

THE DEVELOPER'S CONFERENCE

Trilha – Machine Learning

Douglas Alves Goulart

Graduando em Engenharia Química; Iniciação científica em Aplicação industrial de IA em controle e automação de processos.

Orientador: Prof. Renato Dutra Pereira Filho



THE
DEVELOPER'S
CONFERENCE

Aplicação de Reinforcement Learning em Controle de Processos Industriais

Indústria 4.0 = M.L. + Engenharia

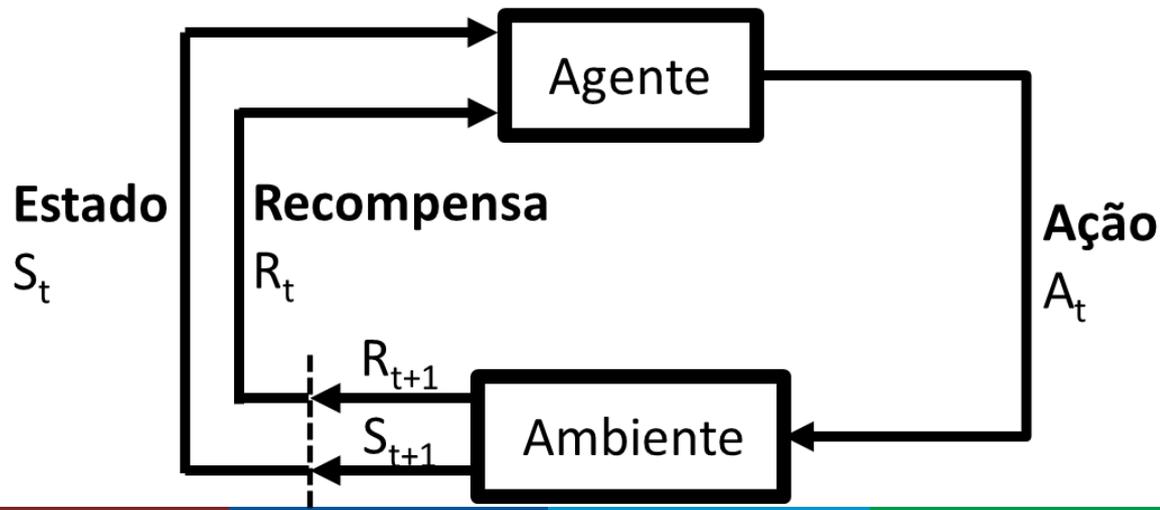
Reinforcement Learning



- Ambiente/dataset dinâmico
- Objetivo: Determinar melhor sequência de ações

↑ Recompensa

- $A_t = \text{policy}(S_t)$



Reinforcement Learning?



THE
DEVELOPER'S
CONFERENCE

➤ Deep Mind



Reinforcement Learning?

➤ E na indústria ...



THE
DEVELOPER'S
CONFERENCE

Objetivo



- Desenvolver e aplicar um agente de Reinforcement Learning para controlar processos industriais
- Avaliar e validar comparando o desempenho do controlador inteligente com um controlador clássico.

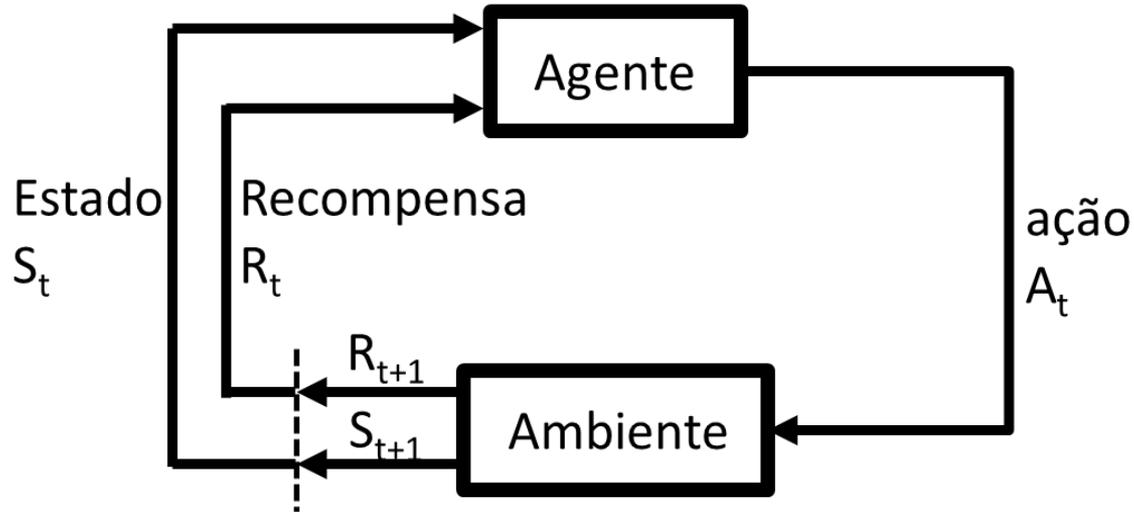
Como?



➤ Correlacionando RL com Controle de processos.

Como?

- Correlacionando RL com Controle de processos.



Como?

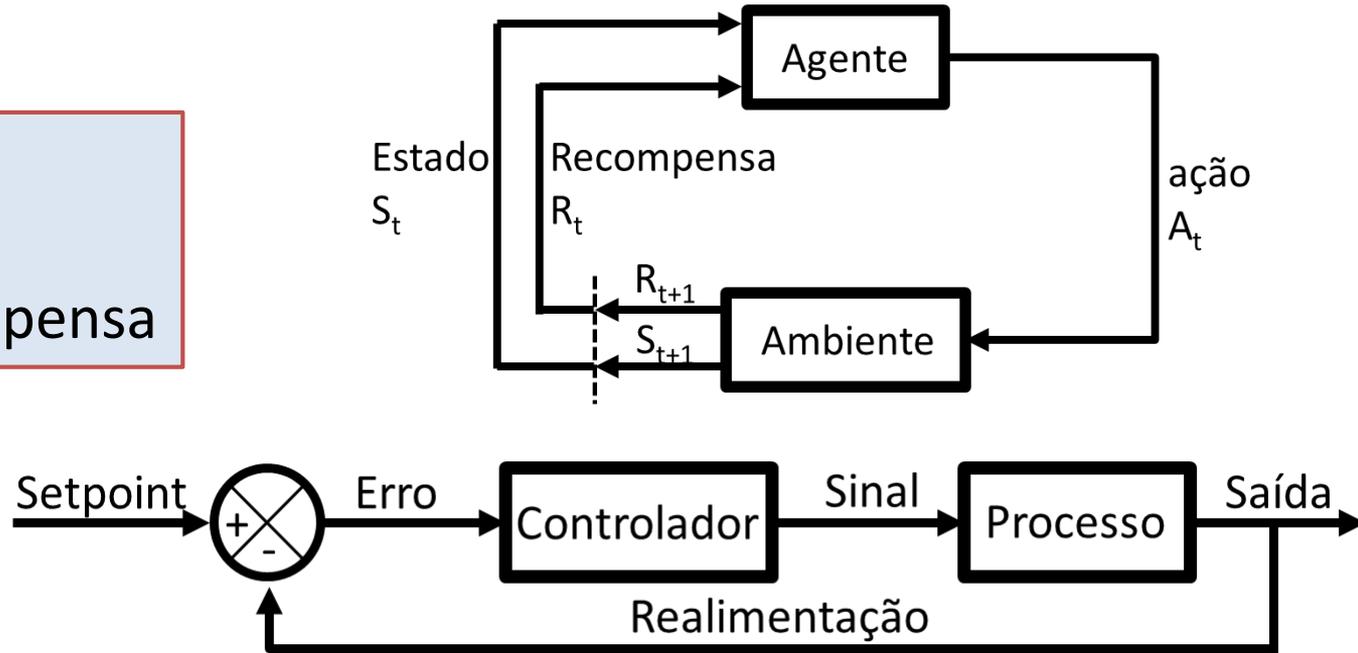
- Correlacionando RL com Controle de processos.



Como?

➤ Correlacionando RL com Controle de processos.

Sinal → Ação
Saída → Estado
Erro → Recompensa



Estudo de caso



THE
DEVELOPER'S
CONFERENCE

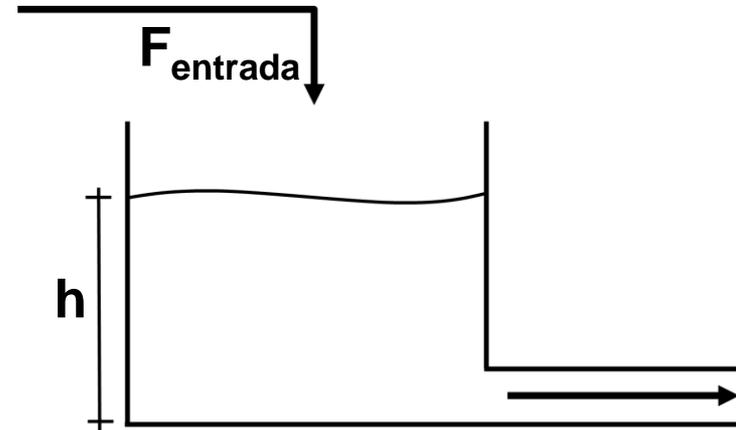
➤ Controle de nível de tanque:

- Tanque aberto de descarga aberta, isotérmico, sem reações químicas e fluido newtoniano
- Considerando a área transversal do tanque constante:

$$\frac{dV}{dt} = F_{entrada} - F_{saída}$$

$$\frac{d(A \cdot h)}{dt} = F_{entrada} - F_{saída}$$

$$\frac{dh}{dt} = \frac{F_{entrada} - F_{saída}}{A}$$





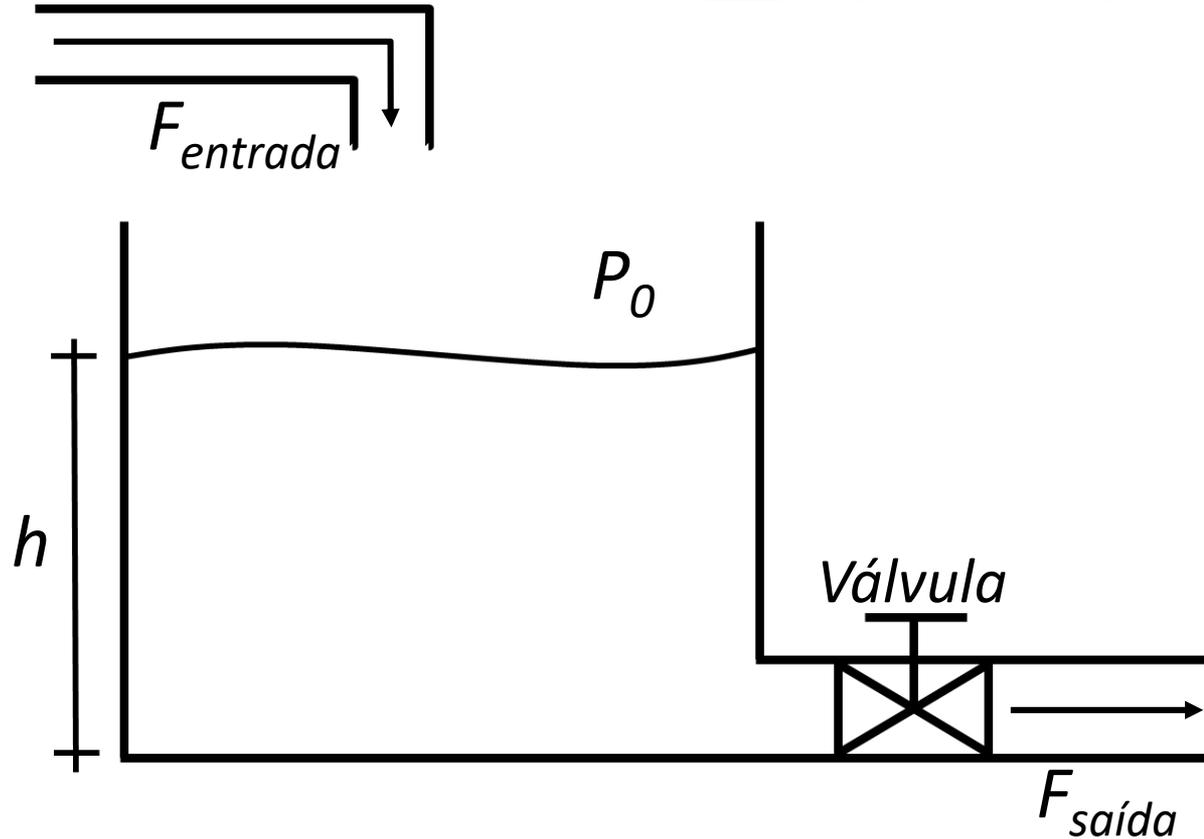
Tanque aberto;
Descarga aberta;
Isotérmico;
Sem reação química;
Fluido newtoniano;

$$\frac{dh}{dt} = \frac{F_{entrada} - F_{saída}}{A}$$

$$F_{saída} = f(x) C_v \sqrt{\Delta P}$$

$$\Delta P = (P_o + \rho gh) - P_o$$

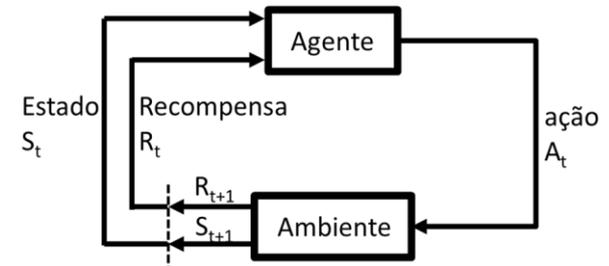
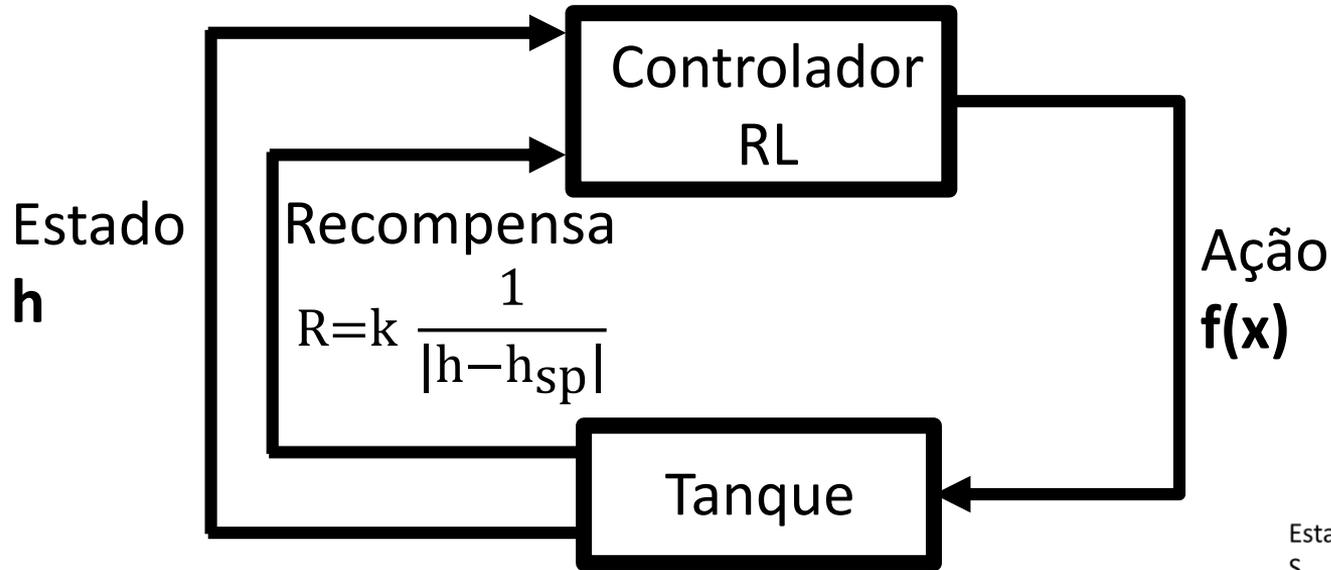
$$\Delta P = \rho gh$$



Estudo de caso



THE
DEVELOPER'S
CONFERENCE



Solução numérica



THE
DEVELOPER'S
CONFERENCE

- E.D.O. solucionada pelo método de RK4;
- Condição inicial: $h_{t=0} = 0,2\text{m}$
- Scilab 6.0.0;

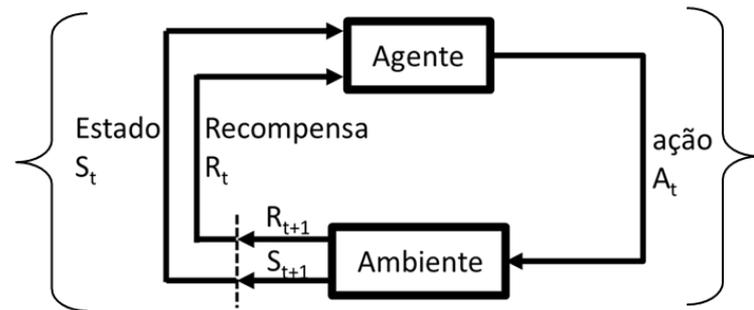
- Dimensões do tanque: $A_b = 3\text{m}^2$
 $h_{\text{max}} = 1\text{m}$
- Parâmetros: $h_{\text{sp}} = 0,5\text{m}$
 $F_{\text{entrada}} = 100\text{m}^3/\text{h}$

- 2 horas de simulação, $dt = 0,01$ horas

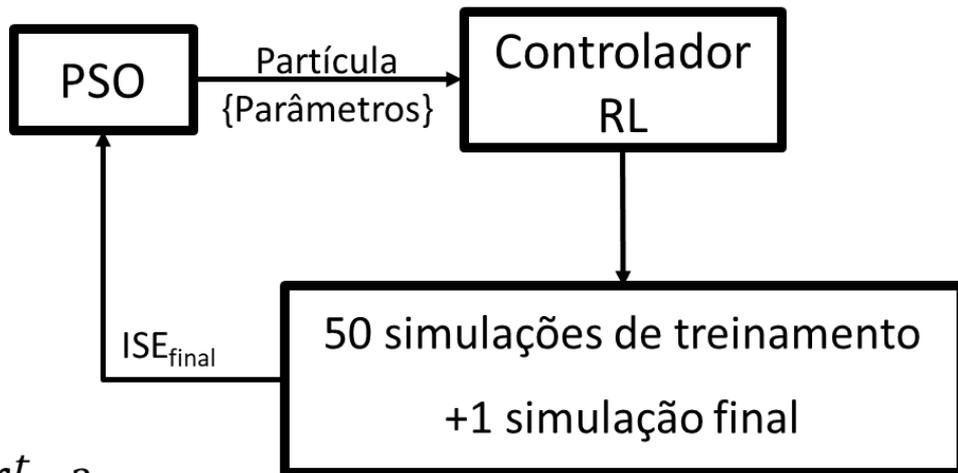
Otimização



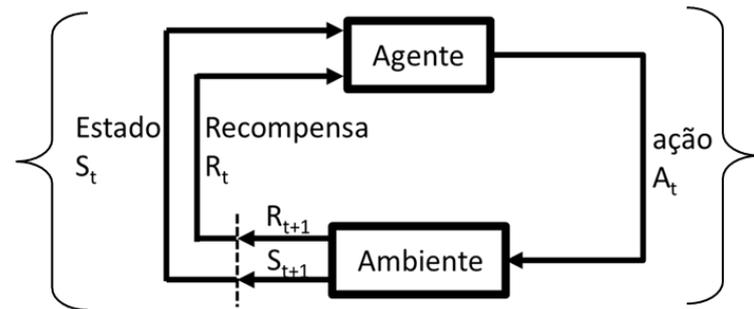
50 simulações de treinamento
+1 simulação final



Otimização



$$ISE = \int_0^t e^2 dt$$



Comparação com P-I



THE
DEVELOPER'S
CONFERENCE

➤ PI, com parâmetros otimizados via PSO

$$A_t = A_{ss} + Kc \left(e_i + \frac{\Delta t}{\tau_i} \sum_0^n e_i \right)$$

- A = Ação;
- Kc = Ganho proporcional;
- e = erro;
- Δt = passo de tempo;
- τ = ganho integral;
- i = instante de tempo
- n = instante de tempo final;



THE
DEVELOPER'S
CONFERENCE

➤ Resultados da otimização dos controladores:

Hiper-parâmetros do RL



THE
DEVELOPER'S
CONFERENCE

Parâmetro	Descrição	Valor
γ	Fator de desconto de recompensas futuras;	0,1185
F	Número de aproximadores de funções;	12
λ	Fator de decaimento do traço de elegibilidade;	0,7013
α_V	Ganho de aprendizado do Actor;	0,0277
α_π	Ganho de aprendizado do Critic;	0,1703
V_N	Velocidade de decrescimento do ruído;	1,1417
K_r	Fator de ajuste de recompensa;	4,1548

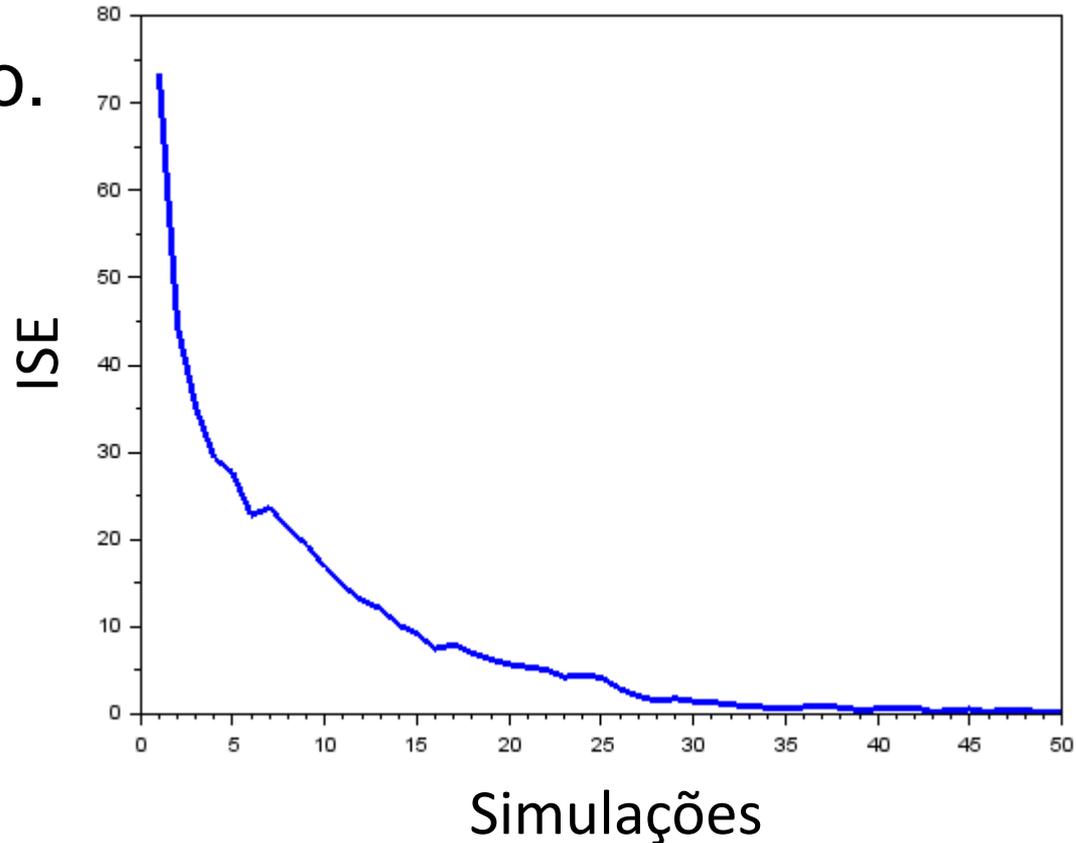
AWS, t2.micro (instância gratuita)

RL Otimizado

- Etapa de treinamento.
- 50 simulações



THE
DEVELOPER'S
CONFERENCE



Parâmetros do PI

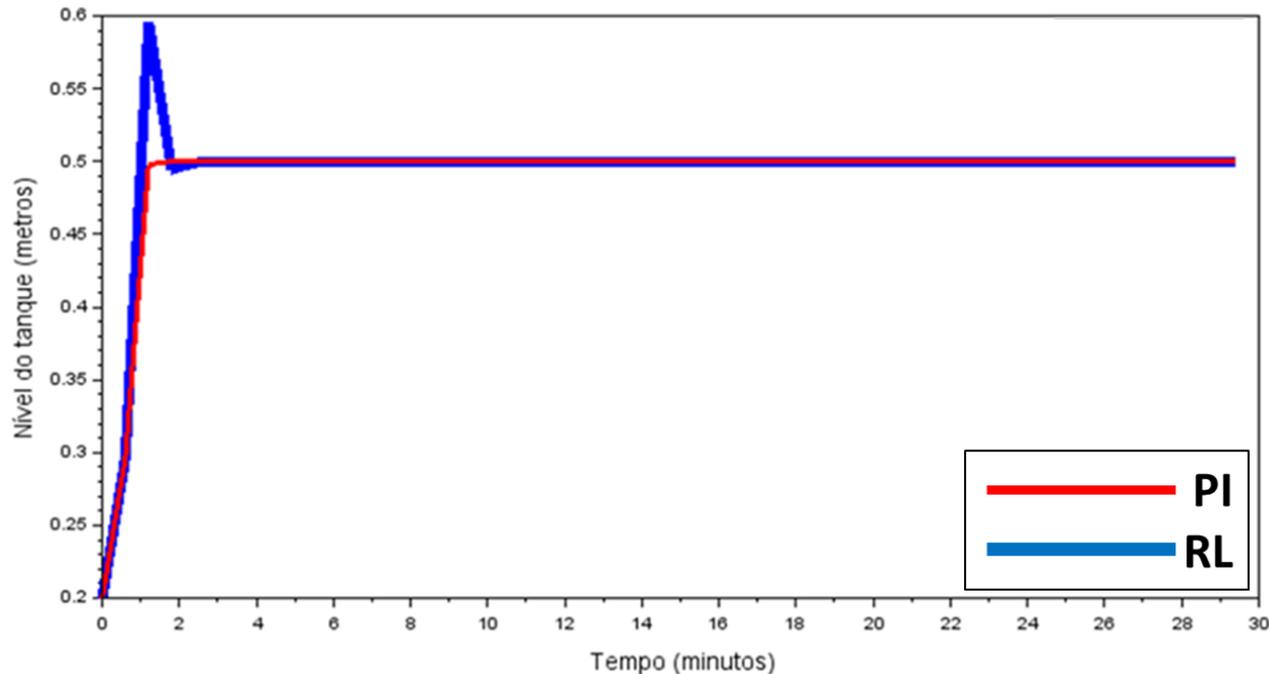


Parâmetro	Descrição	Valor
K_C	Ganho proporcional;	-1,367
τ_i	Ganho integral;	932,1

Onde foram otimizados



➤ Dinâmica da resposta dos controladores:



Solução numérica



- E.D.O. solucionada pelo método de RK4;
- Condição inicial: $h_{t=0} = 0,2\text{m}$
- Scilab 6.0.0;

- Dimensões do tanque: $A_b = 3\text{m}^2$
 $h_{\text{max}} = 1\text{m}$
- Parâmetros: $h_{\text{sp}} = 0,5\text{m}$
 $F_{\text{entrada}} = 100\text{m}^3/\text{h}$

- 2 horas de simulação, $dt = 0,01$ horas

Em novas condições



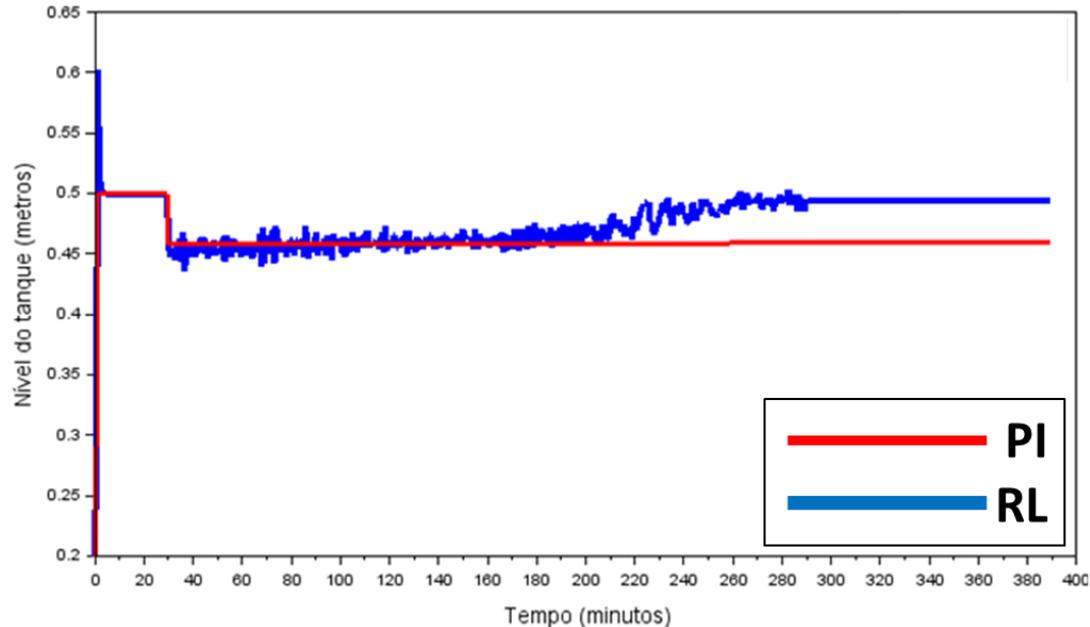
THE
DEVELOPER'S
CONFERENCE

$t < 30\text{min}$

$$F_{\text{entrada}} = 100\text{m}^3/\text{h}$$

$t > 30\text{min}$

$$F_{\text{entrada}} = 85\text{m}^3/\text{h}$$



Em novas condições



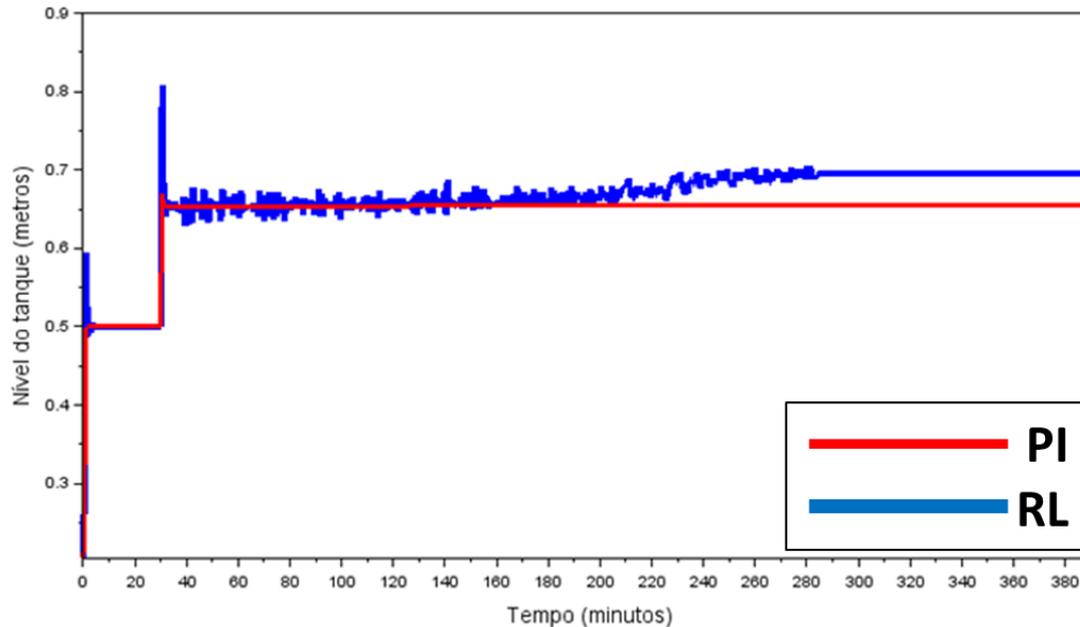
THE
DEVELOPER'S
CONFERENCE

$t < 30\text{min}$

$h_{sp} = 0,5\text{m}$

$t > 30\text{min}$

$h_{sp} = 0,7\text{m}$



Conclusões



- Viabilidade e adaptabilidade do controlador autônomo de processos baseado em Machine Learning, com o algoritmo de RL no estudo de caso de controle de nível de tanque, através de implementação própria no software Scilab.

Muito Obrigado!

Contato:  Douglas Alves Goulart
douglasagoulart@gmail.com



THE DEVELOPER'S
CONFERENCE

