Encontro Nacional do Programa de Formação de Recursos Humanos da ANP - 2026

Controle Reinforcement Learning de atuadores robóticos para compensação ativa de ondas em operações offshore

Bolsista: William Rodrigo Lüdtke

Orientadora: Profª Drª Giuliana Sardi Venter

2º orientador: Prof Dr Eduardo Márcio de Oliveira Lopes

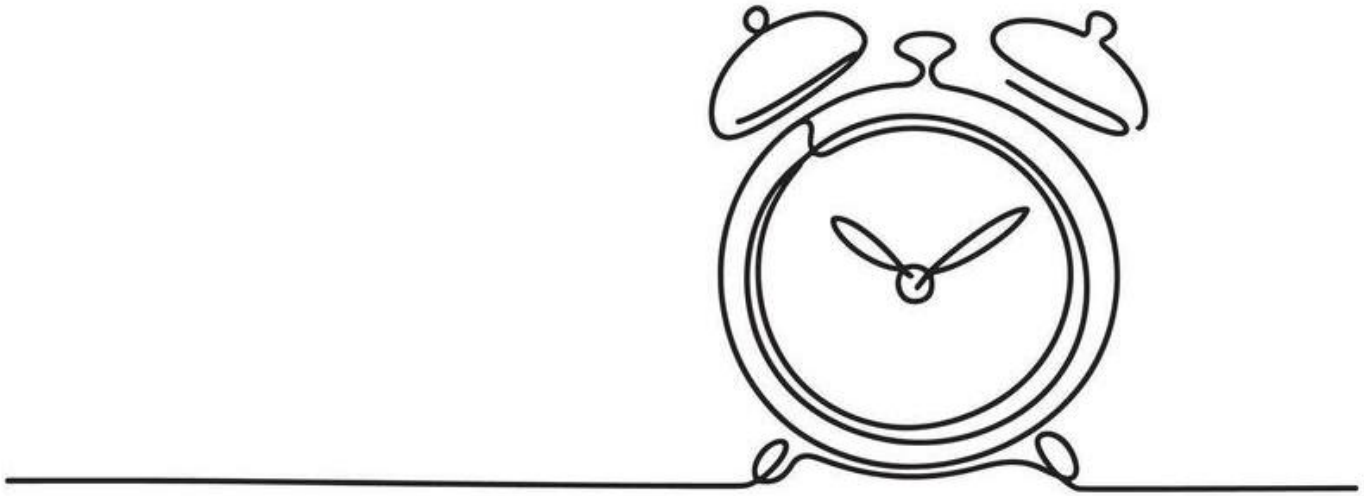
PRH 12/UFPR

Tipo de bolsa: Mestrado

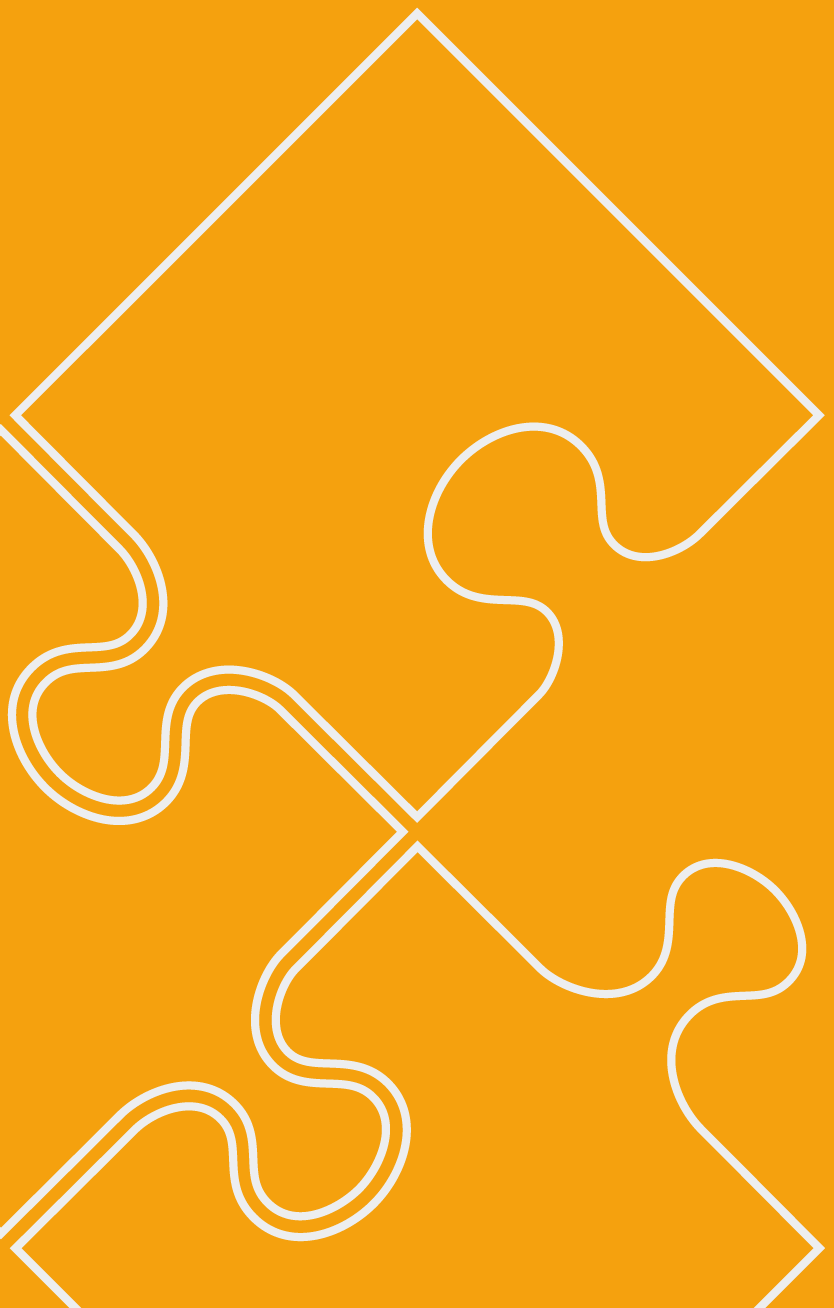
Universidade Federal do Paraná (UFPR)

Gestão:

EM MANUTENÇÃO



SLB-Private



1

Tempo parado é tempo perdido

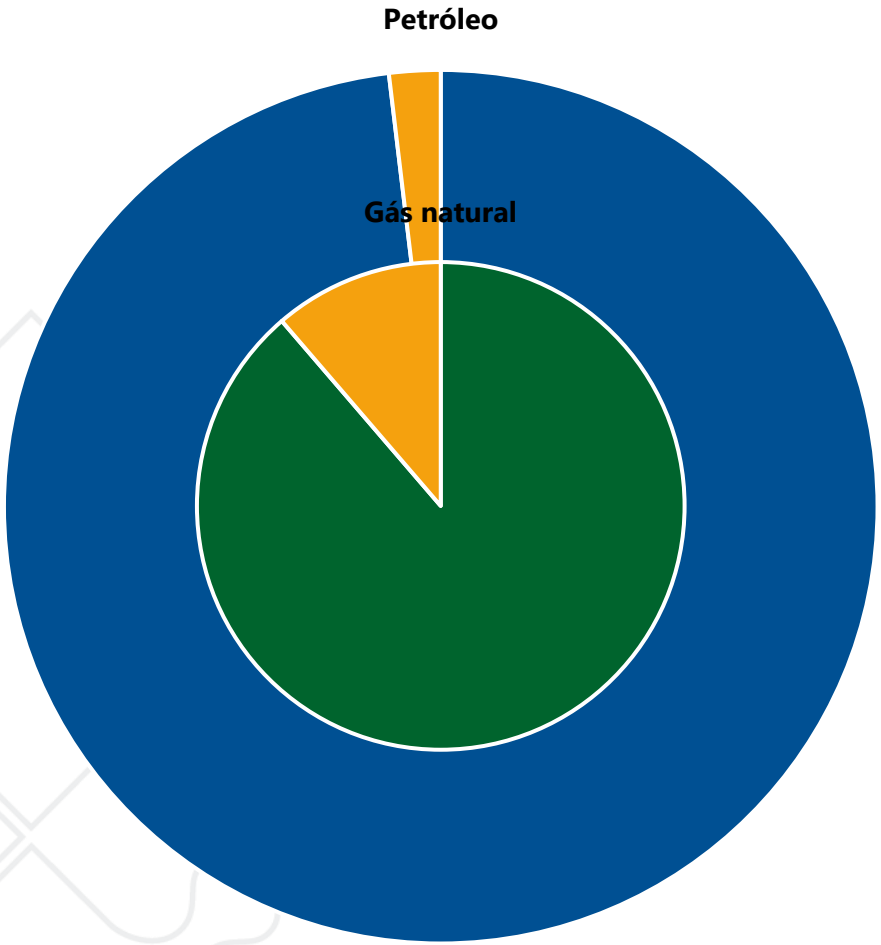
INDÚSTRIA DE PETRÓLEO E GÁS



Fonte: Agencia Brasil (2009)

SLB-Private

PRODUÇÃO OFFSHORE



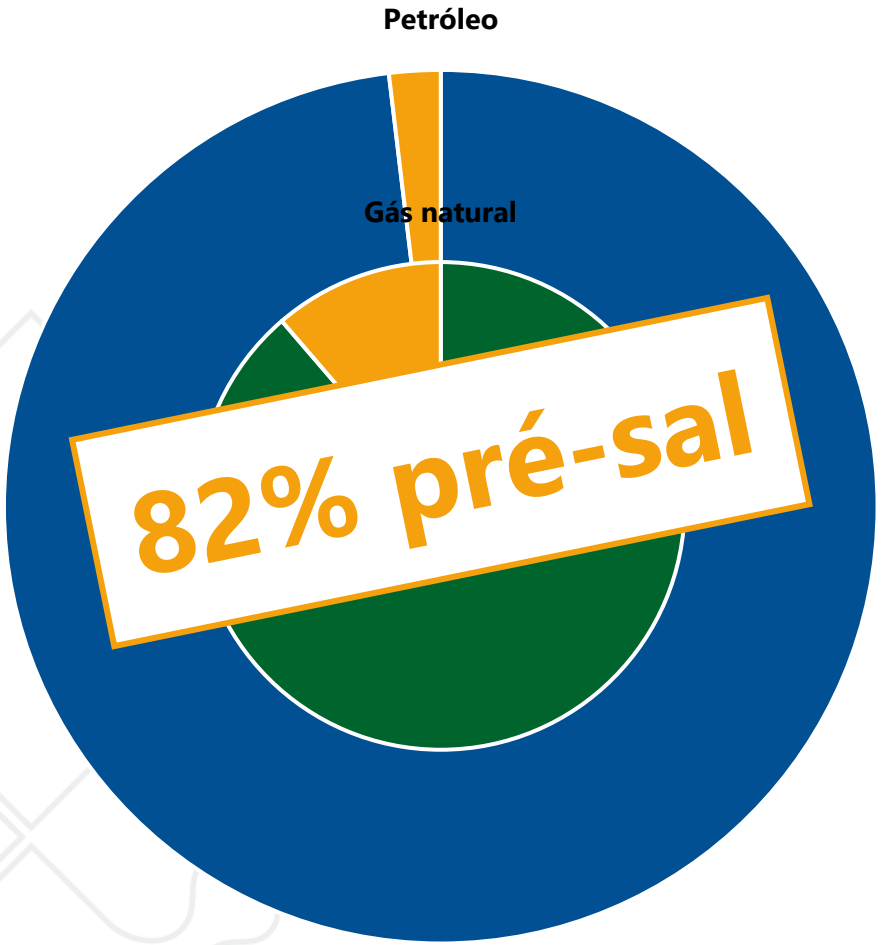
98% do petróleo

89% do gás natural

Fonte: ANP (2026)

SLB-Private

PRODUÇÃO OFFSHORE



98% do petróleo

89% do gás natural

Fonte: ANP (2026)

SLB-Private

CUSTO DE PARADA

409k USD/dia

Fonte: Bermuda (2026)



Fonte: Seadrill (2025)

SLB-Private

CUSTO DE PARADA

409k USD/dia

Fonte: Bermuda (2026)

1% a.a. = 3,65 dias



Fonte: Seadrill (2025)

SLB-Private

CUSTO DE PARADA

409k USD/dia

Fonte: Bermuda (2026)

1% a.a. = 3,65 dias



Fonte: Seadrill (2025)

409k

x 3,65

USD 1.49 Mi

SLB-Private

CUSTO DE PARADA

409k USD/dia

Fonte: Bermuda (2026)

1% a.a. = 3,65 dias

409k
x 3,65
USD 1.49 Mi

10% a.a. = 36,5 dias

Fonte: Moore et al. (2024)

409k
x 36,5
USD 14.9 Mi

SLB-Private

PLANO DE NEGÓCIOS PETROBRAS 2026-2030

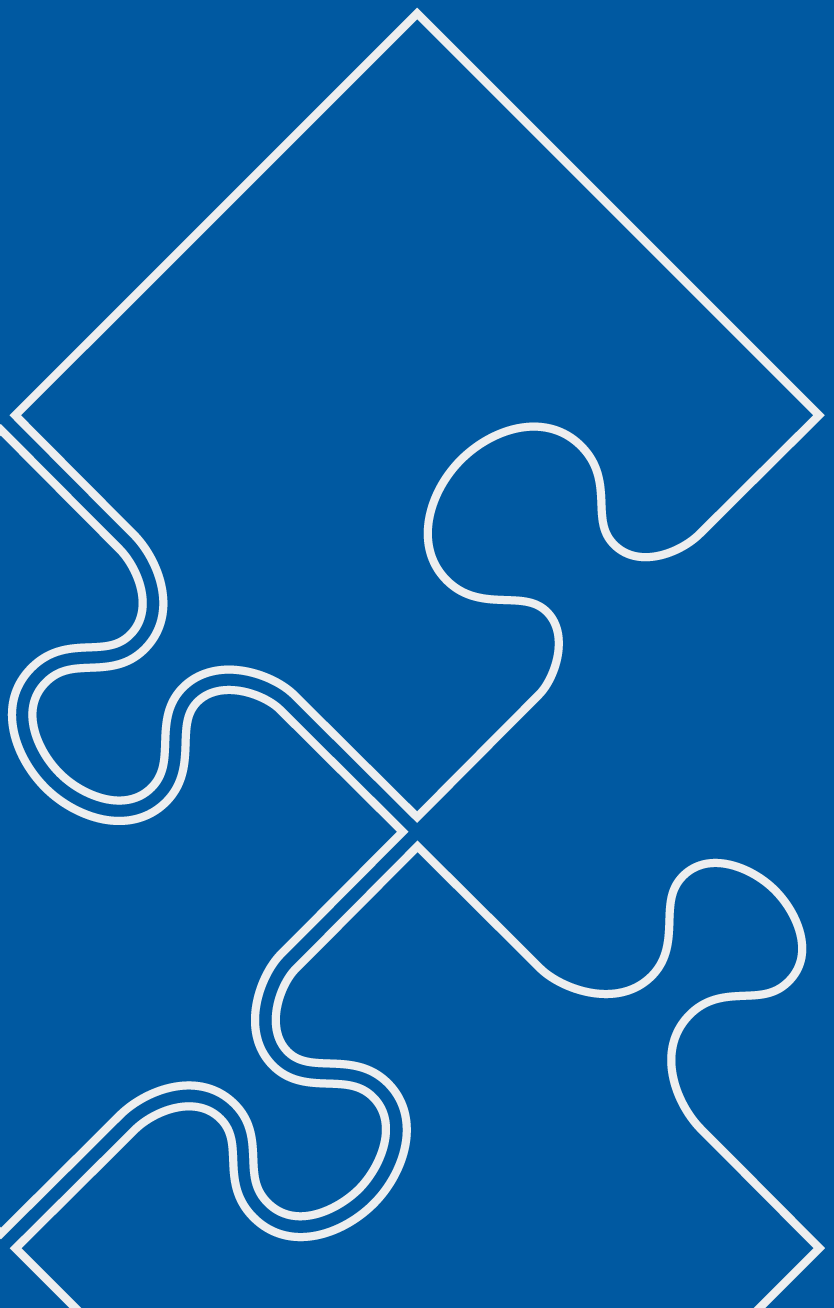


-12Bi USD



Fonte: Agência Petrobras (2025)

SLB-Private



2

Objetivos

SOLUÇÕES JÁ EXISTENTES

Fonte: Ampelmann (2025)



Fonte: Ulstein (2026)

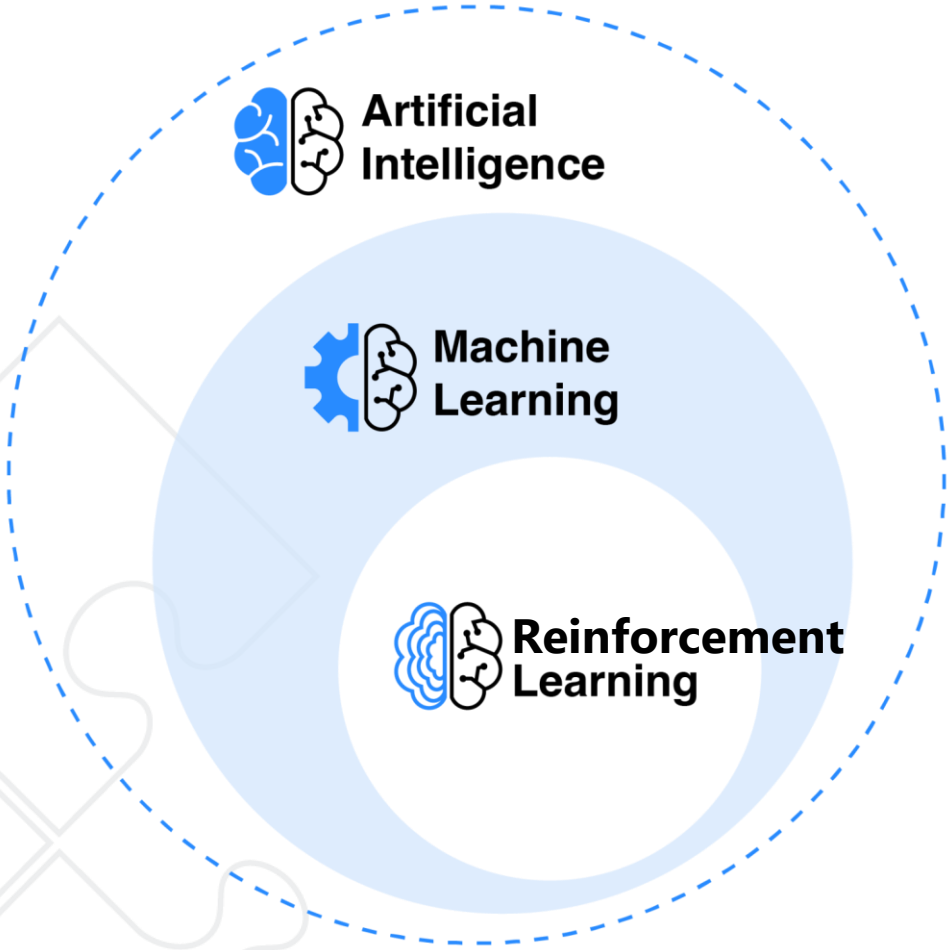




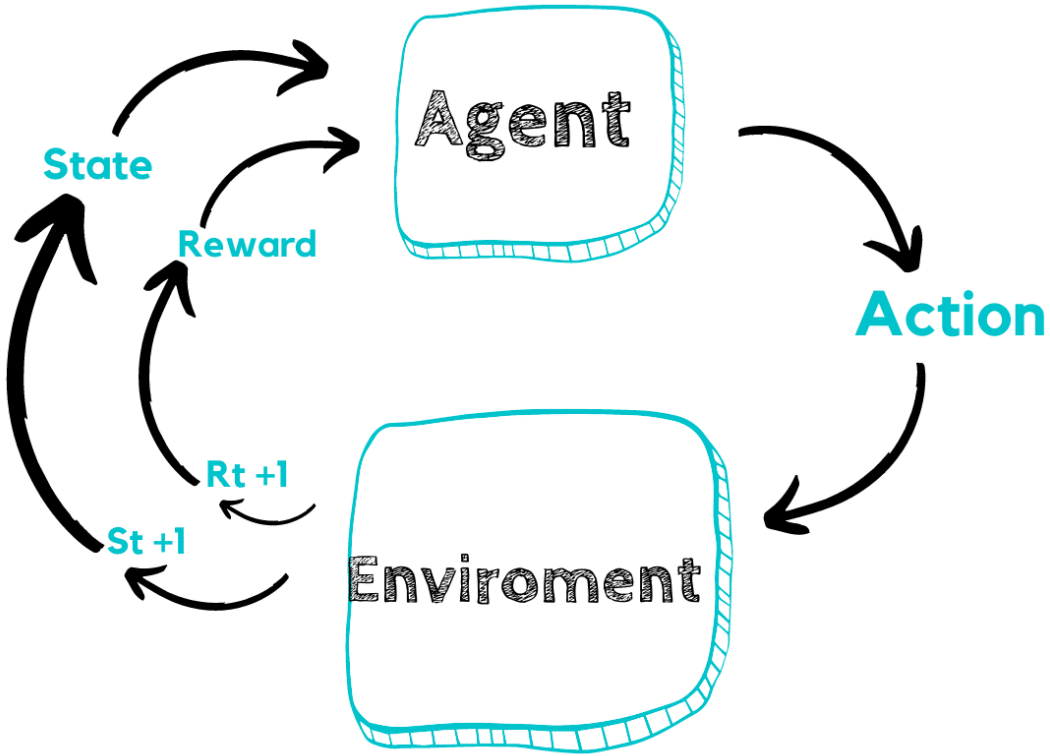
Fonte: Safeway (2026)

SLB-Private

REINFORCEMENT LEARNING



Fonte: adaptado de May (2024)



Fonte: Kuzmenko (2023)

SLB-Private

TRABALHOS UTILIZANDO RL



5456 IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS, VOL. 32, NO. 12, DECEMBER 2021

Data-Driven Performance-Prescribed Reinforcement Learning Control of an Unmanned Surface Vehicle

Ning Wang, *Senior Member, IEEE*, Ying Gao, and Xuefeng Zhang

***Abstract*— An unmanned surface vehicle (USV) under complicated marine environments can hardly be modeled well such that model-based optimal control approaches become infeasible. In this article, a self-learning-based model-free solution only using input–output signals of the USV is innovatively provided. To this end, a data-driven performance-prescribed reinforcement learning co**
pursue control optimalit
simultaneously. By devisin
performance, constrained
verted into constraint-free
unknown dynamics. Rei
neural network-based act
deployed to directly optin
the Bellman error formu
ing errors evolve a data-
analysis eventually ensure
guarantee prescribed trac
Both simulations and virtu
remarkable effectiveness a
scheme.

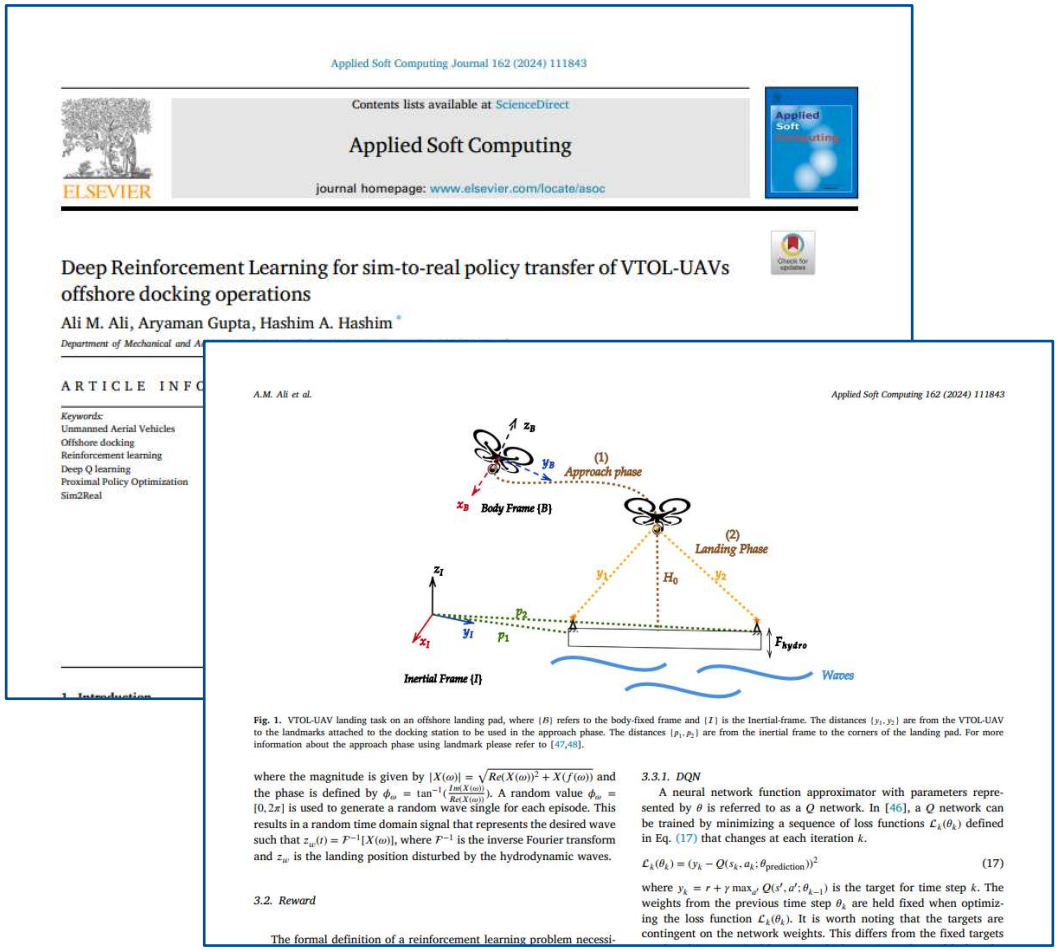
***Index Terms*— Data-**
performance-prescribed
control, unmanned surfac

I. I

nonlinearities due to practical uncertainty and unpredictable marine environments. In this context, the control precision of USV is hardly promoted in practical navigation operations. Accordingly, high-performance control of a complex USV with prescribed performance suffering from compli-

Fig. 11. USV "Intelli-Marine I" and virtual-reality model.

Fonte: Wang et al. (2021)



Applied Soft Computing Journal 162 (2024) 111843

Contents lists available at ScienceDirect

Applied Soft Computing

journal homepage: www.elsevier.com/locate/asoc

Deep Reinforcement Learning for sim-to-real policy transfer of VTOL-UAVs offshore docking operations

Ali M. Ali, Aryaman Gupta, Hashim A. Hashim *

Department of Mechanical and A

ARTICLE INFO

Keywords:
Unmanned Aerial Vehicles
Offshore docking
Reinforcement learning
Deep Q learning
Proximal Policy Optimization
Sim2Real

A.M. Ali et al. Applied Soft Computing 162 (2024) 111843

Fig. 1. VTOL-UAV landing task on an offshore landing pad, where $\{B\}$ refers to the body-fixed frame and $\{I\}$ is the Inertial-frame. The distances $\{y_1, y_2\}$ are from the VTOL-UAV to the landmarks attached to the docking station to be used in the approach phase. The distances $\{p_1, p_2\}$ are from the inertial frame to the corners of the landing pad. For more information about the approach phase using landmark please refer to [47,48].

where the magnitude is given by $|X(\omega)| = \sqrt{Re(X(\omega))^2 + X(f(\omega))}$ and the phase is defined by $\phi_\omega = \tan^{-1}(\frac{Im(X(\omega))}{Re(X(\omega))})$. A random value $\phi_\omega = [0, 2\pi]$ is used to generate a random wave single for each episode. This results in a random time domain signal that represents the desired wave such that $z_w(t) = F^{-1}[X(\omega)]$, where F^{-1} is the inverse Fourier transform and z_w is the landing position disturbed by the hydrodynamic waves.

3.2. Reward

The formal definition of a reinforcement learning problem necessi-

3.3.1. DQN

A neural network function approximator with parameters represented by θ is referred to as a Q network. In [46], a Q network can be trained by minimizing a sequence of loss functions $\mathcal{L}_k(\theta_k)$ defined in Eq. (17) that changes at each iteration k.

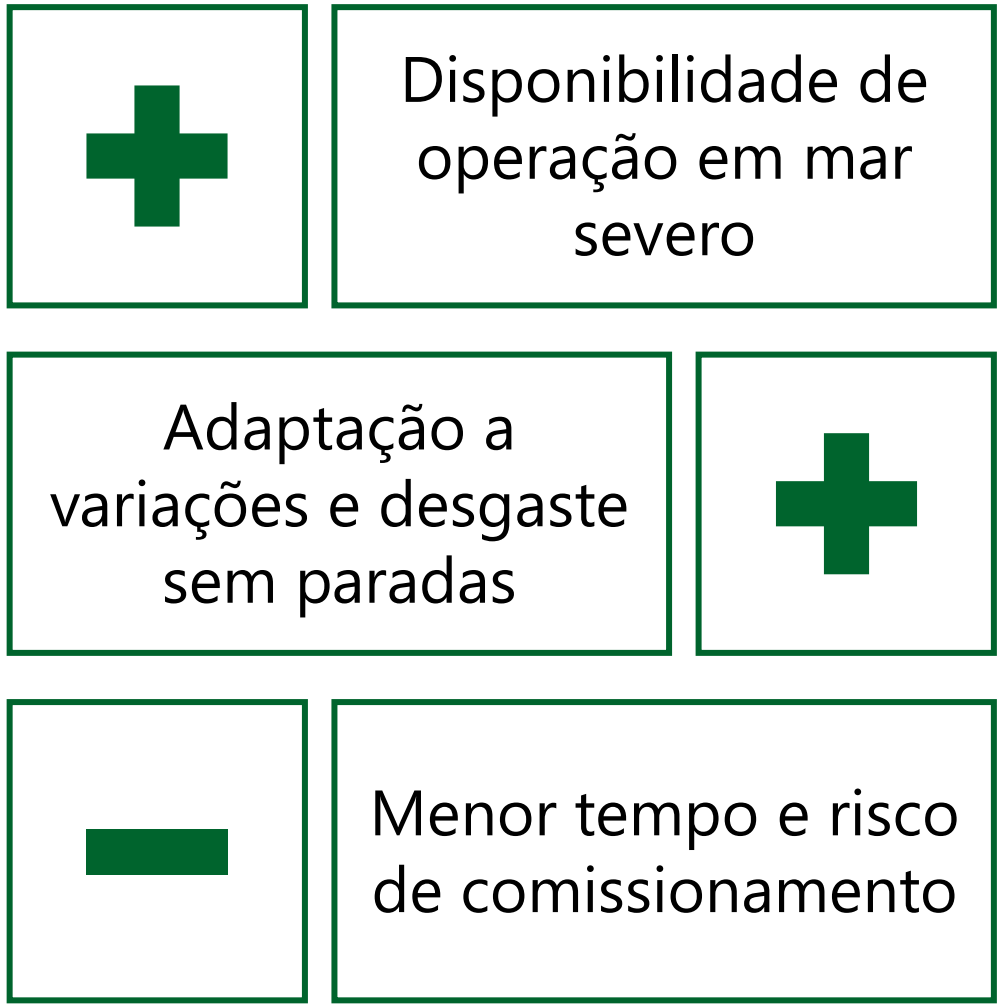
$$\mathcal{L}_k(\theta_k) = (y_k - Q(s_k, a_k; \theta_{\text{prediction}}))^2 \quad (17)$$

where $y_k = r + \gamma \max_{a'} Q(s', a'; \theta_{k-1})$ is the target for time step k. The weights from the previous time step θ_k are held fixed when optimizing the loss function $\mathcal{L}_k(\theta_k)$. It is worth noting that the targets are contingent on the network weights. This differs from the fixed targets

Fonte: Ali et al. (2024)

SLB-Private

GANHOS POTENCIAIS

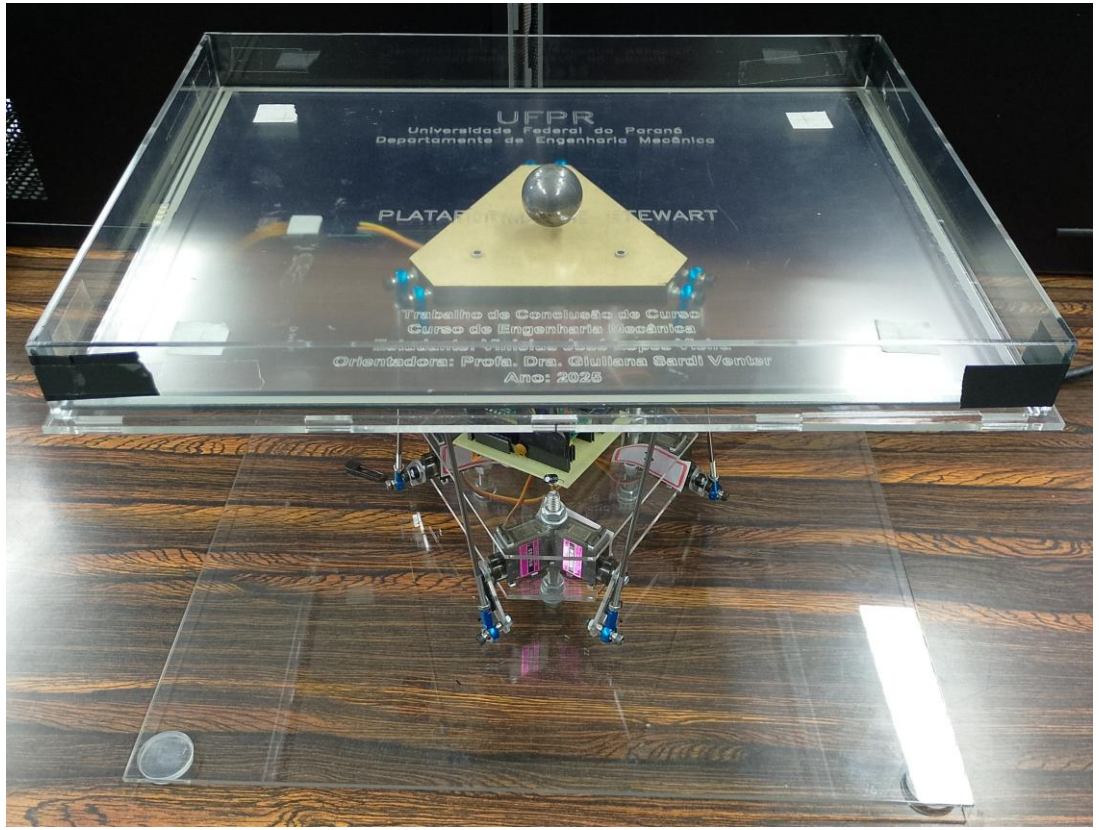


SLB-Private

OBJETIVOS

Objetivo geral

Desenvolver e implementar um controlador baseado em Reinforcement Learning para uma plataforma de Stewart de seis graus de liberdade, acoplada a um sistema de bola e placa usado como prova de conceito de controle não linear sob perturbações.

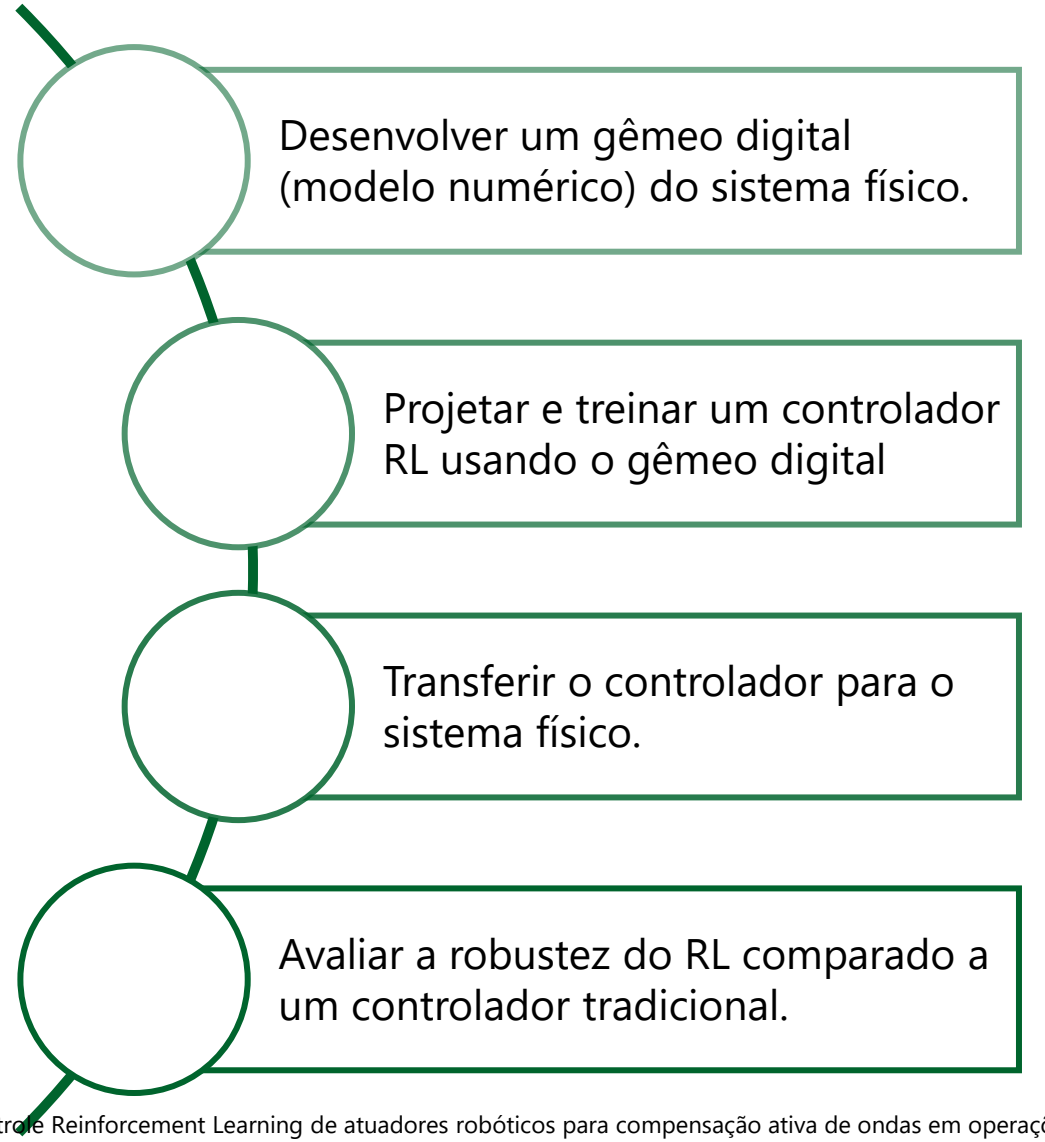


SLB-Private

OBJETIVOS

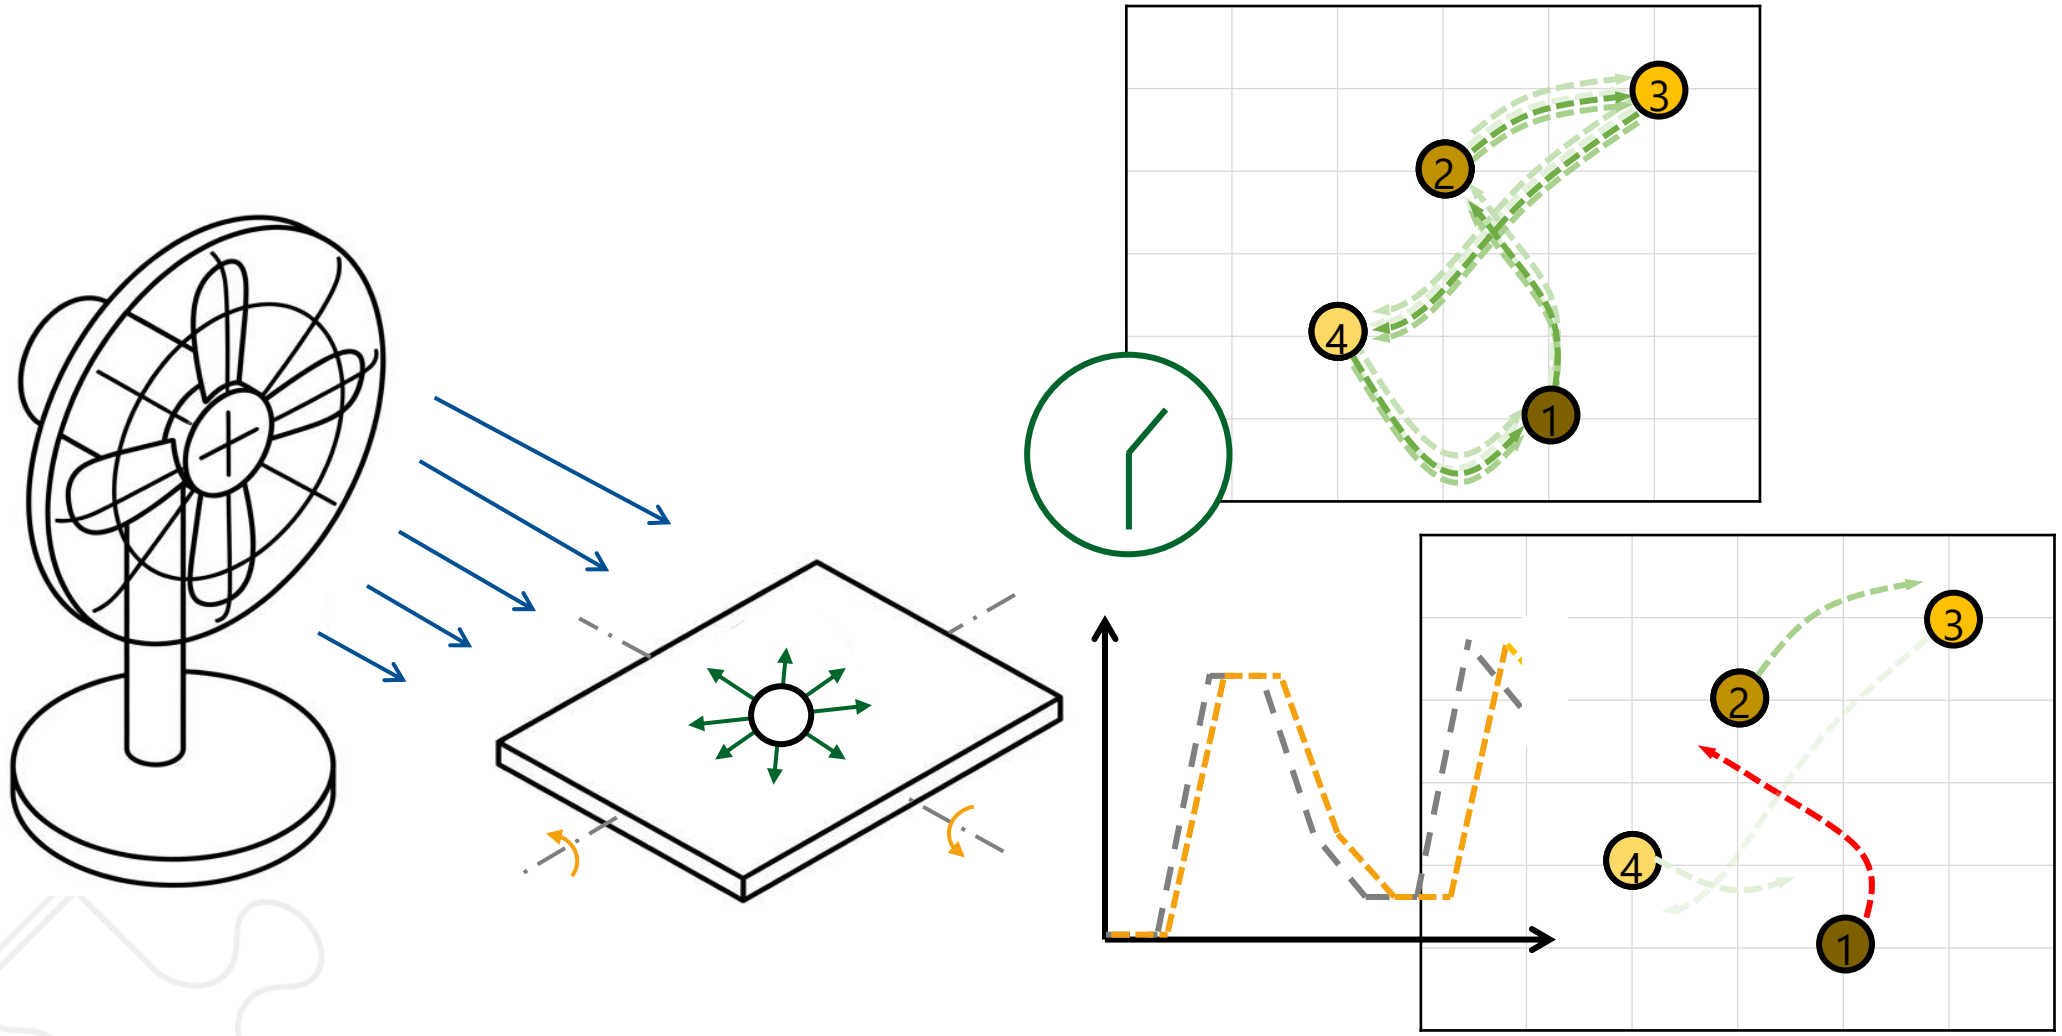
Objetivo geral

Desenvolver e implementar um controlador baseado em Reinforcement Learning para uma plataforma de Stewart de seis graus de liberdade, acoplada a um sistema de bola e placa usado como prova de conceito de controle não linear sob perturbações.

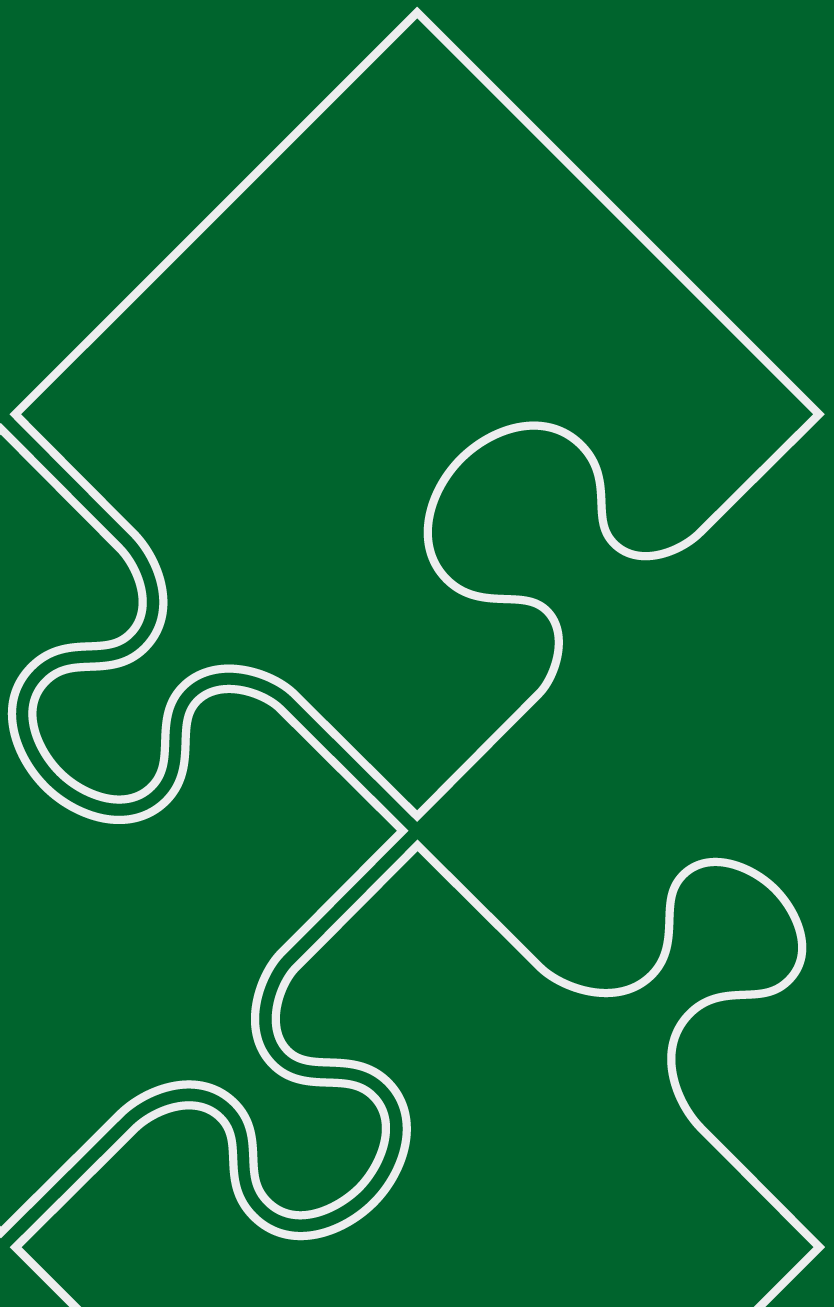


SLB-Private

PERTURBAÇÕES E DETERIORAÇÃO



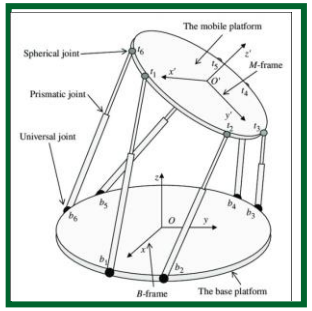
SLB-Private



3

Metodologia e resultados parciais

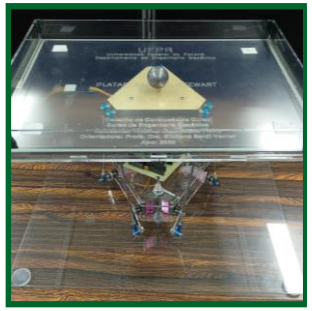
METODOLOGIA



Modelagem numérica do gêmeo digital

Projeto e treinamento do agente RL

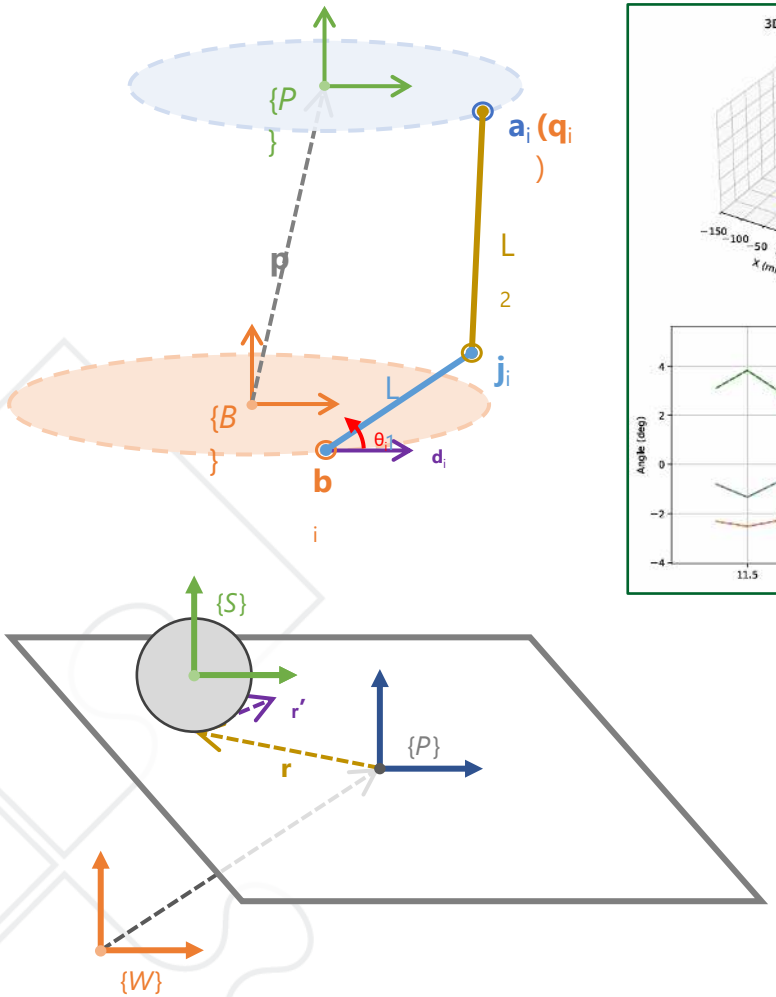


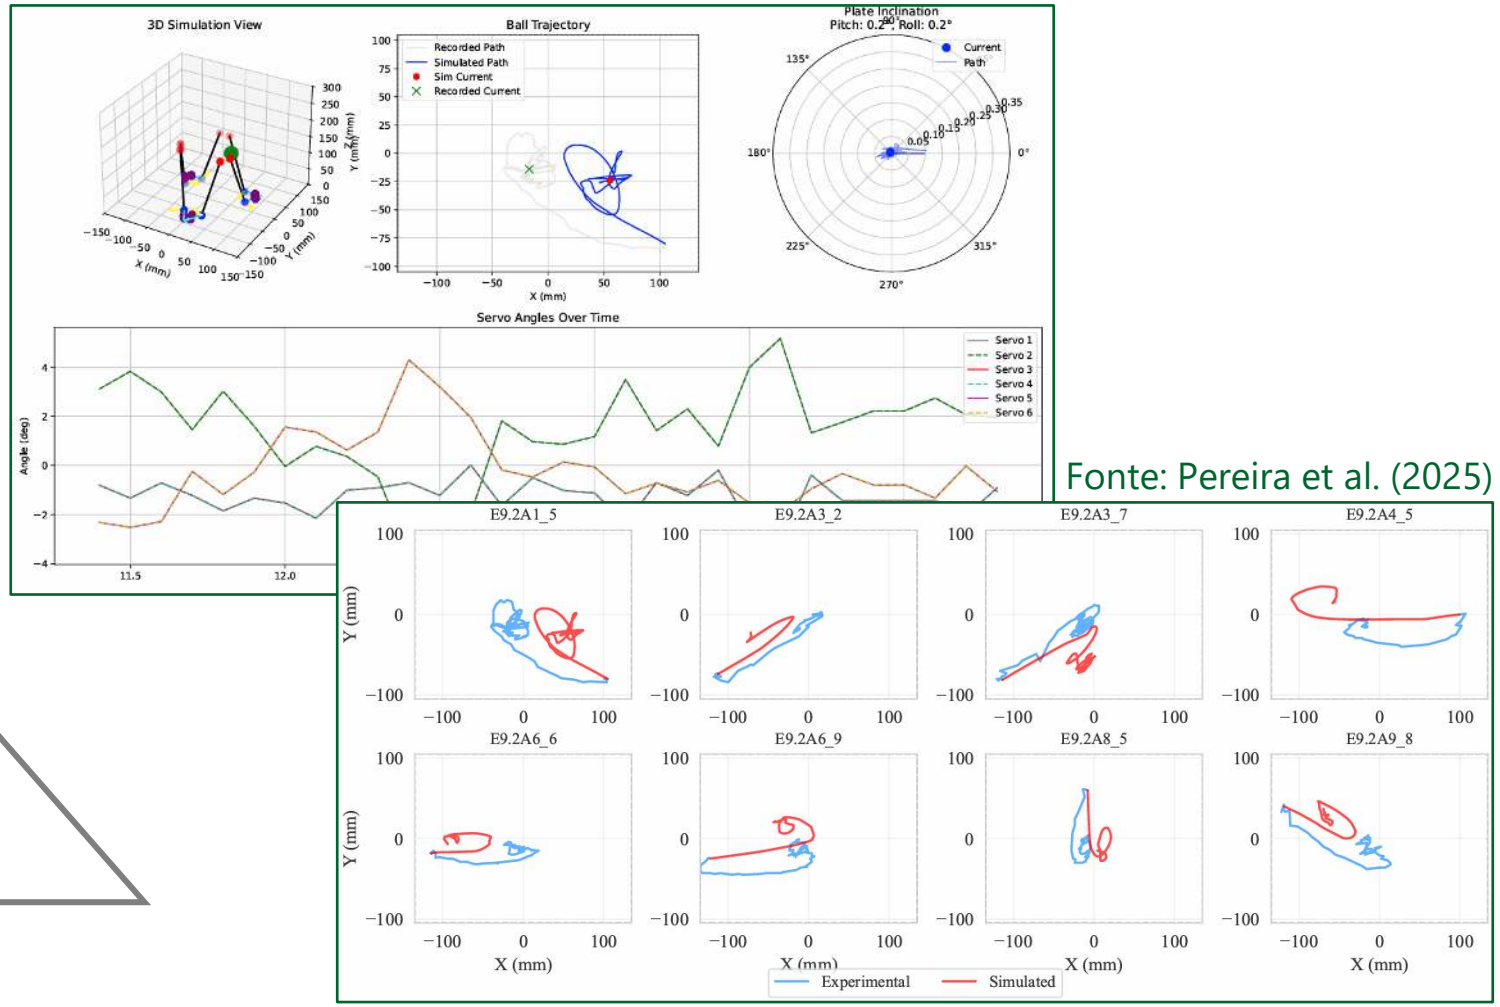


Implementação física e avaliação

SLB-Private

MODELAGEM NUMÉRICA

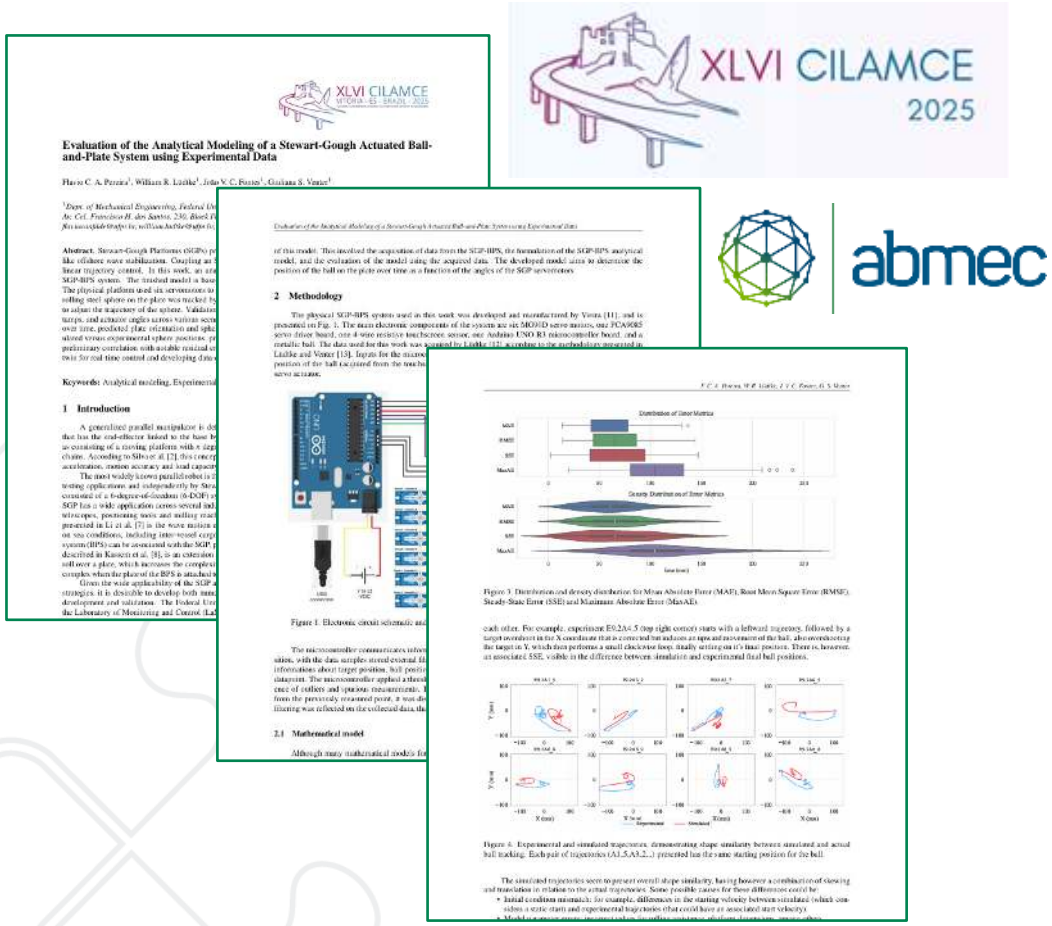




Fonte: Pereira et al. (2025)

SLB-Private

CILAMCE 2025

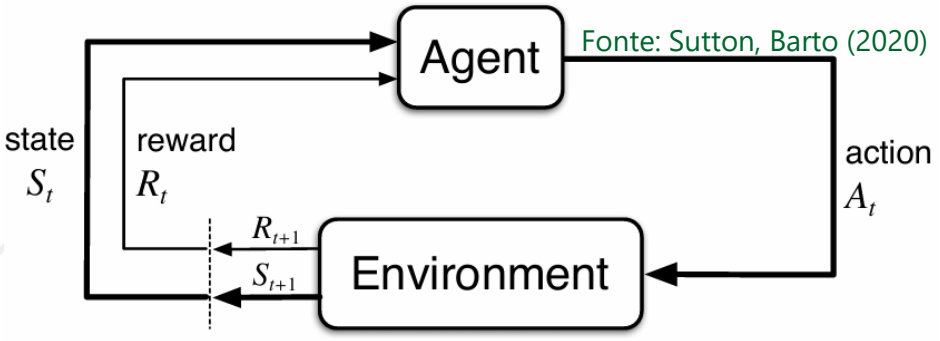


Fonte: Pereira et al. (2025)



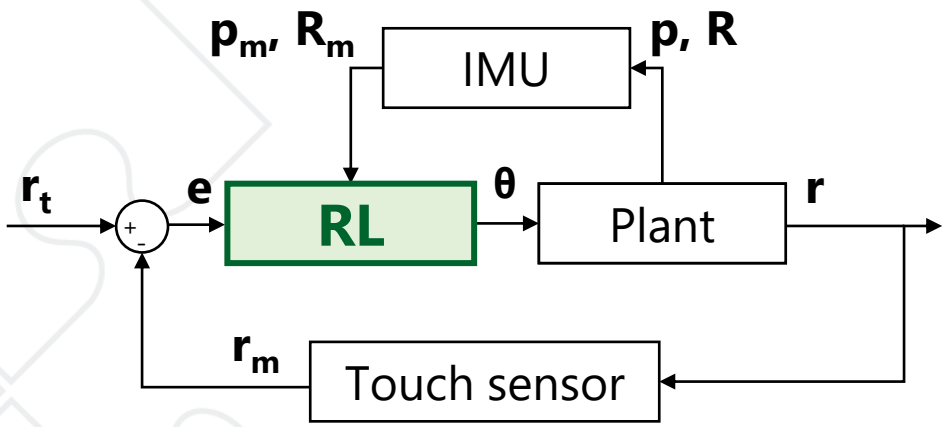
SLB-Private

PROJETO E TREINAMENTO



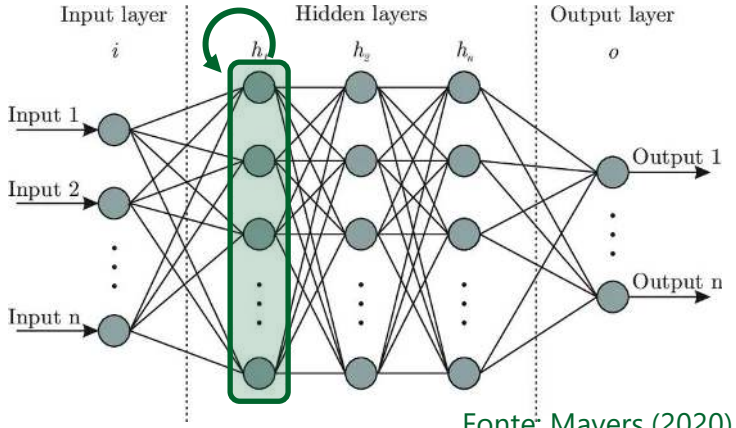
Fonte: Sutton, Barto (2020)

$$r_n^{(B)} = \underbrace{-\lambda_r \left\|\mathbf{e}_{r,n}\right\|^2}_{\text{position error}} \underbrace{-\lambda_{\Delta\theta} \left\|\boldsymbol{\theta}_n - \boldsymbol{\theta}_{n-1}\right\|^2}_{\text{smoothness}} \underbrace{-\lambda_{\text{wall}} \mathcal{P}_{\text{wall}}(\mathbf{r}_{m,n})}_{\text{wall proximity}} \underbrace{+\lambda_{\text{goal}} \left[\left\|\mathbf{e}_{r,n}\right\| < \varepsilon_r\right]}_{\text{goal bonus}},$$



PPO

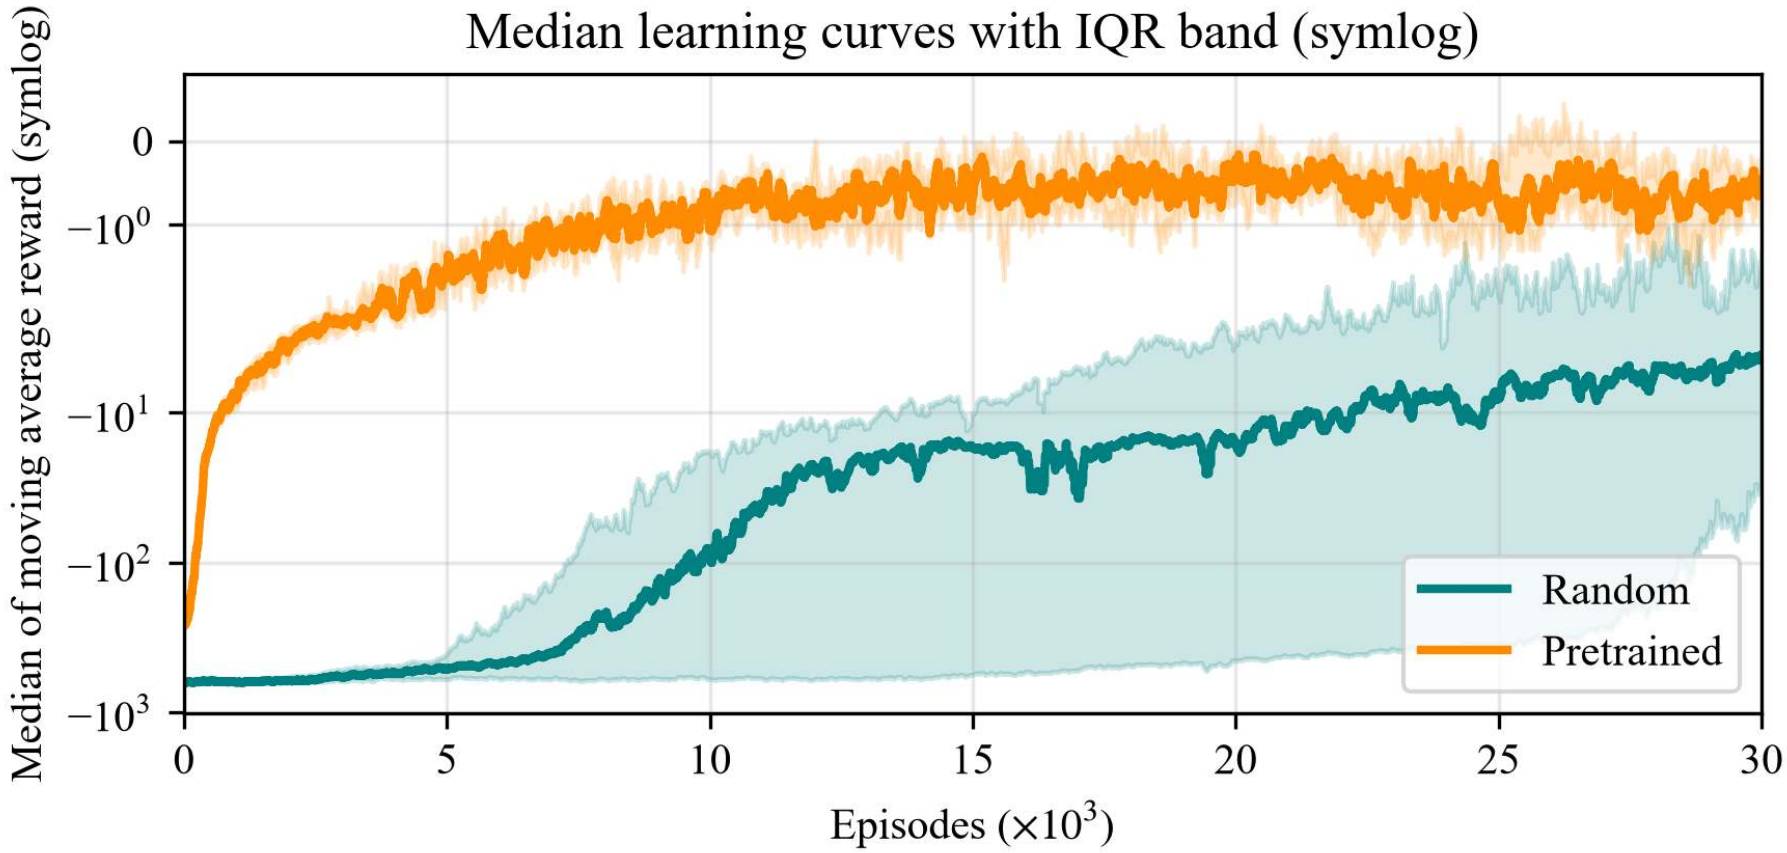
TD3



Fonte: Mayers (2020)

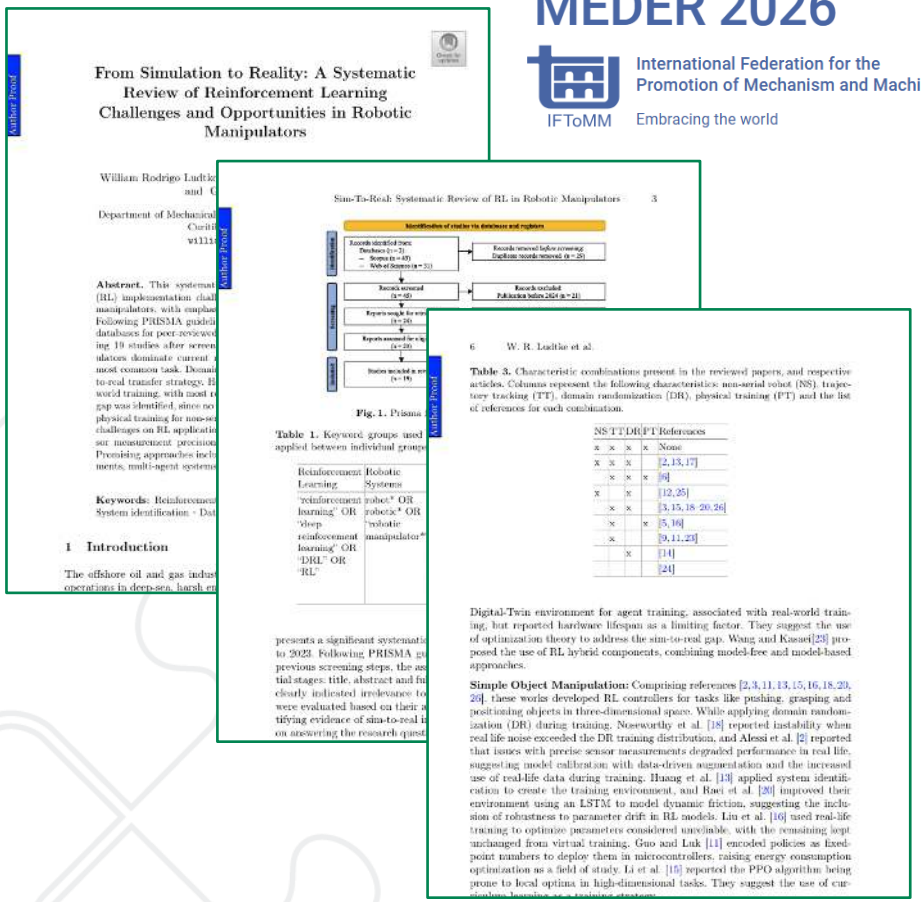
SLB-Private

PROJETO E TREINAMENTO



SLB-Private

MEDER 2026

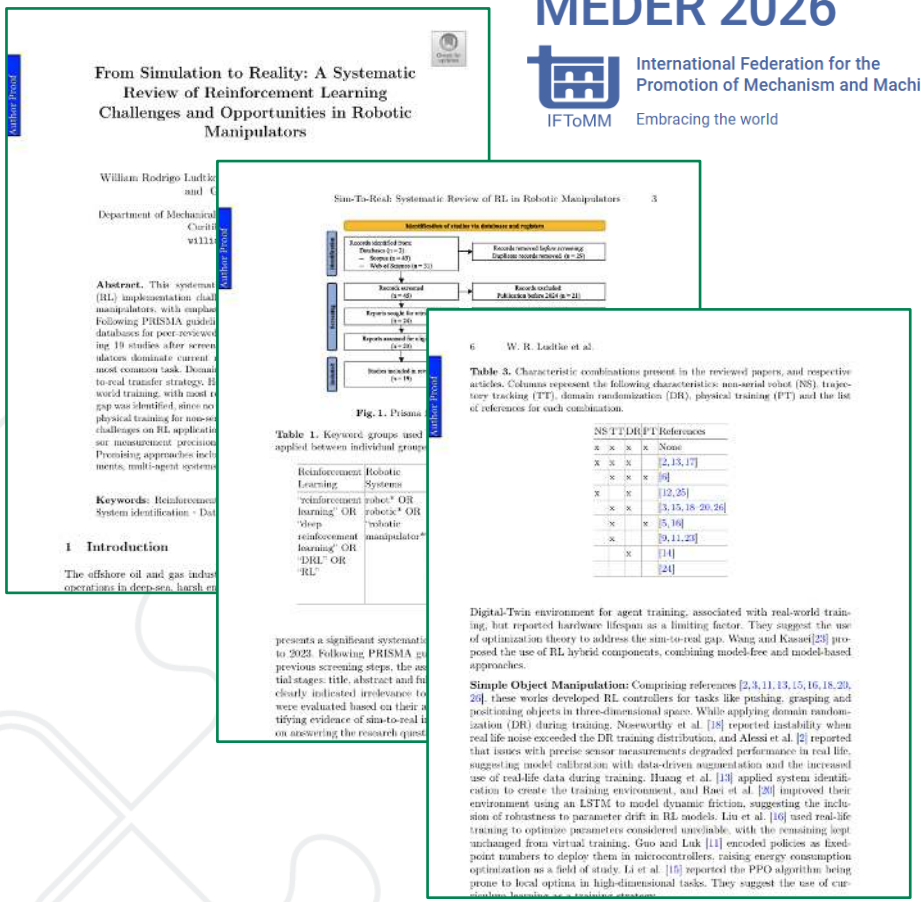


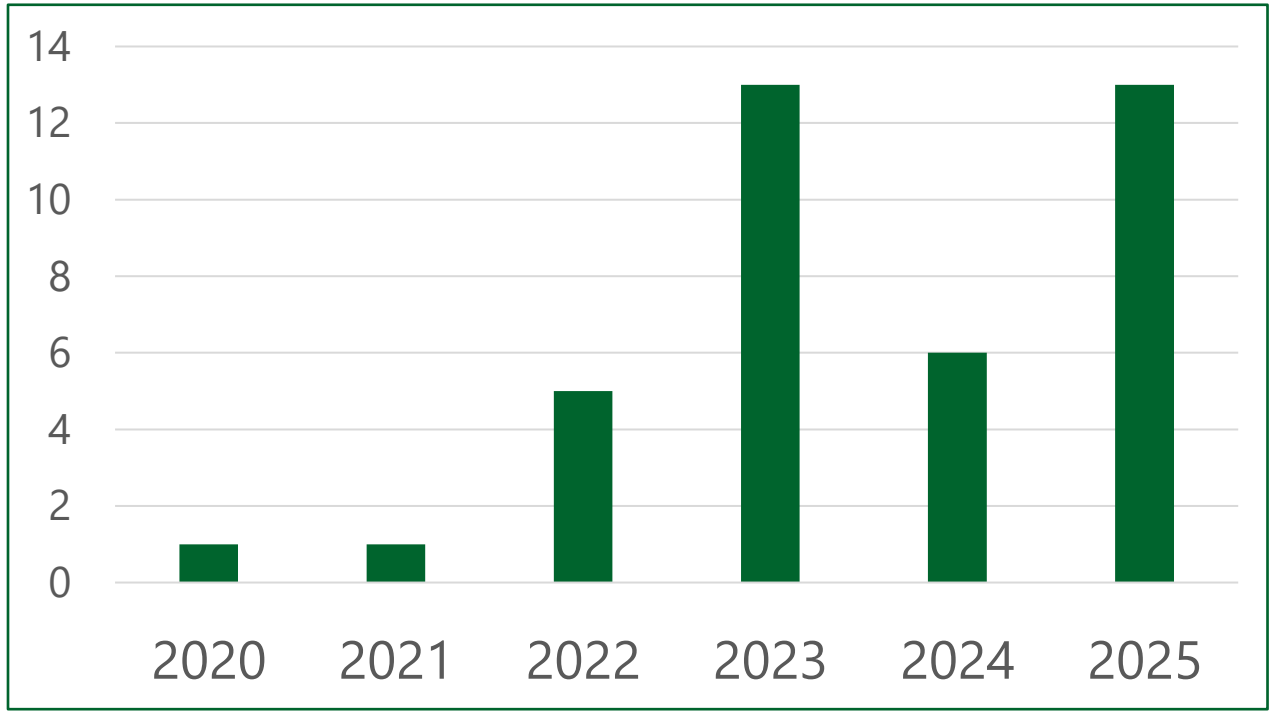
Fonte: Ludtke et al. (2026b)



SLB-Private

MEDER 2026

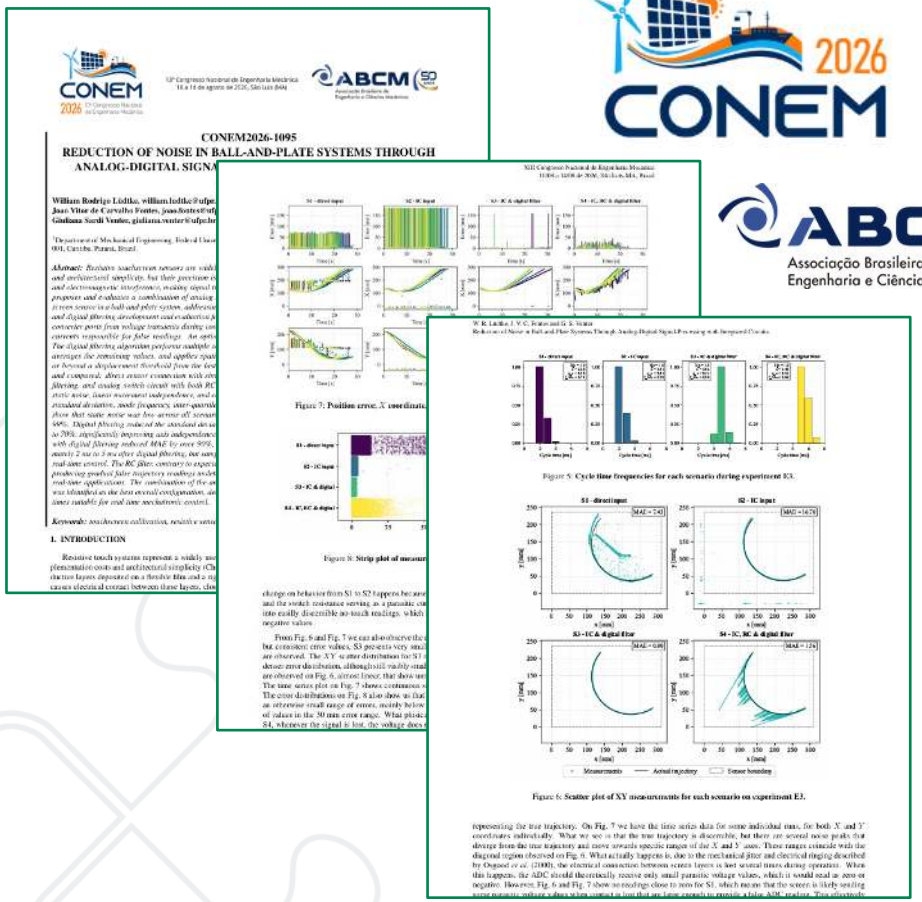




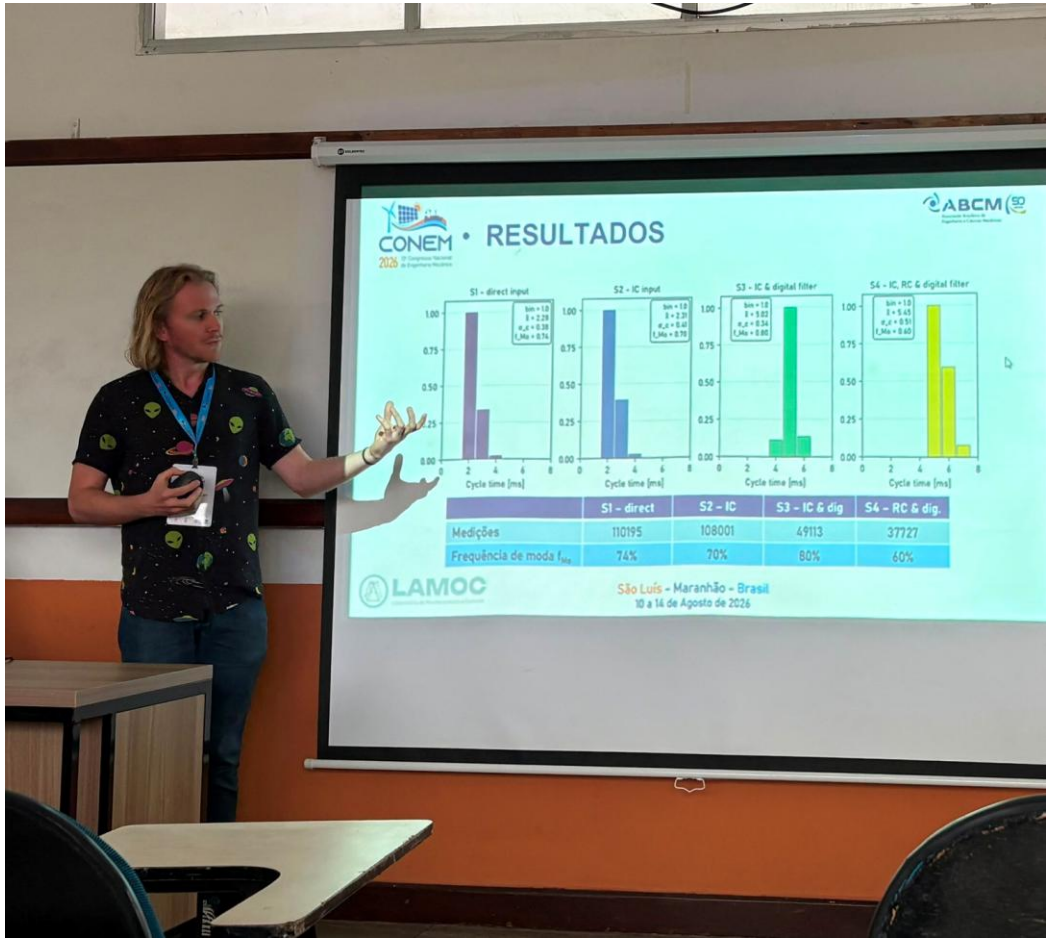
Fonte: Ludtke et al. (2026b)

SLB-Private

CONEM 2026

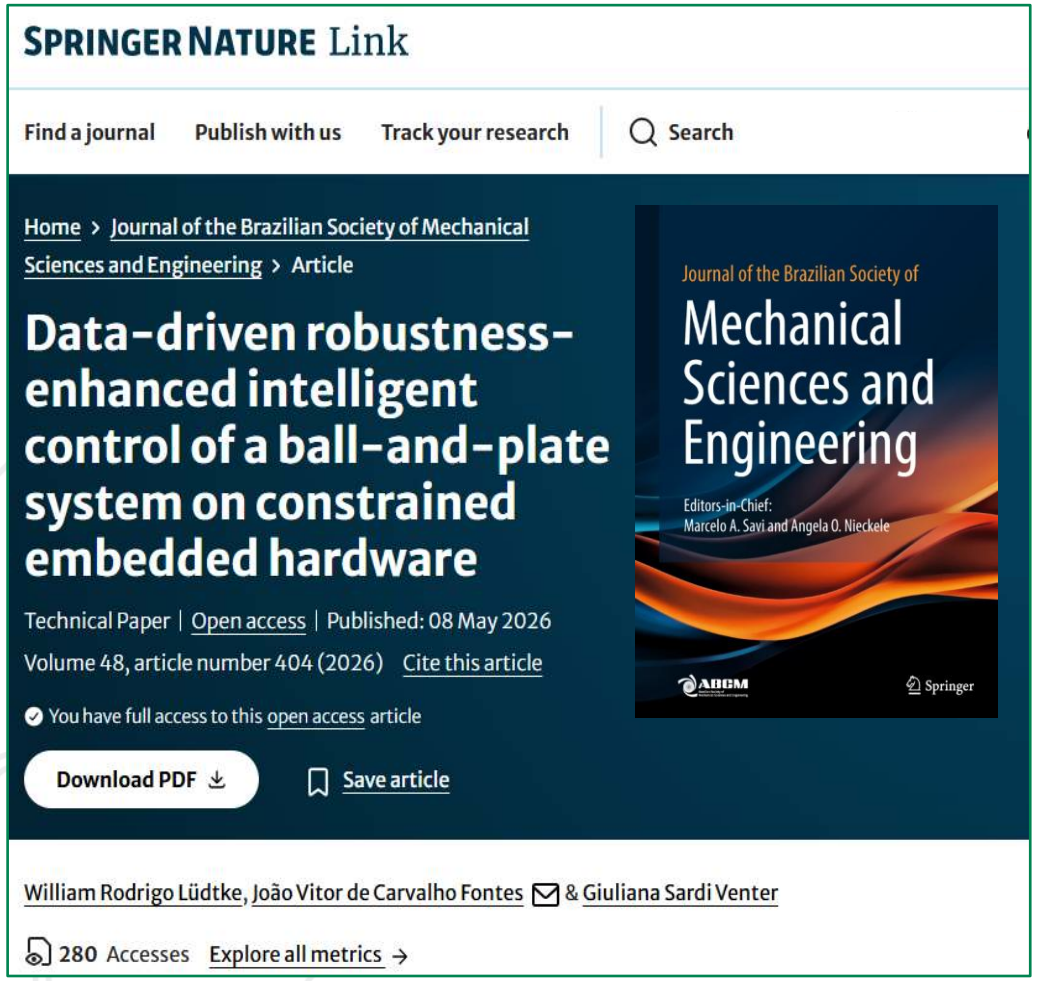


Fonte: Ludtke et al. (2026c)

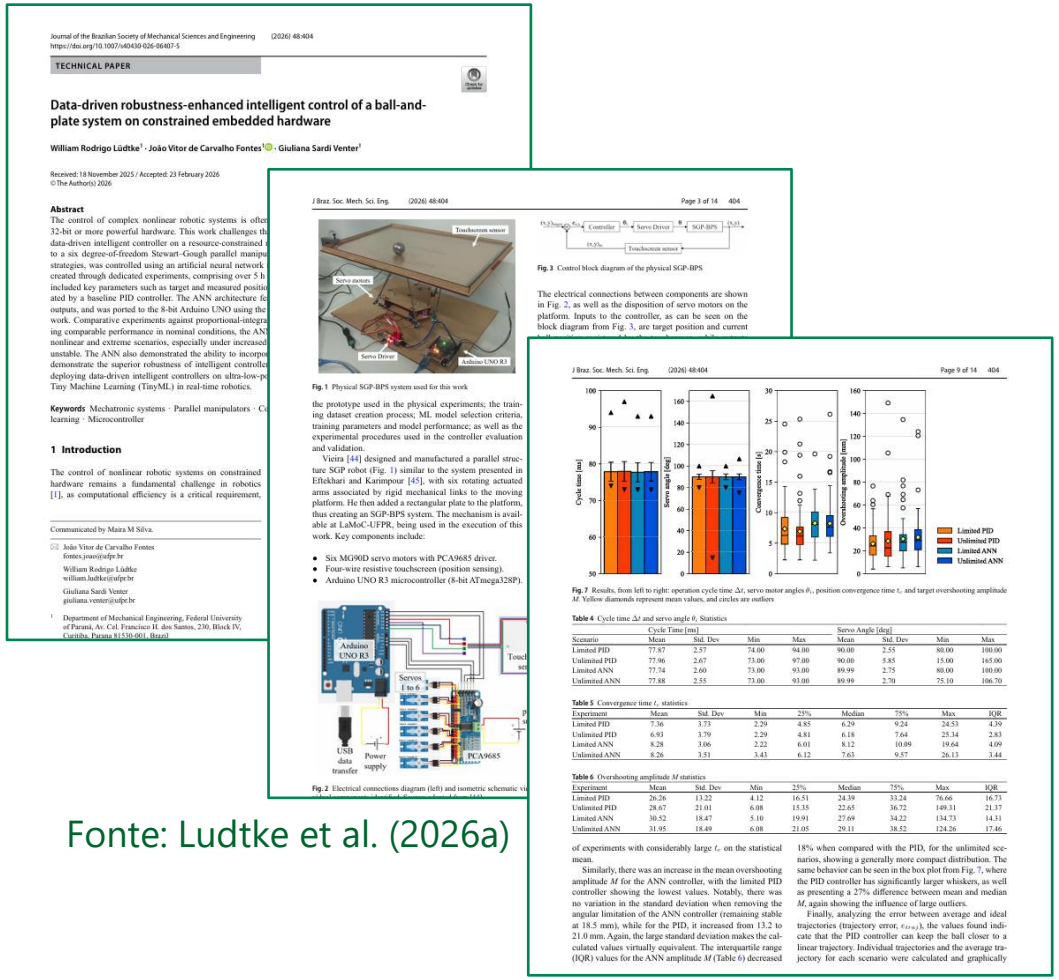


SLB-Private

JOURNAL OF THE BMSE



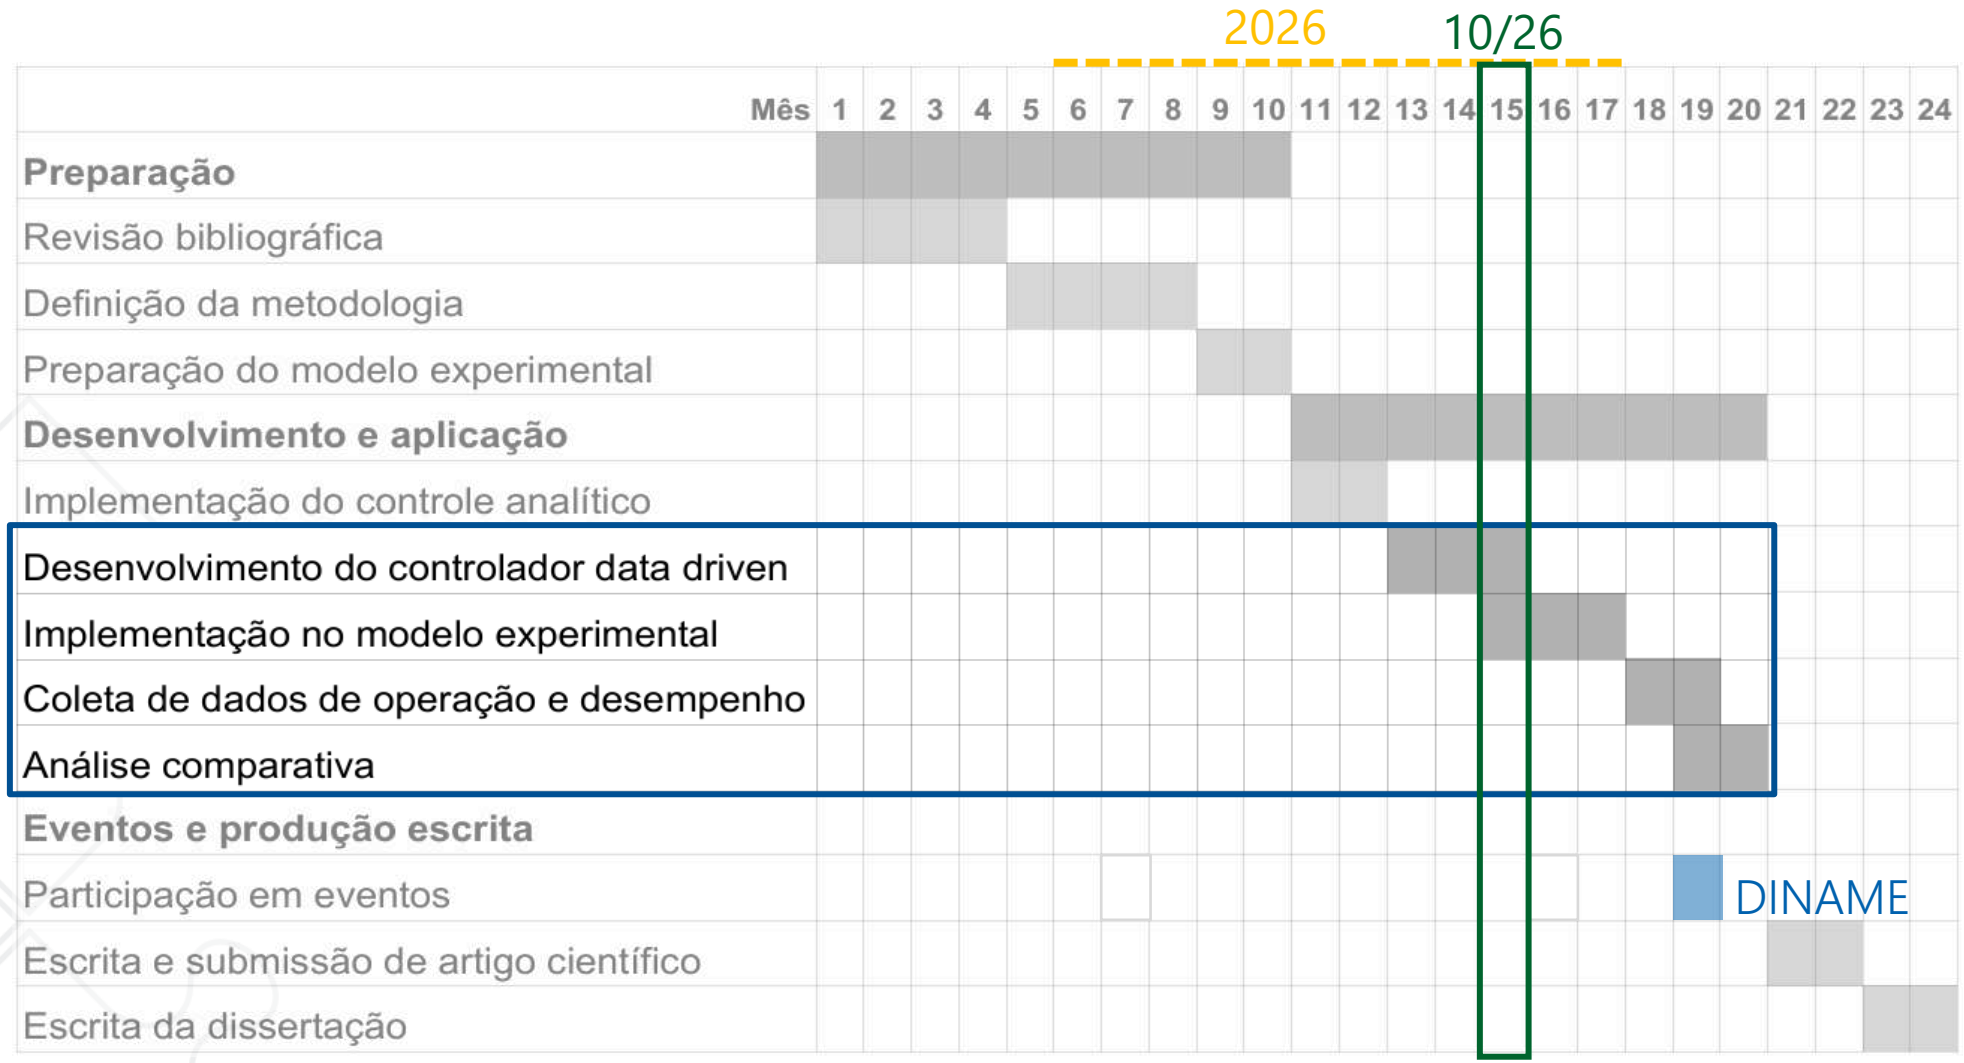
Fonte: Ludtke et al. (2026a)



Fonte: Ludtke et al. (2026a)

SLB-Private

CRONOGRAMA


2026
10/26
Mês 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24
Preparação
Revisão bibliográfica
Definição da metodologia
Preparação do modelo experimental
Desenvolvimento e aplicação
Implementação do controle analítico
Desenvolvimento do controlador data driven
Implementação no modelo experimental
Coleta de dados de operação e desempenho
Análise comparativa
Eventos e produção escrita
Participação em eventos
DINAME
Escrita e submissão de artigo científico
Escrita da dissertação

REFERÊNCIAS

Agencia Brasil, 2009. "2 de Janeiro de 2009". URL https://memoria.ebc.com.br/agenciabrasil/galeria/2009-01-02/2-de-janeiro-de-2009#.

Agencia Petrobras, 2025. "Petrobras aprova Plano de Negocios 2026-2030". URL https://agencia.petrobras.com.br/w/negocio/petrobras-aprova-plano-de-negcios-2026-2030.

Ali, A.M., Gupta, A. and Hashim, H.A., 2024. "Deep Reinforcement Learning for sim-to-real policy transfer of VTOL-UAVs offshore docking operations". Applied Soft Computing, Vol. 162, p. 111843. ISSN 15684946. doi:10.1016/j.asoc.2024.111843. URL https://linkinghub.elsevier.com/retrieve/pii/S1568494624006173.

Ampelmann, 2026. "Ampelmann A-type." URL https://www.ampelmann.nl/systems/a-type.

ANP, 2026. "Boletim da Producao de Petroleo e Gas Natural - Julho 2026". Technical Report 191, Agencia Nacional do Petroleo, Gas Natural e Biocombustıveis. URL https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/boletins-anp/arquivos-bmppgn/2026/julho.pdf.

Bermuda, H., 2026. "Seadrill garante extensao de contrato de US$ 480 milhoes com a Petrobras". URL https://br.investing.com/news/company-news/seadrill-garante-extensao-de-contrato-de-us-480-milhoes-com-a-petrobras-93CH-1890079.

Flavio Canfilde Alves Pereira, William Rodrigo Ludtke, Joao Vitor De Carvalho Fontes and Giuliana Sardi Venter, 2025. "Evaluation of the Analytical Modeling of a Stewart-Gough Actuated Ball-and-Plate System using Experimental Data." Ibero-Latin American Congress on Computational Methods in Engineering (CILAMCE), Vol. 5. ISSN 2675-6269, 2675-6269. doi:10.55592/cilamce2025.v5i.14127. URL https://publicacoes.softaliza.com.br/cilamce-2025/article/view/14127.

Kuzmenko, E., 2023. "Reinforcement Learning For Business: Real-Life Examples." URL https://kitrum.com/blog/reinforcement-learning-for-business-real-life-examples/.

Ludtke, W.R., De Carvalho Fontes, J.V. and Venter, G.S., 2026a. "Data-driven robustness-enhanced intelligent control of a ball-and-plate system on constrained embedded hardware". Journal of the Brazilian Society of Mechanical Sciences and Engineering, Vol. 48, No. 6, p. 404. ISSN 1678-5878, 1806-3691. doi:10.1007/s40430-026-06407-5. URL https://link.springer.com/10.1007/s40430-026-06407-5.

Ludtke, W.R., De Carvalho Fontes, J.V. and Venter, G.S., 2026c. "Reduction of Noise in Ball-and-Plate Systems Through Analog-Digital Signal-Processing with Integrated Circuits". In Proceedings of the XIII Congresso Nacional de Engenharia Mecanica - CONEM 2026. ABCM. doi:10.26678/ABCM.CONEM2026.CON26- 1095. URL http://abcm.org.br/anais-de-eventos/CON26/1095.

May, K., 2024. "What is Artificial Intelligence". URL https://www.nasa.gov/what-is-artificial-intelligence/.

Mayers, G., 2020. "Artificial Neural Networks Demystified". URL https://medium.com/@gabriel.mayers/artificial-neural-networks-demystified-d7cbfb6c6916.

Moore, D., Eftekhari, A. and Nash, S., 2024. "Weather window analysis for the deployment, operation, and maintenance of marine renewable energy devices in Irish coastal waters". Journal of Ocean Engineering and Marine Energy, Vol. 10, No. 4, pp. 711–729. ISSN 2198-6444, 2198-6452. doi:10.1007/s40722-024-00340-2. URL https://link.springer.com/10.1007/s40722-024-00340-2.

Safeway, 2026. "Plug & Play solution built for campaigning". URL https://safewaygangway.com/seagull/.

Seadrill, 2025. "Seadrill joined Petrobras and fellow drilling contractors to exchange knowledge on piping integrity management." URL https://www.linkedin.com/posts/settingthestandard-seadrill-oilandgas-ugcPost-7388953088390496256-Om7u/.

Sutton, R.S. and Barto, A., 2020. Reinforcement learning: an introduction. Adaptive computation and machine learning. The MIT Press, Cambridge, Massachusetts London, England, second edition edition. ISBN 978-0-262-03924-6.

Ulstein, 2026. "Seaway Moxie". URL https://ulstein.com/references/seaway-moxie.

Wang, N., Gao, Y. and Zhang, X., 2021. "Data-Driven Performance-Prescribed Reinforcement Learning Control of an Unmanned Surface Vehicle". IEEE Transactions on Neural Networks and Learning Systems, Vol. 32, No. 12, pp. 5456–5467. ISSN 2162-237X, 2162-2388. doi:10.1109/TNNLS.2021.3056444. URL https://ieeexplore.ieee.org/document/9358986/.

SLB-Private

AGRADECIMENTOS ESPECIAIS





Gestão:









SLB-Private

prh anp 12/UFPR

PRH 12 UFPR

William Rodrigo Lüdtke

Dados para contato

william.ludtke@ufpr.br

linkedin.com/in/williamludtke/

William Lüdtke

SLB-Private

Bermuda (2026) – Valor diário de uma sonda



Investing.com

Pesquisar no site...

Mercados | Carteiras | Desafios de investimento | Notícias | Análises | Corretoras | Gráficos | Técnica | Ferramentas | Academy | Caler

Recentes | Mais lidas | Últimas Notícias | Cripto | Ações | Economia | Carteiras | FII e Fundos | Moedas | Política | Commodities | Dados Econômicos | Gerais

Seadrill garante extensão de contrato de US$ 480 milhões com a Petrobras

Investing.com | Notícias de empresas

Publicado 06.04.2026, 07:07

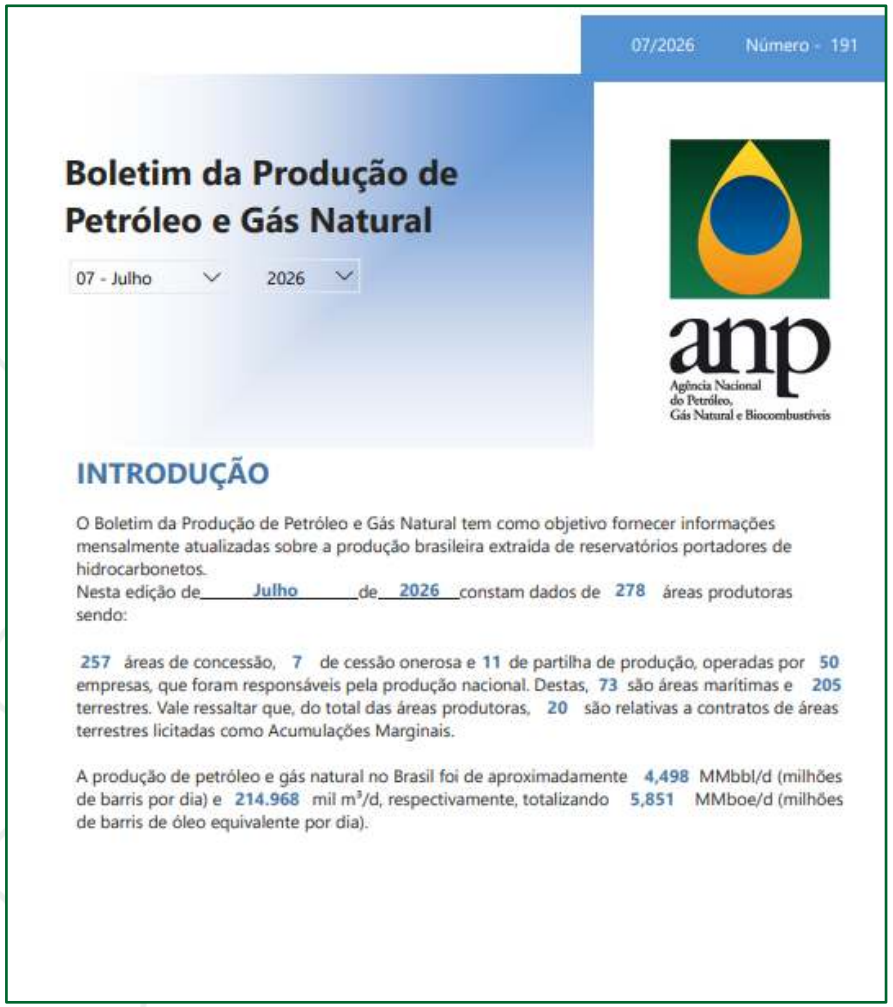
HAMILTON, Bermuda - A Seadrill Limited (NYSE:SDRL) anunciou uma extensão de contrato de 1.095 dias para seu navio de perfuração de águas ultraprofundas West Polaris com a Petrobras para o campo de Búzios na Bacia de Santos, no litoral do Brasil.

A extensão adiciona aproximadamente US$ 480 milhões à carteira de contratos da empresa e está programada para começar em janeiro de 2028, após a conclusão do programa atual, de acordo com um comunicado à imprensa.

A empresa divulgou as taxas diárias contratadas atualizadas para os períodos atual e estendido. De 1º de abril de 2026 até 31 de março de 2027, a taxa diária é de US$ 409.200. De 1º de abril de 2027 até 15 de janeiro de 2028, a taxa aumenta para US$ 454.700.

SLB-Private

ANP (2026) – Distribuição da produção



07/2026 Número - 191

Boletim da Produção de Petróleo e Gás Natural

07 - Julho 2026

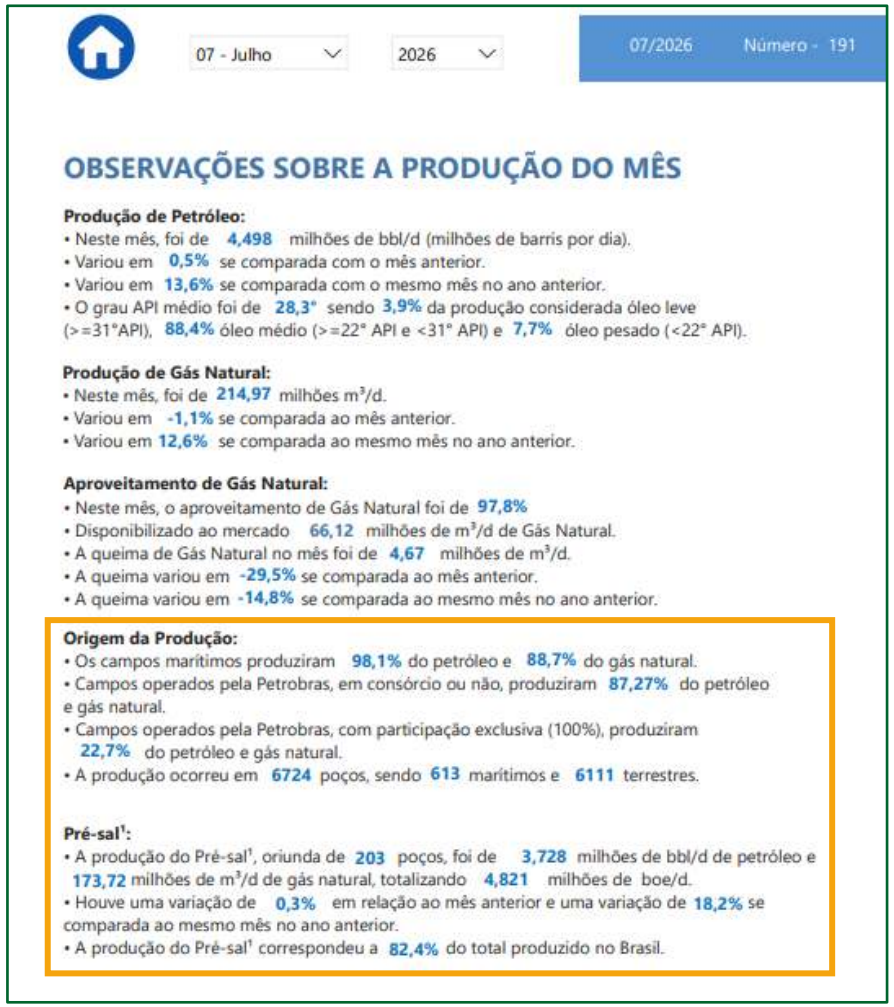
anp
Agência Nacional do Petróleo, Gás Natural e Biocombustíveis

INTRODUÇÃO

O Boletim da Produção de Petróleo e Gás Natural tem como objetivo fornecer informações mensalmente atualizadas sobre a produção brasileira extraída de reservatórios portadores de hidrocarbonetos.
Nesta edição de Julho de 2026 constam dados de 278 áreas produtoras sendo:

257 áreas de concessão, 7 de cessão onerosa e 11 de partilha de produção, operadas por 50 empresas, que foram responsáveis pela produção nacional. Destas, 73 são áreas marítimas e 205 terrestres. Vale ressaltar que, do total das áreas produtoras, 20 são relativas a contratos de áreas terrestres licitadas como Acumulações Marginais.

A produção de petróleo e gás natural no Brasil foi de aproximadamente 4,498 MMbbl/d (milhões de barris por dia) e 214.968 mil m³/d, respectivamente, totalizando 5,851 MMboe/d (milhões de barris de óleo equivalente por dia).



07 - Julho 2026 07/2026 Número - 191

OBSERVAÇÕES SOBRE A PRODUÇÃO DO MÊS

Produção de Petróleo:
- Neste mês, foi de 4,498 milhões de bbl/d (milhões de barris por dia).
- Variou em 0,5% se comparada com o mês anterior.
- Variou em 13,6% se comparada com o mesmo mês no ano anterior.
- O grau API médio foi de 28,3° sendo 3,9% da produção considerada óleo leve (>=31°API), 88,4% óleo médio (>=22° API e <31° API) e 7,7% óleo pesado (<22° API).

Produção de Gás Natural:
- Neste mês, foi de 214,97 milhões m³/d.
- Variou em -1,1% se comparada ao mês anterior.
- Variou em 12,6% se comparada ao mesmo mês no ano anterior.

Aproveitamento de Gás Natural:
- Neste mês, o aproveitamento de Gás Natural foi de 97,8%
- Disponibilizado ao mercado 66,12 milhões de m³/d de Gás Natural.
- A queima de Gás Natural no mês foi de 4,67 milhões de m³/d.
- A queima variou em -29,5% se comparada ao mês anterior.
- A queima variou em -14,8% se comparada ao mesmo mês no ano anterior.

Origem da Produção:
- Os campos marítimos produziram 98,1% do petróleo e 88,7% do gás natural.
- Campos operados pela Petrobras, em consórcio ou não, produziram 87,27% do petróleo e gás natural.
- Campos operados pela Petrobras, com participação exclusiva (100%), produziram 22,7% do petróleo e gás natural.
- A produção ocorreu em 6724 poços, sendo 613 marítimos e 6111 terrestres.

Pré-sal[1]:
- A produção do Pré-sal[1], oriunda de 203 poços, foi de 3,728 milhões de bbl/d de petróleo e 173,72 milhões de m³/d de gás natural, totalizando 4,821 milhões de boe/d.
- Houve uma variação de 0,3% em relação ao mês anterior e uma variação de 18,2% se comparada ao mesmo mês no ano anterior.
- A produção do Pré-sal[1] correspondeu a 82,4% do total produzido no Brasil.

SLB-Private

Agência Petrobras (2025) – Plano de negócios



SLB-Private

Agência Petrobras (2025) – Plano de negócios



SLB-Private

Agência Petrobras (2025) – Plano de negócios



SLB-Private



prh anp

anp | Gestão: FAPESP

SLB-Private