór atrybutów analizowanych danych. 2. Analiza danych. Dopasowywanie modeli (agregacja, wzmacnianie, łączenie modeli), a następnie weryfikacja. 3. Klasyfikacja. Metody kNN. Naive Bayes. Sieci Bayesowskie. 4. Drzewa decyzyjne. Drzewo decyzyjne dla dużych zbiorów danych. 5. Problem klastrowania. Grupowanie dużych zbiorów danych. 6. Teoria uczenia się. Maszyny uczące się. 7. Wzorce. Klasyfikacja zbiorem reguł w dużych zbiorach danych. Sieci neuronowe. 8. Metody przygotowywania danych. Podstawy tworzenia systemów bazodanowych oraz analitycznych. 9. Wprowadzenie do wspomagania procesów decyzyjnych. Systemy OLAP (Online Analytical Processing) i Data mining. 10. Text mining. Przetwarzanie danych i przygotowywanie ich do analizy.		
Literatura podstawowa:		
1. Larose D.T. Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych, Warszawa, Wydawnictwo Naukowe PWN, 2013 2. Ramsza M. Elementy modelowania ekonomicznego opartego na teorii uczenia się w grach populacyjnych, Oficyna Wydawnicza SGH, Warszawa, 2010 3. Brandt S. Analiza danych – metody statystyczne i obliczeniowe, Warszawa, WNT, 1998		
Literatura dodatkowa:		
1. Urbański M. Data Mining, czyli wyszukiwanie informacji w zbiorach danych, Wydawnictwo Wiedza i Praktyka 2. Fayyad U., Piatetsky-Shapiro G. Advances in Knowledge Discovery and Data Mining, MIT Press, 1996		
Planowane formy/działania/metody dydaktyczne:		
Wykład: tradycyjny i z wykorzystaniem technik multimedialnych.		

Ćwiczenia: zadania ilustrujące wykład z wykorzystaniem programu Statistica / case study.	
Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:	
Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_03, U_01 – U_03, K_01 – K_03	Wszystkie efekty kształcenia będą sprawdzone podczas kolokwium i/ lub projektu oraz na zaliczeniu końcowym.
Forma i warunki zaliczenia:	
Zaliczenie przedmiotu odbywa się na podstawie kolokwium i/ lub projektu oraz zaliczenia końcowego w formie pisemnej. Warunkiem zaliczenia przedmiotu jest uczestnictwo w ćwiczeniach (co najwyżej dwie nieusprawiedliwione nieobecności na zajęciach), uzyskanie co najmniej 51% ogólnej liczby punktów z kolokwium i/ lub projektu oraz z zaliczenia końcowego. Poniżej podano progi procentowe dla 6-stopniowej skali ocen: 1) 0-50%---2.0 2) 51-60%---3.0 3) 61-70%---3.5 4) 71-80%---4.0 5) 81-90%---4.5 6) 91-100%---5.0 Poprawy: jednorazowa poprawa kolokwium i/ lub projektu w trakcie zajęć w semestrze, natomiast poprawa zaliczenia końcowego w sesji egzaminacyjnej.	
Bilans punktów ECTS:	
Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	45 godz.
Udział w konsultacjach z przedmiotu	4 godz.
Samodzielne przygotowanie się do ćwiczeń	20 godz.
Samodzielne przygotowanie się do kolokwiów	26 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Finansowe szeregi czasowe
Nazwa w języku angielskim:	Financial time series	
Język wykładowy:	angielski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Matematyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		fakultatywny
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr hab. Agnieszka Gil-Świdarska, prof. uczelni
Imię i nazwisko prowadzących zajęcia:		dr hab. Agnieszka Gil-Świdarska, prof. uczelni
Założenia i cele przedmiotu:		Celem przedmiotu jest ukazanie studentom praktycznego zastosowania metod data mining w analizie i prognozowaniu danych finansowych.
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	metodykę eksploracji danych rzeczywistych	K_W07, K_W10
W_02	podstawy finansowych szeregów czasowych	K_W03 , K_W07
W_03	znaczenie eksploracji danych w analizie danych finansowych	K_W01, K_W13
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	analizować dane rzeczywiste metodami wnioskowania statystycznego	K_U07
U_02	obalać nieuprawnione rozumowanie poprzez argumentację opartą o wyniki przeprowadzonych analiz danych finansowych	K_U07, K_U08
U_03	budować modele eksploracji danych i stosować je do prognozowania danych z rynków finansowych	K_U07, K_U14
U_04	charakteryzować zależności pomiędzy rzeczywistymi danymi z rynków finansowych, ujmować je w postaci tabel, wykresów czy schematów	K_U05

Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	krytycznej oceny swojej wiedzy i odbieranych treści, rozumie potrzebę dalszego jej pogłębiania	K_K01
K_02	uznawania znaczenia wiedzy w rozwiązywaniu problemów poznawczych związanych z różnymi aspektami analizy i prognozowania danych finansowych	K_K02
Forma i typy zajęć:		wykłady (30 godz.), ćwiczenia laboratoryjne (30 godz.)
Wymagania wstępne i dodatkowe:		
Znajomość podstaw statystyki oraz algorytmów eksploracji danych		
Treści modułu kształcenia:		
1. Natura rynków finansowych 2. Czym jest szereg czasowy 3. Eksploracja baz danych finansowych 4. Identyfikacja trendów i cykliczności 5. Metody analizy Fourierskiej w zastosowaniach finansowych 6. Metoda głównych składowych w analizie danych finansowych 7. Analiza i prognozowanie w badaniach nad zachowaniem danych finansowych w oparciu o metody uczenia maszynowego		
Literatura podstawowa:		
1. Discrete Time Series, Processes, and Applications in Finance, Gilles Zumbach, 2013, Springer (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line) 2. Introduction to Modern Time Series Analysis, Gebhard Kirchgässner, Jürgen Wolters, Uwe Hassler, 2013, Springer (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line) 3. Time Series Econometrics. Learning Through Replication, John D. Levendis, 2018, Springer (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line)		
Literatura dodatkowa:		
1. Separating Information Maximum Likelihood Method for High-Frequency Financial Data, Naoto Kunitomo, Seisho Sato, Daisuke Kurisu, 2018, Springer (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line) 2. A Time Series Approach to Option Pricing. Models, Methods and Empirical Performances, Christophe Chorro, Dominique Guégan, Florian Ielpo, 2015, Springer (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line)		
Planowane formy/działania/metody dydaktyczne:		
Wykład wspomagany technikami multimedialnymi. Ćwiczenia laboratoryjne - zajęcia praktyczne przy komputerze, podczas których studenci będą wykonywać analizy i prognozy w oparciu o dane z rynków finansowych		
Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:		
Symbol efektu	Metody weryfikacji efektów uczenia się	

U_01-U_04, K_01-K_02	Efekty kształcenia będą sprawdzone podczas dyskusji w trakcie wykładów i ćwiczeń, jak również podczas wykonywania ćwiczeń laboratoryjnych przed komputerem.
W_01-W_03	Efekty kształcenia będą sprawdzone podczas dyskusji w trakcie wykładów i ćwiczeń, jak również podczas kolokwium i zaliczenia.

Forma i warunki zaliczenia:

Przedmiot kończy się zaliczeniem pisemnym, do którego można przystąpić dopiero po uzyskaniu zaliczenia ćwiczeń laboratoryjnych. Zaliczenie laboratorium daje średnia ocen z poszczególnych zadań oraz kolokwium. Na ocenę końcową składa się w 50% ocena z laboratorium i w 50% ocena z zaliczenia pisemnego

Kryterium oceny końcowej:

51-60% ogólnej liczby punktów– ocena dst

61-70% ogólnej liczby punktów– ocena dst+

71-80% ogólnej liczby punktów– ocena db

81-90% ogólnej liczby punktów– ocena db+

91-100% ogólnej liczby punktów– ocena bdb

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	30 godz.
Udział w konsultacjach z przedmiotu	3 godz.
Samodzielne przygotowanie się do ćwiczeń	17 godz.
Samodzielne przygotowanie się do kolokwium	20 godz.
Przygotowanie się do zaliczenia i obecność na zaliczeniu	25 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Data mining w badaniach nad pogodą kosmiczną
Nazwa w języku angielskim:	Data mining in space weather studies	
Język wykładowy:	angielski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Matematyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		fakultatywny
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty	
Liczba punktów ECTS:	5	
Imię i nazwisko koordynatora przedmiotu:		dr hab. Agnieszka Gil-Świdarska, prof. uczelni
Imię i nazwisko prowadzących zajęcia:		dr hab. Agnieszka Gil-Świdarska, prof. uczelni
Założenia i cele przedmiotu:		Celem przedmiotu jest ukazanie studentom praktycznego zastosowania metod data mining w najnowszych trendach naukowych w zakresie badań nad pogodą kosmiczną.
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	metodykę eksploracji danych rzeczywistych	K_W07, K_W10
W_02	podstawy pogody kosmicznej	K_W03 , K_W07
W_03	strategiczne znaczenie eksploracji danych w badaniach nad zjawiskami pogody kosmicznej	K_W01, K_W13
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	analizować dane rzeczywiste metodami wnioskowania statystycznego	K_U07
U_02	obalać nieuprawnione rozumowanie poprzez argumentację opartą o wyniki przeprowadzonych analiz danych rzeczywistych	K_U07, K_U08
U_03	budować modele eksploracji danych i stosować je do prognozowania wybranych zjawisk pogody kosmicznej	K_U07, K_U14

U_04	charakteryzować zależności pomiędzy danymi związanymi z badaniami nad pogodą kosmiczną, ujmować je w postaci tabel, wykresów czy schematów	K_U05
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	krytycznej oceny swojej wiedzy i odbieranych treści, rozumie potrzebę dalszego jej pogłębiania	K_K01
K_02	uznawania znaczenia wiedzy w rozwiązywaniu problemów poznawczych związanych z różnymi aspektami badań nad pogodą kosmiczną	K_K02
Forma i typy zajęć:		wykłady (30 godz.), ćwiczenia laboratoryjne (30 godz.)
Wymagania wstępne i dodatkowe:		
Znajomość podstaw statystyki oraz algorytmów eksploracji danych		
Treści modułu kształcenia:		
1. Naturalne zagrożenia w otaczającym świecie 2. Aktywność Słońca 3. Promieniowanie kosmiczne mierzone na Ziemi 4. Zjawiska słoneczne oraz pogody kosmicznej 5. Wpływ pogody kosmicznej na Ziemię i jej otoczenie 6. Zagrożenia jakie niosą ze sobą zjawiska pogody kosmicznej 7. Eksploracja baz danych słonecznych, heliofizycznych i geofizycznych 8. Analiza i prognozowanie zjawisk pogody kosmicznej		
Literatura podstawowa:		
1. Machine learning techniques for space weather, edited by Enrico Camporeale, Simon Wing, Jay R. Johnson, Elsevier (Amsterdam), 2019 2. Space Weather. The Physics Behind a Slogan, Editors: Klaus Scherer, Horst Fichtner, Bernd Heber, Urs Mall, Springer, 2005 (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line) 3. Solar Particle Radiation Storms Forecasting and Analysis. The HESPERIA HORIZON 2020 Project and Beyond, Editors: Olga E. Malandraki, Norma B. Crosby, Springer, 2018 (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line)		
Literatura dodatkowa:		
1. Space Weather and Coronal Mass Ejections, Tim Howard, Springer, 2014 (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line) 2. Space Weather. Research Towards Applications in Europe, Jean Lilensten, Springer, 2007 (książka w wersji pdf dostępna w BG UPH poprzez bazy on-line)		
Planowane formy/działania/metody dydaktyczne:		
Wykład wspomagany technikami multimedialnymi. Ćwiczenia laboratoryjne - zajęcia praktyczne przy komputerze, podczas których studenci będą wykonywać analizy i prognozy w oparciu o dane rzeczywiste: heliofizyczne, geofizyczne, słoneczne		
Sposoby weryfikacji efektów uczenia się osiąganym przez studenta:		

Symbol efektu	Metody weryfikacji efektów uczenia się
U_01 - U_04, K_01 - K_02	Efekty kształcenia będą sprawdzone podczas dyskusji w trakcie wykładów i ćwiczeń, jak również podczas wykonywania ćwiczeń laboratoryjnych przed komputerem.
W_01 - W_03	Efekty kształcenia będą sprawdzone podczas dyskusji w trakcie wykładów i ćwiczeń, jak również podczas kolokwium i zaliczenia.

Forma i warunki zaliczenia:

Przedmiot kończy się zaliczeniem pisemnym, do którego można przystąpić dopiero po uzyskaniu zaliczenia ćwiczeń laboratoryjnych. Zaliczenie laboratorium daje średnia ocen z poszczególnych zadań oraz kolokwium. Na ocenę końcową składa się w 50% ocena z laboratorium i w 50% ocena z zaliczenia pisemnego

Kryterium oceny końcowej:

51-60% ogólnej liczby punktów– ocena dst

61-70% ogólnej liczby punktów– ocena dst+

71-80% ogólnej liczby punktów– ocena db

81-90% ogólnej liczby punktów– ocena db+

91-100% ogólnej liczby punktów– ocena bdb

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
Udział w wykładach	30 godz.
Udział w ćwiczeniach	30 godz.
Udział w konsultacjach z przedmiotu	3 godz.
Samodzielne przygotowanie się do ćwiczeń	17 godz.
Samodzielne przygotowanie się do kolokwiów	20 godz.
Przygotowanie się do zaliczenia i obecność na zaliczeniu	25 godz.
Sumaryczne obciążenie pracą studenta	125 godz.
Punkty ECTS za przedmiot	5 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Seminarium dyplomowe
Nazwa w języku angielskim:		Diploma seminar
Język wykładowy:	polski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Matematyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		obowiązkowy
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	piąty, szósty	
Liczba punktów ECTS:	10	
Imię i nazwisko koordynatora przedmiotu:		Dyrektor Instytutu
Imię i nazwisko prowadzących zajęcia:		Osoby wyznaczone przez dyrekcję Instytutu
Założenia i cele przedmiotu:		Celem zajęć jest zapoznanie studenta z metodyką przygotowywania pracy zaliczeniowej i jej ustnej prezentacji, jak też przygotowanie studenta do egzaminu dyplomowego. Celem przedmiotu jest także weryfikacja umiejętności wykonania przez studentów samodzielnego lub zespołowego projektu. Realizacja tego celu wiąże się z osiągnięciem następujących celów szczegółowych: – umiejętność opracowania prawidłowego harmonogramu prac zarówno pod względem chronologicznym jak kalendarzowym, – umiejętność systematycznej pracy nad projektem, zgodnie z zatwierdzonym harmonogramem, – umiejętność rozwiązywania problemów oraz prezentowania opracowanych rozwiązań, – umiejętność raportowania postępów w pracy, – umiejętność przygotowania pisemnego opracowania.
Symbol efektu	Efekt uczenia się:	
	WIEDZA Student zna i rozumie:	
		Symbol efektu kierunkowego

W_01	zagadnienia z zakresu studiowanego kierunku	K_W01-K_W12
W_02	podstawowe narzędzia prowadzenia badań i obliczeń	K_W07
W_03	zagadnienia z różnych dyscyplin niezbędny do realizacji projektu	K_W01-K_W12
W_04	podstawy prawne i etyczne w zakresie pozyskiwania, przetwarzania i udostępniania danych	K_W13
W_05	technologie informacyjne	K_W14
Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	trafnie diagnozować problem, potrafi dostrzegać prawidłowości występujące w obrębie badanego problemu	K_U08, K_U09, K_U15
U_02	dobierać i właściwie wykorzystać źródła literaturowe, również w języku angielskim, do będącego przedmiotem projektu – problemu	K_U18, K_U20
U_03	planować, analizować, oceniać i wyciągać wnioski	K_U08
U_04	redagować spójną i logiczną wypowiedź ustną i pisemną z wykorzystaniem poprawnej i profesjonalnej terminologii	K_U20
U_05	samodzielnie planować i realizować własne uczenie się przez całe życie	K_U22
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	przestrzegania zasad uczciwości intelektualnej; postępuje etycznie	K_K04
K_02	rozpowszechniania aktualnej wiedzy	K_K02
K_03	samooceny własnych kompetencji i doskonalenia kwalifikacji zawodowych	K_K01, K_K02

Forma i typy zajęć:

Seminarium dyplomowe (30 godz. + 30 godz.)

Wymagania wstępne i dodatkowe:

Znajomość treści nauczania w dotychczasowym przebiegu studiów.

Znajomość programów komputerowych do edycji, opracowania wyników oraz ich prezentacji.

Treści modułu kształcenia:

Treści modułu kształcenia zawierają elementy wszystkich wykładów przewidzianych planem studiów I stopnia na studiowanym kierunku. Największy nacisk jest położony na podnoszenie umiejętności i kompetencji w zakresie opracowywania i prezentowania wyników oraz korzystania z fachowej literatury, także w języku angielskim.

Główne zagadnienia:

1. Precyzowanie obszaru zainteresowań studentów. Omówienie przez prowadzącego proponowanej tematyki projektów.

2. Sposoby zbierania materiałów źródłowych. Omówienie przez prowadzącego źródeł informacji naukowej oraz sposobów jej wyszukiwania i wykorzystywania. Przestrzeganie prawa autorskiego.
3. Zasady redagowania pracy pisemnej (referatu).
4. Prezentacja przez studentów referatów z zakresu wstępnie wybranej tematyki i celów ich prac projektowych – z wykorzystaniem środków multimedialnych. Dyskusja i ewentualna korekta tematów projektów. Określenie ich zakresu.
5. Omówienie przez prowadzącego zasad realizacji poszczególnych etapów projektów i ich multimedialnej prezentacji.
6. Prezentacja wyników realizacji określonych harmonogramami poszczególnych etapów pracy studentów nad projektami, dyskusja i ewentualne zalecenia korygujące.
7. Przedstawienie projektu.
8. Omówienie przebiegu egzaminu dyplomowego i obowiązującego na nim zestawu pytań.

Literatura podstawowa:

Specyficzna dla danej dziedziny i konkretnego tematu zlecona przez opiekuna/promotora pracy oraz samodzielnie wyszukane przez studenta w dostępnych źródłach (również elektronicznych) zarówno w języku polskim jak i obcym oraz, m.in.

1. R. Kozłowski, Praktyczny sposób pisania prac dyplomowych z wykorzystaniem programu komputerowego i Internetu, Warszawa 2009
2. W. Młyniec, S. Ufnalska, Scientific Communications, czyli jak pisać i prezentować prace naukowe, Poznań 2004

Literatura dodatkowa:

1. M. Cieślarczyk (red.), Poradnik metodyczny autorów prac magisterskich, dyplomowych i podyplomowych, Warszawa 2002.
2. Z. Stachowiak, Metodyka i metodologia pisania prac kwalifikacyjnych, Warszawa 2001.
3. W. Zaczyński, Poradnik autora prac seminaryjnych, dyplomowych i magisterskich, Warszawa 1995.

Planowane formy/działania/metody dydaktyczne:

Metoda słowna problemowa, dyskusja, prezentacja multimedialna. Poster lub prezentacja jako forma przedstawienia wyników projektu. Zastosowanie informatycznych programów, systemów oraz technik audiowizualnych.

Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:

Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_05, U_01 – U_05, K_01 – K_03	Weryfikację założonych efektów kształcenia dokonują w sposób ciągły prowadzący seminaria dyplomowe na podstawie udziału w dyskusji oraz podczas przedstawianych prezentacji na poszczególnych etapach realizacji projektu (I – uzasadnienie wyboru tematu, studia literaturowe, II – postawienie hipotezy, omówienie wybranej metody badawczej i przedstawienie uzyskanych wyników/projektów/rozwiązań, wnioski, weryfikacja postawionej hipotezy).

Forma i warunki zaliczenia:

Zaliczenia seminarium dyplomowego dokonuje się na podstawie udziału w zajęciach, przedstawienia referatu oraz posteru/prezentacji na zadany temat obejmujący materiał związany z tematyką projektu.

Bilans punktów ECTS:

Aktywność	Obciążenie studenta
-----------	---------------------

Udział w zajęciach	60 godz.
Udział w konsultacjach z przedmiotu	10 godz.
Samodzielne studia literaturowe	45 godz.
Przygotowanie referatu	25 godz.
Opracowywanie projektu	40 godz.
Przygotowanie prezentacji projektu	30 godz.
Przygotowanie się do egzaminu dyplomowego	40 godz.
Sumaryczne obciążenie pracą studenta	250 godz.
Punkty ECTS za przedmiot	10 ECTS

Sylabus przedmiotu / modułu kształcenia		
Nazwa przedmiotu/modułu kształcenia:		Praktyka zawodowa III
Nazwa w języku angielskim:	Professional practice III	
Język wykładowy:	polski	
Kierunek studiów, dla którego przedmiot jest oferowany:		Analiza danych
Jednostka realizująca:	Instytut Matematyki	
Rodzaj przedmiotu/modułu kształcenia (obowiązkowy/fakultatywny):		obowiązkowy
Poziom modułu kształcenia (np. pierwszego lub drugiego stopnia):		pierwszego stopnia
Rok studiów:	trzeci	
Semestr:	czwarty (zaliczenie w semestrze V)	
Liczba punktów ECTS:	10	
Imię i nazwisko koordynatora przedmiotu:		Kierunkowy opiekun praktyk
Założenia i cele przedmiotu:		Cele praktyki III: – pogłębienie umiejętności i kompetencji nabytych podczas praktyki I i II; – uzupełnienie wiedzy teoretycznej i praktycznej w zakresie analizy danych;• – organizowanie pracy własnej i pracy niewielkich zespołów; – przygotowanie do samodzielnej realizacji zadań i projektów.
Symbol efektu	Efekt uczenia się:	Symbol efektu kierunkowego
	WIEDZA Student zna i rozumie:	
W_01	organizację pracy i różne stanowiska w danym zakładzie pracy oraz obowiązujące procedury, zasady bezpieczeństwa i higieny pracy	K_W13, K_W14
W_02	rozwiązania informatyczne stosowane w zakresie analizy danych w firmie/instytucji, w której odbywa praktykę zawodową, potrafi ich użyć w tym zakresie. Posiada wiedzę dotyczącą projektowania nowych rozwiązań	K_W07, K_W11, K_W12
W_03	zagadnienia z zakresu baz danych, orientuje się w obecnym stanie oraz najnowszych trendach rozwojowych i standardach z tego zakresu wykorzystywanych w firmie/instytucji, w której odbywa praktykę zawodową.	K_W09

Symbol efektu	UMIEJĘTNOŚCI Student potrafi:	Symbol efektu kierunkowego
U_01	posługiwać się technikami i narzędziami wykorzystywanymi w eksploracji danych, zaprojektować nowe rozwiązania na potrzeby firmy/instytucji, w której odbywa praktykę zawodową	K_U11, K_U12, K_U16
U_02	przeprowadzić eksplorację danych rzeczywistych na dużych zbiorach danych, wybrać optymalny system dla danego zadania	K_U14, K_U15, K_U16
U_03	pozyskiwać dane do analizy	K_U13
U_04	kierować pracami zespołu, planować pracę zespołu, także o charakterze interdyscyplinarnym	K_U21
U_05	samodzielnie planować i realizować własny rozwój zawodowy	K_U22
Symbol efektu	KOMPETENCJE SPOŁECZNE Student jest gotów do:	Symbol efektu kierunkowego
K_01	uznawania znaczenia wiedzy w rozwiązywaniu problemów poznawczych i praktycznych oraz zasięgania opinii ekspertów w przypadku trudności	K_K02
K_02	myślenia i działania w sposób samodzielny i przedsiębiorczy; wykazuje się inicjatywą	K_K03
Forma i typy zajęć:		Praktyka – zajęcia poza pomieszczeniami dydaktycznymi UwS; w wybranych przez studenta jednostkach, państwowych i prywatnych instytucjach zajmującymi się analizą danych.
Wymagania wstępne i dodatkowe:		
Przedmioty podstawowe, przedmioty kierunkowe		
Treści modułu kształcenia:		
Szczegółowe treści w zależności od miejsca wykonywania praktyk zawodowych. Mogą one obejmować między innymi: – organizowanie pracy własnej i pracy niewielkich zespołów; kierowanie pracami zespołu; – przygotowanie do samodzielnej realizacji zadań i projektów; – planowanie i przeprowadzanie zaawansowanych prac projektowych, programistycznych; – łączenie w duże zbiory danych informacji z różnych baz danych mając na uwadze ich różnorodność oraz często, brak jasno określonej struktury; – umiejętne stosowanie niestandardowych metody analizy dużych i niejednorodnych zbiorów danych; – samodzielne i zespołowe wykonywanie konkretnych zadań na zajmowanym stanowisku pracy zleconych przez kierownictwo zakładu.		
Literatura podstawowa:		
Literatura podana przez opiekuna praktyki z ramienia zakładu pracy: dokumenty wytworzone w danym zakładzie pracy; obowiązujące regulaminy, stosowane akty prawne i normatywne; instrukcje obsługi aparatury i urządzeń.		

Literatura dodatkowa:	
J.w.	
Planowane formy/działania/metody dydaktyczne:	
Sposoby weryfikacji efektów uczenia się osiągniętych przez studenta:	
Symbol efektu	Metody weryfikacji efektów uczenia się
W_01 – W_03, U_01 – U_05, K_01, K_02	Podstawą weryfikacji efektów kształcenia będą: ocena praktykanta dokonana przez opiekuna z ramienia zakładu pracy; ankieta wypełniona przez praktykanta i opiekuna praktykanta i dostarczona do uczelni; ocena formalna i merytoryczna dziennika praktyk prowadzonego przez praktykanta, a dokonana przez opiekuna praktykanta z ramienia UwS a także wyniki kontroli praktyk dokonywanych przez opiekuna praktyk ze strony UwS oraz innych osób – wyznaczonych przez Dziekana.
Forma i warunki zaliczenia:	
Terminowe dostarczenie wymaganej dokumentacji przed, w trakcie i po odbyciu praktyk, Uzyskanie pozytywnej oceny za odbytą praktykę u opiekuna praktykanta z ramienia zakładu (ocena praktykanta), Uzyskanie pozytywnej oceny za prawidłowe i rzetelne prowadzenie dziennika praktyk u opiekuna z ramienia uczelni.	
Bilans punktów ECTS:	
Aktywność	Obciążenie studenta
Udział w zorganizowanej formie pracy na terenie zakładu pracy – miejscu odbywania praktyki pod nadzorem opiekuna zakładowego	128 godz.
Wykonywanie zadań zleconych przez opiekuna zakładowego	192 godz.
Sumaryczne obciążenie pracą studenta	320 godz.
Punkty ECTS za przedmiot	10 ECTS