

MS08: Stochastic Modeling, Statistics and Uncertainty Quantification

PARTE I

1. Gerônimo G. Z. Lemos, Juliana A. Anochi, Haroldo F. Campos Velho

Institution: INPE (National Institute for Space Research)

Title: Machine learning for climate precipitation prediction: preprocessing, prediction model, and post-processing

Abstract: Machine Learning (ML) algorithms have been successfully used in geophysical fluid dynamics, especially in meteorology. In fact, climate and climate predictions are very relevant issues, due to the climate and the economic sectors. In operational forecasting centers, there are at least three steps for the operational prediction: pre-processing, the execution of the prediction model, and the post-processing task. The most common pre-processing procedure is the data assimilation (DA), estimating the best initial condition for the model execution. After that, the forecasting system is executed using the initial condition calculated by the DA process. Finally, the estimation of the prediction degree – or the prediction uncertainty quantification (UQ) – is linked to the prediction. The study is focused on the development of ML for the three mentioned stages. The convolutional neural network (NN) U-Net is designed as a DA operator. Another convolutional NN is used as a model for climate precipitation prediction in the South American region. A decision tree algorithm is employed for quantifying forecast uncertainties in a climate model.

2. Prof. Eduardo Cursi, INSA-Rouen

Título: Quantificação de Incertezas – exemplos, perspectivas e desafios

Resumo: A Quantificação de incertezas (QI ou, em inglês, UQ) é geralmente definida como um conjunto de métodos e ferramentas para a caracterização das incertezas, variabilidades e erros em modelos, assim como de seus efeitos sobre os resultados. Tradicionalmente, a QI adota um ponto de vista probabilista e busca determinar distribuições de probabilidade. Este ponto de vista tem raízes históricas nas Engenharias Civil e Mecânica e um dos desafios futuros da QI é a integração de outros pontos de vista, de forma colaborativa ou complementar. Desde suas origens históricas, a Quantificação de Incertezas também tem procurado se abrir a outras áreas, tais como a epidemiologia, a economia, a informática. Apresentaremos nesta conferência uma introdução histórica, exemplos destas novas aplicações e discutiremos alguns dos desafios e perspectivas desta área.

3. Prof. Pablo M. Rodriguez

Head of the Graduate Program in Statistics (since 2022)
Federal University of Pernambuco – UFPE

Título: Processos de ramificação aplicados ao estudo de processos estocásticos especiais

Resumo: A teoria dos processos de ramificação teve origem a partir da análise da probabilidade de extinção dos sobrenomes de uma família e, com o tempo, tornou-se uma ferramenta valiosa na modelagem de fenômenos físicos e biológicos. Considere um fenômeno aleatório onde partículas produzem novas partículas de maneira independente, conforme uma variável aleatória discreta que assume valores inteiros não negativos. Supondo que esse conjunto aleatório de partículas seja organizado em gerações — com a geração inicial composta por uma única partícula —, a sequência de variáveis aleatórias que contabiliza o número de partículas por geração constitui um processo estocástico conhecido como processo de ramificação. Nesta palestra, exploraremos aplicações recentes desses processos no estudo de diversos processos estocásticos especiais.

4. Profa. Roberta Lima, PUC-Rio

Título: Applications of ramifications processes to the prodding of a dicease

Resume: In this paper, the spread of an epidemiological disease over time is modeled as a Bienaymé-Galton-Watson process. Therefore, a discrete random variable models the number of infections per infector and rules the branching process. Given this probabilistic model, the aim is to compare theoretically and computationally methodologies to get mass functions of further generations' size: probability generating functions, polynomial identities, Markov chain and Monte Carlo simulation. Comparisons are done in two distinct levels. The first is a local one, in which for the same generation, the analysis are done state by state. The other is a global, which focus on the whole support of each generation. Results show that the first two methodologies are not able to cover the entire support, due runtime issues in the probability generating functions approach and lack of RAM in the polynomial one. On the other hand, they give likelihood functions for bayesian inference, because their algorithm works with symbolic computation. Moreover, they are the only ones to also perform a local analysis. Despite of the limitation of the random variable modeling the contagion in Markov chain's technique, it has more advantages in terms of runtime and storage than the previous methods and still provides analytical relations, since it also works with symbolic computation. The further the generation is, Monte Carlo seems to be the only feasible approach, but as a consequence all the features evaluated are then random objects that need a more careful analysis and the requirement to perform bayesian inference is lost.

PARTE II

Na segunda parte, um painel, com um título provisório:

Título: Presente e futuro de Modelagem Estocástica e Quantificação de Incertezas no Brasil.

Mediador: Prof. Rubens Sampaio, PUC-Rio.