SYLABUS PRZEDMIOTU ZAJĘĆ W SZKOŁACH DOKTORSKICH

1.	Nazwa przedmiotu w języku polskim oraz angielskim **Bayesowska analiza danych/Bayesian Data Analysis**
2.	Dyscyplina **matematyka**
3.	Język wykładowy **język angielski**
4.	Jednostka prowadząca przedmiot **Instytut Matematyczny UWr**
5.	Kod przedmiotu *(jeśli jest ustalony)*
6.	Rodzaj przedmiotu *(obowiązkowy lub do wyboru)* do wyboru
7.	Nazwa Kolegium Doktorskiego **Kolegium Doktorskie Matematyki**
8.	Rok studiów *(jeśli obowiązuje*) dowolny
9.	Semestr *(zimowy lub letni)* zimowy
10.	Formy i metody prowadzenia przedmiotu Zajęcia e-learning
11.	Imię, nazwisko, tytuł/stopień naukowy osoby prowadzącej zajęcia **prof. Emmanuel Lesaffre**
12.	Treści programowe I Wprowadzenie 1. Statystyki opisujące rozkład a posteriori (definicje i obliczenai). 2. Metody losowania dla jednowymiarowych rozkładów a posteriori: typowe podejścia, algorythm accept-reject, techniki sampling-resampling. 3. Bayesowskie testowanie hipotez: prawdopodobieństwa konturowe i współczynnik Bayesa. 4. Bayesowskie wnioskowanie dla wielu parametrów: rozkład a posteriori dla rozkładu z nieznaną średnią i wariancją, popularne rozkłady, metody losowania dla rozkładów wielowymiarowych. II Rozkład a priori 1. Sprzężony rozkład a priori: wyprowadzenie, dalsze przykłady, pół-sprzężenie. 2. Wyrażanie braku wiedzy: nieinformatywny rozkład a priori, "vague prior", rozkład a priori Jeffrey'a, niewłaściwe rozkłady a priori. 3. Informatywne rozkłady a priori: rozkłady oparte na danych, uwzględnienie wiedzy a priori, archetypiczne rozkłady a priori, rozkłady a priori dla modeli regresyjnych, modelowanie rozkładów a priori. III Techniki Markov Chain Monte Carlo 1. Gibbs sampler: wprowadzenie i przykłady. 2. Algorytm Metropolisa(-Hastingsa): wprowadzenie i przykłady. 3. Własności algorytmów losowania i ich wybór. 4. Odwracalny algorytm MCMC ze skokami. 5. Sprawdzanie zbieżności algorytmu: metody graficzne i formalne.

	6. Przyśpieszanie zbieżności. 7. Algorytm Data Augmentation IV Oprogramowanie bayesowskie 1. Szczegóły wykorzystania WinBUGS, i powiązanych programów: OpenBUGS, R2WinBUGS 2. Bayesowskie procedury w SAS-ie 3. Krótki przegląd innych programów bayesowskich. V Modele hierarchiczne 1. Model hierarchiczny Poisson-gamma 2. Gaussowski model hierarchiczny 3. Porównanie: pełny model bayesowski vs empiryczny model bayesowski. 4. Bayesowskie modele mieszane: liniowe, uogólnione liniowe i nieliniowe. 5. Różne tematy: wybór rozkłady a priori dla wariancji, własności rozkładów a posteriori, porównanie z metodami częstościowymi. VI Budowa i ocena modeli 1. Współczynnik Bayesa i jego warianty, np. pseudo-Bayes. 2. Wybór modelu na podstawie predykcyjnej funkcji straty. 3. Analiza reszt 4. Analiza czułości 5. Analiza predykcyjnego rozkładu a posteriori 6. Metody rozszerzania modeli	
13.	Zakładane efekty uczenia się Wiedza: - zna teoretyczne podstawy statystyki Bayesowskiej; - zna współczesne metody obliczeniowe statystyki Bayesowskiej. Umiejętności: - potrafi skonstruować Bayesowski model hierarchiczny do analizy konkretnego zbioru danych; - potrafi przeprowadzić formalne wnioskowanie Bayesowskie; -potrafi zaimplementować podstawowe metody próbkowania z rozkładu aposteriori; -potrafi skorzystać z zaawansowanego oprogramowania z implementacją statystyki Bayesowskiej; -potrafi wykorzystać zaawansowaną wiedzę statystyczną do analizy rzeczywistych zagadnień naukowych i społecznych. Kompetencje społeczne: - jest gotów do śledzenia literatury naukowej i rozumie potrzebę ciągłego dokształcania.	Symbole efektów uczenia się: P8S_WG (SD_W01, SD_W02) P8S_UW (SD_U01, SD_U03); P8S_UK (SD_U05) P8S_KK (SD_K01); P8S_KO (SD_K02)
14.	Literatura obowiązkowa i zalecana *(źródła, opracowania, podręczniki, itp.)* Notatki ""Bayesian Data Analysis II"". Lesaffre, E. and Lawson, A. Bayesian Biostatistics, John Wiley & Sons, 2012	
15.	Metody weryfikacji zakładanych efektów uczenia się: **Projekt (pisemne zadania domowe), egzamin ustny.**	
16.	Liczba punktów ECTS *(jeśli jest wymagana)*	