

# Redes de Estado de Eco Híbridas para Simulação Rápida e Controle de Processos Industriais

Proposta de Dissertação de Mestrado 2020/2021

## Orientadores

Prof. Eric Aislan Antonelo

Prof. Eduardo Camponogara (co-orientador)

## Palavras-chave

Aprendizagem de máquina, sistemas dinâmicos, controle preditivo, inteligência artificial

## Introdução

Sistemas do mundo real podem ser representados matematicamente por equações diferenciais ordinárias (EDO) ou equações diferenciais parciais (EDP), por exemplo, as quais são formuladas usando leis físicas já conhecidas. Alguns exemplos são: previsão do tempo (clima), dinâmica de fluídos, modelagem de turbulências, modelagem de plataformas de produção e reservatórios de petróleo e gás. A simulação computacional desses sistemas não-lineares dinâmicos é necessária para o estudo do comportamento dos mesmos em diferentes circunstâncias, bem como para sua utilização em tomadas de decisão, como o controle de plantas industriais. No entanto, essa simulação pode ser bastante custosa computacionalmente se o sistema é grande e complexo. Nesse contexto, modelos de **aprendizagem de máquina** (AM) podem ser úteis para diminuir significativamente o custo computacional ao usar dados provenientes da medição de variáveis do processo em questão. Essa abordagem direcionada a dados (*data driven*) pode ser combinada com o conhecimento físico a priori do processo, o que permite:

- reduzir a quantidade de dados requerida para um modelo de AM aprender corretamente o comportamento dinâmico do processo;
- regularizar o modelo de AM a partir do conhecimento físico a priori, restringindo e informando que seu funcionamento deve obedecer a certas leis físicas;
- em um contexto de *indústria 4.0*, acelerar a simulação de processos, visto que a execução de um modelo de AM é muitas ordens de magnitude mais rápida que a de sistemas grandes de PDO ou EDO.

Uma das abordagens recentes que usam aprendizagem profunda para alcançar esta combinação é denominada *Physics-informed neural networks* [3]. Nesta abordagem, o tempo  $t$  é dado como entrada para uma rede neural estática modelar uma certa EDO, o que gera dificuldades de generalização na fase

de teste quando  $t$  é maior que os valores visto no treinamento. Por outro lado, redes de estado de eco (REE) [2] são redes neurais recorrentes que naturalmente modelam sistemas dinâmicos, não necessitando de ter o tempo  $t$  como entrada, e que apresentam rápido treinamento, constituindo um forte candidato para combinar o conhecimento físico de plantas de processos industriais em seu funcionamento (REE híbridas [1]).

## Objetivos

Neste tema de dissertação de mestrado, baseado em conceitos e resultados do estado-da-arte em de aprendizagem de máquina informada pela física (*physics-informed machine learning*), o mestrando buscará desenvolver:

- modelos de Redes de Estado de Eco (REE) híbridas que utilizem conhecimento físico do processo em seu treinamento e/ou predição a fim de obter simulação rápida e consistente com a física;
- métodos para síntese de modelos simplificados de poços de petróleo a partir de medições de campo, dados históricos e ODEs, usando REE híbridas (informada pela física).
- controle preditivo de plantas não-lineares complexas com modelos do tipo REE.

## Perfil do candidato

Você tem: habilidade para leitura e escrita na língua inglesa e capacidade de trabalho individual e em grupo; e grande motivação para estudos avançados. É desejável ter experiência em: frameworks em Python **tensorflow/pytorch** (redes neurais), **CasADi** (diferenciação automática, otimização e controle), e base sólida de conhecimento em aprendizagem de máquina (e.g.: treinamento, *overfitting*, validação cruzada, etc.).

## Plano de atividades preliminar

O mestrando selecionado se capacitará em temas relevantes como redes neurais recorrentes, redes de estado de eco, arquitetura híbridas usando conhecimento a priori, e implementará modelos segundo a metodologia proposta. As seguintes atividades estão previstas:

1. **Capacitação em Aprendizagem de Máquina:** Consiste no estudo dos conceitos básicos de aprendizagem de máquina (AM), em especial aprendizagem supervisionada do tipo regressão. Inclui também o estudo de redes neurais recorrentes do tipo Redes de Estado de Eco e propostas de arquiteturas híbridas da literatura levando em conta o conhecimento físico.
2. **Capacitação em simulação de sistemas dinâmicos:** Consiste no estudo e simulação numérica (métodos de Euler e Runge-Kutta) de sistemas dinâmicos clássicos da literatura de controle em uma primeira etapa, e de um modelo de poço ou reservatório de petróleo e gás disponível em forma de um sistema de EDOs em um segundo momento. Ensaios experimentais serão realizados através da programação em Python e uso de bibliotecas como CasADi (ferramenta de código aberto para diferenciação algorítmica e otimização não-linear).

3. **Coleta de dados experimentais:** Para a identificação do processo escolhido, será fundamental definir e realizar a coleta adequada de dados experimentais da planta a partir da simulação numérica das EDOs implementadas no passo anterior, usando uma ação de controle  $\mathbf{u}(t)$  representativa e por tempo suficiente para o treinamento de modelos de AM. O conjunto de dados coletados é definido por um conjunto de pares  $\{(\mathbf{u}_i, \mathbf{y}_i) | i = 1, \dots, N\}$ , gerado considerando um certo período de amostragem, e onde  $\mathbf{y}_i$  corresponde a resposta do sistema (ex.: pressão de fundo de poço).
4. **Implementação de modelos REE informados pela física:** Consiste no desenvolvimento de propostas de arquiteturas híbridas de REE que utilizam o conhecimento físico dado pela EDO em duas principais abordagens: a primeira usa uma simulação computacionalmente barata de EDO na função de custo da REE, fornecendo um método de regularização para o treinamento da mesma; a segunda abordagem consiste em usar as amostras de um simulador barato da EDO tanto na fase de treinamento quanto na fase de predição. O *framework* de aprendizagem profunda *tensorflow* em Python será empregado para a implementação dos métodos.
5. **Avaliação e Comparação:** Nesta etapa, os modelos desenvolvidos anteriormente serão avaliados estatisticamente, considerando múltiplas realizações tanto da REE quanto da ODE. A influência de parâmetros da REE e do período de amostragem no desempenho do modelo serão investigados. Comparações serão realizadas entre modelos sem ou com conhecimento físico integrado, e também entre diferentes formas de hibridização da REE.
6. **Redação de documentos:** Consiste na escrita de artigos científicos relacionados a este tema e aos resultados obtidos e da dissertação de mestrado.

## Referências bibliográficas

- [1] Nguyen Anh Khoa Doan, Wolfgang Polifke, and Luca Magri. Physics-informed echo state networks for chaotic systems forecasting. In *International Conference on Computational Science*, pages 192–198. Springer, 2019.
- [2] Herbert Jaeger and Harald Haas. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless telecommunication. *Science*, 304(5667):78–80, Apr 2004.
- [3] Maziar Raissi, Paris Perdikaris, and George E Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378:686–707, 2019.