

Redes Neurais Recorrentes para MPC de Sistemas Dinâmicos Desconhecidos

Proposta de Dissertação de Mestrado

Orientador: Eduardo Camponogara

Coorientador: Thiago Lima Silva

Julho de 2017

1 Informações Gerais

- **Áreas de concentração:** controle e automação.
- **Início:** agosto/2017.
- **Previsão de término:** março/2019.
- **Experiência Prévia:** é desejável conhecimento em sistemas de controle, interesse em programação em linguagens como Python e Matlab, e capacidade para trabalho individual e em grupo.

2 Objeto da Pesquisa

2.1 Problemática

Controle Preditivo Baseado em Modelo (MPC) é uma estratégia de controle avançado que produz ações de controle a partir da otimização iterativa de uma função objetivo, ocorrendo sobre um intervalo de predição deslizante no tempo, enquanto toma como base um modelo do sistema dinâmico [3]. A partir da aproximação local do processo com um modelo linear, MPC linear pode ser aplicado utilizando mecanismos de compensação e predição de erros entre o modelo e o processo. Contudo, modelos lineares não são suficientemente precisos para modelos fortemente não lineares, para os quais MPC linear poderá levar a um desempenho insatisfatório. Em geral, MPC não linear leva à solução de problemas de otimização não convexos [8], por isso não existem métodos eficientes que garantem o cálculo do controle ótimo para tais problemas.

Uma outra questão se refere à otimização em tempo real. Redes Neurais Recorrentes (RNR) surgiram como uma abordagem promissora, que consiste de

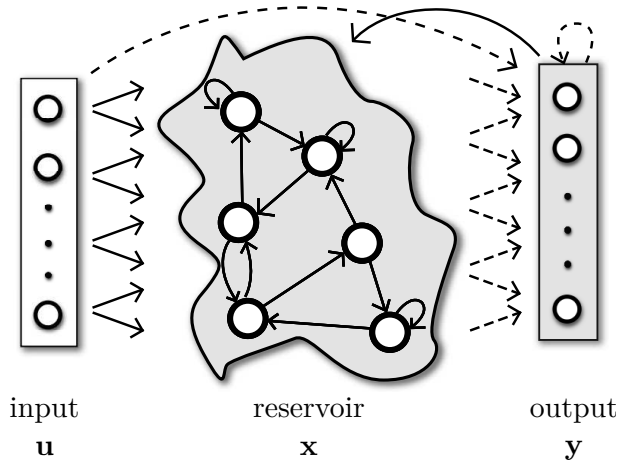


Figura 1: Arquitetura de uma Rede de Estado de Eco. A camada interna consiste de unidades com estado que evolue no tempo segundo uma dinâmica não linear recorrente. O treinamento se dá pela combinação linear dos estados das unidades do reservatório (camada interna, reservatório), que resulta em um problema de mínimos quadrados.

uma ferramenta computacional baseada em objetivos que pode resolver diversos problemas de otimização. Utilizando dualidade e projeção, diversas RNRs foram desenvolvidas para resolver problemas de programação linear, programação quadrática e o problema geral de otimização não convexa. Tais RNRs apresentaram características desejáveis e atingiram desempenho superior em termos de convergência global e baixa complexidade de modelo [14, 15, 16].

Além de otimização em tempo real, quando o modelo do processo não é conhecido, se faz necessário a identificação do sistema [4]. Diversos estudos sobre identificação e controle de sistemas não lineares empregaram redes neurais [11, 10]. RNRs demonstraram uma capacidade superior e obtiveram sucesso em aplicações de modelagem e controle de sistemas dinâmicos não lineares [10].

Mais recentemente as Redes de Estado de Eco (ESN, Echo State Networks) demonstram grande potencial de modelagem com um problema de treinamento relativamente simples. ESNs são modelos de aprendizagem dinâmicos compostos por duas partes: uma rede neural recorrente com ponderação fixa e uma camada de saída de pesos adaptativos, conforme ilustra a Figura 1. A partir da resolução de um problema de mínimos quadrados, os pesos da camada de saída são treinados para a rede reproduzir padrões temporais. Tais redes obtiveram resultados promissores na identificação e controle em malha-fechada de sistemas dinâmicos [9, 13, 2, 1, 6, 7].




Figura 2: Estrutura básica de um riser.

2.2 Objetivos

Motivado pelos resultados promissores discutidos acima, este projeto de mestrado visa desenvolver e aplicar uma estratégia de controle MPC baseada em redes neurais recorrentes para sistemas não lineares desconhecidos. A estratégia irá seguir a metodologia proposta em [12], que relaxa o problema de otimização não convexa com um problema quadrático convexo definido a partir uma linearização Jacobiana. A estratégia será aplicada ao controle anti-golfada de poços e risers de petróleo e gás [5].

Os objetivos específicos são:

1. Estudar estratégias de MPC baseadas em Redes de Estado de ECO para controle de sistemas dinâmicos não lineares desconhecidos.
2. Implementar e testar as estratégias de MPC baseadas em ESNs com aplicações ao controle anti-golfada de poços e risers de petróleo.

3 Metodologia

O plano de trabalho consiste de etapas metodológicas delineadas no sentido de se atingir os objetivos propostos. São elas:

1. cursar disciplinas básicas e especializadas da pós-graduação durante o 3º e 4º bimestre de 2017;
2. estudar a teoria básica sobre Redes Neurais Recorrentes, com ênfase em Redes de Estado de Eco;
3. estudar a teoria básica sobre MPC para sistemas dinâmicos não lineares desconhecidos, realizando implementações didáticas para dominar esta tecnologia;
4. revisar a literatura técnica relacionada a RNRs, ESNs e MPC;

5. implementar modelos de simulação de poços e risers de petróleo em ambientes de simulação, tais como Modelica e Matlab;
6. implementar e testar estratégias de MPC baseado em ESNs para controle anti-golfada de poços e risers;
7. redação e submissão de artigos;
8. redação e defesa da dissertação de mestrado.

Está previsto o aprofundamento técnico-científico com estudos as serem realizados nas seguintes disciplinas:

1. Disciplinas a serem cursadas no 3º bimestre de 2017:
 - (a) DAS-410036 Metodologia Científica, 2 créditos.
2. Disciplinas a serem cursadas no 4º bimestre de 2017:
 - (a) DAS-410036 Metodologia Científica, 2 créditos.
 - (b) DAS-410066 Controle Preditivo, 2 créditos.

As ferramentas de desenvolvimento incluem: Modelica; Python; Pacote Sundials para simulação e solução numérica de equações diferenciais; Ferramenta de controle de versão de software Git.

Outros Membros da Equipe:

- Dr. Marcelo Lima (Pesquisador CENPES Petrobras)
- Doutorando Marco Aurélio Schmitz de Aguiar (PPGEAS)
- Mestrando Jean Jordanou (PPGEAS)

Bibliografia de Referência

- [1] Eric Antonelo, Eduardo Camponogara, and Bjarne Foss. Echo state networks for data-driven downhole pressure estimation in gas-lift oil wells. *Neural Networks*, 85:106–117, 2017.
- [2] Eric A Antonelo and Benjamin Schrauwen. On learning navigation behaviors for small mobile robots with reservoir computing architectures. *IEEE Transactions on Neural Networks and Learning Systems*, 26(4):763–780, 2015.
- [3] E.F. Camacho and C. Bordons. *Model Predictive Control*. Springer, Berlin, 2004.
- [4] Antônio Augusto Rodrigues Coelho and Leandro dos Santos Coelho. *Sistemas Dinâmicos Lineares*. editora UFSC, 2004.

- [5] Esmacil Jahanshahi, Sigurd Skogestad, and Henrik Hansen. Control structure design for stabilizing unstable gas-lift oil wells. *IFAC Papers Online*, 45(15):93–100, 2012.
- [6] Jean Jordanou. Echo state networks for control of dynamic systems. Technical report, UFSC, 2016. Relatório de Estágio do Curso de Engenharia de Controle e Automação.
- [7] Jean Jordanou. Recurrent neural network based control for risers and oil wells. Technical report, UFSC, 2017. Projeto de Fim de Curso de Engenharia de Controle e Automação.
- [8] B. Kouvaritakis and M. Cannon. *Nonlinear Predictive Control: Theory and Practice*. Edison, 2001.
- [9] Xiaowei Lin, Zehong Yang, and Yixu Song. Short-term stock price prediction based on echo state networks. *Expert Systems with Applications*, 36(3):7313–7317, 4 2009.
- [10] C. Lu and C. Tsai. Adaptive predictive control with recurrent neural network for industrial processes: An application to temperature control of a variable-frequency oil-cooling machine. *IEEE Transactions on Industrial Electronics*, 55(3):1366–1375, 2008.
- [11] K. Nardnera and K. Parthasarathy. Identification and control of dynamical system using neural networks. *IEEE Transactions on Neural Networks*, 1(1):4–27, 1990.
- [12] Yunpeng Pan and Jun Wang. Model predictive control of unknown nonlinear dynamical systems based on recurrent neural networks. *IEEE Transactions on Industrial Electronics*, 59(8):3089–3101, 2012.
- [13] Tim Waegeman, Francis Wyffels, and Benjamin Schrauwen. Feedback control by online learning an inverse model. *IEEE Transactions on Neural Networks and Learning Systems*, 23(10):1637–1648, 10 2012.
- [14] J. Wang. A deterministic annealing neural network for convex programming. *Neural Networks*, 7(4):629–641, 1994.
- [15] Y. Xia. A new neural network for solving linear and quadratic programming problems. *IEEE Transactions on Neural Networks*, 7(6):1544–1548, 1996.
- [16] Y. Xia, G. Feng, and J. Wang. A recurrent neural network with exponential convergence for solving convex quadratic program and related linear piecewise equations. *Neural Networks*, 17(7):1003–1015, 2004.