



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
ENG07053 - TRABALHO DE DIPLOMAÇÃO EM  
ENGENHARIA QUÍMICA



# Utilização do controlador no processo de auditoria e diagnóstico de malhas de controle

*Autor: Murilo Becher Dewes*

*Orientador: Jorge Otávio Trierweiler*

*Co-orientador: Leonardo Mandler De Marco*

Porto Alegre, dezembro de 21

## Sumário

Sumário	ii
Agradecimentos	iii
Resumo	iv
Abstract	v
Lista de Figuras	vi
Lista de Tabelas	ix
Lista de Abreviaturas e Siglas	x
1 Introdução	1
2 Revisão Bibliográfica	3
2.1 Metodologia baseada em dados	3
2.2 Uso dos parâmetros do controlador	5
3 Metodologia deste trabalho	8
3.1 Metodologia DECOR	8
3.2 Metodologia proposta	11
4 Resultados	15
5 Conclusões e Trabalhos Futuros	25
6 Referências Bibliográficas	26
Apêndice - A	28

## **Agradecimentos**

Agradeço a Deus pela vida e a saúde para me permitirem fazer o que gosto e o que tomei como propósito a ser seguido. Agradeço aos meus pais, Marineusa Becher Dewes e Carlos Roberto Dewes, por todo o apoio, seja ele financeiro, emocional, enfim, desde antes do começo da graduação até o presente momento.

Agradeço a UFRGS pelo ensino de qualidade, através de seu quadro docente, infraestrutura e por abrir portas para o futuro da minha carreira. Agradeço também aos meus colegas por tornarem, através do convívio diário, uma rotina mais leve e menos estressante, com certeza, sem a presença de vocês isso não teria sido possível. Em especial ao Daniel, Eduardo, Vicente, Letícia e Gabriela.

Por fim, gostaria de agradecer ao professor Dr<sup>o</sup> Jorge Otávio Trierweiler e ao Leonardo Mandler de Marco por terem aceitado serem meus respectivos orientador e co-orientador. Minha eterna gratidão. A ajuda e apoio de vocês foi essencial para a realização deste trabalho. São pessoas que inspiram.

## **Resumo**

A avaliação de performance de controladores representa um importante tópico de pesquisa devido a sua grande demanda em processos industriais de diversos seguimentos. Neste trabalho foi estudado um método capaz de avaliar a sintonia de controladores.

Diversas técnicas de avaliação existem no mercado, porém, poucas fazem uso dos parâmetros dos controladores, que permitem um maior conhecimento sobre o processo. Desta forma, neste trabalho é abordado de forma principal, o uso da função de autocorrelação, apresentada por Márcio Ferreira em 2006. Foram estudadas dez plantas de comportamentos distintos, gerando diversos gráficos e cálculos, para então, compreensão dos resultados obtidos.

Após obtenção dos resultados, discussões foram levantadas a respeito do comportamento dos gráficos, seja no quesito robustez, desempenho, sintonia e outros comportamentos.

Os resultados obtidos com esse método foram satisfatórios, pois a autocorrelação conseguiu identificar as situações em que o controlador estava bem ajustado ou não para as respectivas plantas em estudo, mostrando que a autocorrelação pode ser aplicada para avaliações de performance de malhas de controle, e que possui ainda mais campo para pesquisas e novas formas de ser implementada, para fim de obter maior conhecimento a respeito do assunto.

---

## **Abstract**

Controller performance assessment represents an important research topic for reason to its high demand in industrial processo of various segments. In this work, a method capable of evaluating the tuning of controllers was studied.

Various evaluation techniques exist on the Market, but, few methodologies make use of the parameters of the controllers, that allow for greater knowledge about the process. Thus, in this work it is addressed in a main way, the autocorrelation function, based on the autocorrelation function, presented by Márcio Ferreira em 2006. Ten plants of different behaviors were studied, generating several graphs and calculations, to then, understanding of the results obtained.

After obtaining the results, discussions were raised regarding the behavior of the graphs, for example: robustness, performance, tuning and other behaviors.

The results obtained with this method were satisfactory, because the autocorrelation was able to identify the situations in which the controller was well adjusted or not for the respective plants under study, showing that autocorrelation can be applied for performance evaluations of control loop, and that has even more field for research and new ways of implementing, to gain greater knowlegde of the subject.

## Lista de Figuras

<b>Figura 2.1:</b> Estrutura característica de um controlador <i>feedback</i> .....	3
<b>Figura 3.1:</b> Função de autocorrelação para um controlador com ajuste rápido e um lento. Fonte: (Ferreira, 2006).....	9
<b>Figura 3.2:</b> Pontos para obtenção da inclinação GAN. Fonte: (Ferreira, 2006).....	9
<b>Figura 3.3:</b> A – Resposta a um degrau unitário com diferentes ajustes de controladores. B- Funções de autocorrelação para os respectivos ajustes. Fonte: (Ferreira, 2006).....	10
<b>Figura 3.4:</b> Diagrama de blocos para cálculo do $I_{DECOR}$ .....	11
<b>Figura 3.5:</b> Mesma ação de controle sob a planta real e a ideal.....	12
<b>Figura 3.6:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta J.....	12
<b>Figura 3.7:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta J.....	12
<b>Figura 3.8:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta J.....	13
<b>Figura 3.9:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta J.....	13
<b>Figura 3.10:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta J...13	
<b>Figura 3.11:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta J.....	14
<b>Figura 3.12:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta J.....	14
<b>Figura 4.1:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta C.....	15
<b>Figura 4.2:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta C.....	16
<b>Figura 4.3:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta C.....	16
<b>Figura 4.4:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta C.....	16
<b>Figura 4.5:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta C.....	17
<b>Figura 4.6:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta C.....	17
<b>Figura 4.7:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta C.....	17
<b>Figura 4.8:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta E.....	18
<b>Figura 4.9:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta E.....	18
<b>Figura 4.10:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta E...18	
<b>Figura 4.11:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta E.....	19
<b>Figura 4.12:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta E.....	19
<b>Figura 4.13:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta E.....	19

<b>Figura 4.14:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta E.....	20
<b>Figura 4.15:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta G.....	20
<b>Figura 4.16:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta G.....	20
<b>Figura 4.17:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta G..	21
<b>Figura 4.18:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta G.....	21
<b>Figura 4.19:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta G.....	21
<b>Figura 4.20:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta G.....	22
<b>Figura 4.21:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta G.....	22
<b>Figura A0.1:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta A.....	28
<b>Figura A0.2:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta A.....	28
<b>Figura A0.3:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta A.....	28
<b>Figura A0.4:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta A.....	29
<b>Figura A0.5:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta A.....	29
<b>Figura A0.6:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta A.....	29
<b>Figura A0.7:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta A.....	30
<b>Figura A0.8:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta B.....	30
<b>Figura A0.9:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta B.....	30
<b>Figura A0.10:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta B.....	31
<b>Figura A0.11:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta B.....	31
<b>Figura A0.12:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta B.....	31
<b>Figura A0.13:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta B.....	32
<b>Figura A0.14:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta B.....	32
<b>Figura A0.15:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta D.....	32
<b>Figura A0.16:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta D.....	33
<b>Figura A0.17:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta D.....	33

<b>Figura A0.18:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta D.....	33
<b>Figura A0.19:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta D.....	34
<b>Figura A0.20:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta D.....	34
<b>Figura A0.21:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta D.....	34
<b>Figura A0.22:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta F.....	35
<b>Figura A0.23:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta F.....	35
<b>Figura A0.24:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta F.....	35
<b>Figura A0.25:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta F.....	36
<b>Figura A0.26:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta F.....	36
<b>Figura A0.27:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta F.....	36
<b>Figura A0.28:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta F.....	37
<b>Figura A0.29:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta H.....	37
<b>Figura A0.30:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta H.....	37
<b>Figura A0.31:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta H.....	38
<b>Figura A0.32:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta H.....	38
<b>Figura A0.33:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta H.....	38
<b>Figura A0.34:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta H.....	39
<b>Figura A0.35:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta H.....	39
<b>Figura A0.36:</b> Autocorrelação de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta I.....	39
<b>Figura A0.37:</b> Autocorrelação da ação de controle frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta I.....	40
<b>Figura A0.38:</b> Autocorrelação da ação de controle VS autocorrelação de saída da planta I.....	40
<b>Figura A0.39:</b> Erro de simulação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta I.....	40
<b>Figura A0.40:</b> Erro entre autocorrelação frente a uma mudança de <i>setpoint</i> e um distúrbio na carga da planta I.....	41
<b>Figura A0.41:</b> Sinal da variável manipulada frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta I.....	41
<b>Figura A0.42:</b> Sinal de saída frente a uma mudança de <i>setpoint</i> e a um distúrbio na carga da planta I.....	41

---

## Lista de Tabelas

<b>Tabela 3.1:</b> Parâmetros do controlador.....	11
<b>Tabela 3.2:</b> Parâmetros da planta ideal.....	11
<b>Tabela 4.1:</b> Tabela de integrais das plantas.....	23
<b>Tabela 4.2:</b> Todos os $I_{DECOR}$ calculados.....	24

### Lista de Abreviaturas e Siglas

Abreviaturas	Descrição
DECOR	Método de auditoria de desempenho, não intrusivo, de controladores baseado na análise da autocorrelação da variável controlada.
$I_{decor}$	Índice de desempenho calculado pelo método DECOR
GAN	Gráfico de autocorrelação normalizado
$GAN_r$	Gráfico de autocorrelação normalizado para a malha aberta
$GAN_y$	Gráfico de autocorrelação normalizado para a malha fechada com controlador em específico
$IAE$	Integral do erro absoluto
$MVI$	<i>Minimum Variance Index</i>
$ISE$	Integral do erro quadrático
$ITAE$	integral do erro absoluto ponderado no tempo
$k_p$	Constante proporcional do controlador PI/PID
$\tau_i$	Fator integral de um controlador PI/PID
$\tau_d$	Fator derivativo de um controlador PI/PID
$r_k$	Autocorrelação no atraso $k$
$y_t$	Sinal de saída
$y_{set}$	<i>Setpoint</i> do sinal de saída
$\bar{y}$	Média amostral da saída ou variável controlada
$C_I$	Cálculo do intervalo de confiança
$z$	Função da distribuição normal
$\alpha$	Nível de significância
$n$	Dimensão do vetor de dados coletados
$k$	Deslocamento
$e$	Erro ( $y_t - y_{set}$ )
$t$	Tempo
$\beta$	Beta

---

$\zeta$	Zeta
$\sigma^2 MV$	Variância mínima do processo
$\sigma^2 y$	Variância atual do processo



## 1 Introdução

Nos mais diversificados seguimentos industriais, sejam eles fabricação de papel e celulose, produção de petróleo ou plantas químicas, se faz uso de centenas de milhares de malhas de controle. Em processos de produção contínua, basicamente todas as decisões que afetam a produção, são mudanças de abertura nas válvulas existentes, através de um controlador regulatório, e uma malha que apresenta variação em torno do *setpoint*. A oscilação, ou demora para atingir o *setpoint* implica em perda de dinheiro, portanto, qualquer melhoria que seja realizada em uma malha de controle pode ter um impacto financeiro significativo em uma empresa.

Dentre todos os tipos de controladores existentes no cenário industrial, os do tipo PID (*Proportional Integral Derivate*) possuem maioria considerável, com mais de 90% de presença, devido a sua simplicidade e robustez, Veronesi e Visioli (2012), e também dois terços desses tem possibilidade de melhoria, apresentando uma ampla oportunidade de mercado e estudos (Airikka, 2012)(Shahni et al., 2019).

Conforme mencionado, todas essas malhas de controle são acompanhadas por poucos engenheiros de processos existentes em uma planta industrial, logo, é fácil de se imaginar que é uma tarefa praticamente inviável fazer isso manualmente, ainda mais, quando uma malha de controle não atua sozinha, existe uma cadeia de ligações entre elas, onde uma afeta na outra, e o número de variáveis existentes em um processo contínuo de grande escala é enorme. Sendo assim, técnicas e ferramentas que realizem uma avaliação de performance são essenciais e causam impacto relevante.

Quando uma malha de controle é recém programada para algum processo em específico, é de se esperar que sua performance seja a melhor possível, porém, com o passar do tempo, diversos fatores contribuem para que o desempenho tenha um decaimento, sejam eles: degradação ou incrustação dos equipamentos, ponto de operação não é mais o mesmo daquele na qual a malha de controle foi projetada, agarramento de válvula, entre outros (Kempf, 2003).

No momento que se define que será realizada uma avaliação de performance de malhas de controle, é necessário ter um *benchmark*, para ao chegar nos resultados, o diagnóstico seja o correto, e evitar que decisões erradas sejam tomadas, uma vez que os resultados por si só não são conclusivos.

Em uma malha de controle, existem variações que são inerentes ao processo e impossíveis de se retirar, e também estão presentes outras anomalias que, somadas ao citado anteriormente, fazem com que a malha não opere em sua eficiência máxima. O objetivo de uma avaliação de performance foca justamente nesse desvio que é viável de correção.

Usando dados de operação normal, no trabalho de Harris (1989) é apresentado o controlador de variância mínima como método de comparação de desempenho do controlador. Seu intuito foi conseguir quantificar essas variâncias naturais com aquelas em excesso, que acabam prejudicando o desempenho da malha de controle. Após esse estudo, novos trabalhos discutindo sobre a avaliação de performance surgiram, trazendo novas metodologias, tanto estocásticas quanto determinísticas, que serão mais detalhadas no capítulo 2.

Depois que a avaliação de performance é feita, e constata-se um mau desempenho, deve ser feito o diagnóstico da malha de controle, e quatro são as causas mais recorrentes: Desvios, dinâmicas pobres, alta variabilidade e oscilações (Rengaswamy et al., 2020).

Considerado o cenário atual e as informações já apresentadas, optou-se pela realização de uma avaliação de performance de malha de controle, a fim de diagnosticá-la, onde uma metodologia inovadora será aplicada, fazendo-se uso dos parâmetros do controlador na avaliação de performance da malha de controle, tecnologia essa, que tem ganhado espaço na comunidade acadêmica. Eventualmente, se necessário, propor um tratamento corretivo, no intuito de tornar essa malha de estudo apta para um melhor desempenho (Liu e Yoo, 2011) (De Francisco et al., 2019).

Conforme será visto na sequência do trabalho, o fato de se fazer uso dos dados da planta, e principalmente, o uso explícito do controlador, fornecem uma ampla vantagem para a realização de um diagnóstico mais interessante em comparação aos métodos já existentes e utilizados. Logo, será realizada uma auditoria do desempenho de um controlador, fazendo uso da autocorrelação de saída e da ação de controle.

O trabalho está organizado na seguinte forma: no capítulo 2 será feita uma revisão bibliográfica sobre o assunto, apresentando o que já existe de consolidado sobre avaliação de performance de malhas de controle. No capítulo 3 será mostrado a metodologia que será utilizada no decorrer do trabalho. No capítulo 4 estarão os resultados obtidos com a abordagem de estudo utilizada. Conclusões a qual o estudo levou e sugestões de trabalhos futuros que complementem o assunto serão apresentados no capítulo 5. Após a conclusão, são apresentadas as referências bibliográficas utilizadas como fontes, e depois, um apêndice com gráficos apresentando os resultados completos das análises realizadas.

## 2 Revisão Bibliográfica

As avaliações de desempenho de malhas de controle seguirão preferencialmente dois caminhos de estudo nesta revisão, uma abordagem determinística e outra estocástica. De uma forma resumida, métodos estocásticos necessitam apenas de dados operacionais de rotina normal e uma estimação do tempo morto da malha de controle, contudo, não levam a resultados muito conclusivos; enquanto, uma análise determinística é mais eficiente nesse quesito, contudo para a realização da mesma é necessária uma perturbação de carga no sistema, e se tratando de uma linha de produção, possíveis perdas de produtividade podem ocorrer. Portanto, o ideal seria a unificação dos dois mundos, uma avaliação qualificada quanto a determinística, porém, não invasiva e com poucos dados como a estocástica (Farenzena, 2008).

Controladores *feedback* geralmente tem a estrutura apresentada na Figura 2.1.

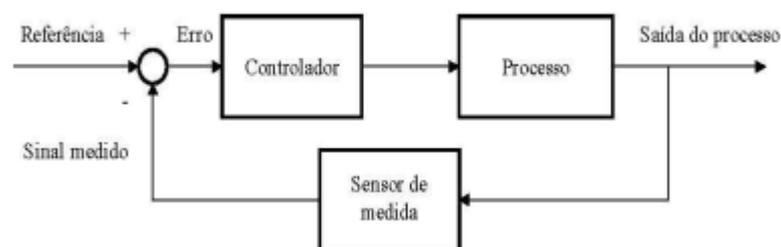


Figura 2.1: Estrutura característica de um controlador *feedback*.

### 2.1 Metodologia baseada em dados

Algumas técnicas para avaliação de performance de malhas de controle são bem difundidas e com literatura rica, como por exemplo: o Índice de Variância Mínima, Integral Absoluta do Erro, Integral Quadrática do Erro. Todas possuem seus benefícios e lacunas abertas que serão elucidadas no decorrer do trabalho.

O Índice de Variância Mínima (MVI, do inglês *Minimum Variance Index*) deixa algumas lacunas sem respostas, e outras de difícil interpretação que podem levar ao erro. O MVI não apresenta nenhum parâmetro que possa tirar conclusões sobre a robustez do sistema, apresenta uma dependência de padrões de distúrbio, sua margem de interpretação é reduzida, onde a diferença entre uma malha de controle boa e ruim é pequena e também possui uma escala não conclusiva, na qual a análise pura do valor pode levar ao engano o engenheiro que está interpretando o resultado (Farenzena, 2008).

O MVI usa os dados de saída do processo, portanto, depende fortemente dos sinais de leitura dos sensores, e se tratando de um processo de monitoramento contínuo, eventualmente existem erros de leitura que prejudicam a análise, fornecendo resultados não fiéis com a realidade da operação. Além do mais, é um método vinculado ao tempo de amostragem, logo, é necessária uma grande quantidade de dados coletados para a realização da avaliação, o que torna o MVI menos interessante em relação a metodologia que será aplicada neste trabalho (Farenzena, 2008).

Um problema das avaliações de performance está nos dados coletados, uma vez que alguns são excluídos ou comprimidos, em outras palavras, são alterados pelo *software* que faz a leitura, então novamente, o cálculo fornece um valor que não é condizente com a realidade.

A coleta de dados de rotina é importante na avaliação de performance. Os dados se comportam de diversas maneiras: constantes, puramente aleatórios, com periodicidade, por exemplo, se comportando como uma função seno. Logo, isso é fundamental para o cálculo de variância na saída do processo e está fortemente atrelado ao tamanho da amostra de dados coletadas (Rengaswamy et al., 2020).

O método estocástico tem a vantagem de não ser um método invasivo, ou seja, não é necessário provocar perturbações na produção, o que academicamente seria interessante por levar a melhores resultados, porém, pode levar a perdas de produtividade. Portanto, basta informações de rotina e tempo morto. Como *benchmark*, é escolhido um período de referência, no qual a malha de controle teve seu melhor desempenho, na maioria das vezes, no começo da campanha da planta. De posse desse período de ouro é feita a avaliação na faixa de tempo de interesse (Farenzena, 2008).

A amostragem de dados é um fator relevante para a realização de uma avaliação. Em um cenário ideal, uma grande quantidade de dados está disponível para assim, os cálculos serem mais confiáveis, porém, dependendo da dinâmica do processo, ou no caso de impossibilidade de se obter esses valores, depara-se com uma situação de difícil resolução. Em casos onde a frequência de amostra de dados é pequena, o tempo morto ganha ainda mais significância na avaliação e é requerido que uma dinâmica rápida seja implementada na malha de controle (Kempf, 2003).

O Índice de Variância Mínima (MVI) é dado pela Equação 2.1, onde o  $\sigma^2 MV$  é a variância mínima do processo e  $\sigma^2 y$  é a variância atual do processo (Farenzena, 2008).

$$MVI = \frac{\sigma^2 MV}{\sigma^2 y} \quad (2.1)$$

A integral absoluta do erro (IAE), dada pela Equação 2.2, é a integral do valor absoluto do sinal de erro no tempo. É equivalente a soma das áreas acima e abaixo do *setpoint* (MARLIM, 1995).

$$IAE = \int |e(t)| dt \quad (2.2)$$

A integral do erro quadrático (ISE) é a integral do quadrado do sinal de erro no tempo, dada pela Equação 2.3. Esse indicador penaliza mais valores maiores do sinal de erro (MARLIM, 1995).

$$ISE = \int e(t)^2 dt \quad (2.3)$$

A integral do erro absoluto ponderado no tempo (ITAE), definido pela Equação 2.4, é a integral do tempo multiplicado pelo valor absoluto do sinal de erro no tempo e penaliza erros que se mantêm no tempo (MARLIM, 1995).

$$ITAE = \int t|e(t)| dt \quad (2.4)$$

Novamente, em uma avaliação de performance de malhas de controle, onde o método escolhido é o IAE, o benchmark consiste em se obter um valor de IAE teórico, ou seja, um valor que seja aceitável no processo. Para isso, distúrbios de carga são aplicados, a fim de

se observar o comportamento do sistema e obter esse valor. Após isso, é então avaliado um IAE real, para então ser feita a comparação entre os dois, calculando a razão  $IAE_{teórico}/IAE_{real}$ . Quando o valor for um, tem-se a melhor performance possível da malha de controle, conforme for se aproximando de zero, a performance vai enfraquecendo. É assumido que valores abaixo de 0,8 são passíveis de ajuste (Ghousiya Begum et al., 2020).

Porém como observado, tanto para o IAE quanto para outros métodos apresentados, observa-se uma forte dependência da amostragem de dados, além dos índices serem calculados puramente em função dos valores de saída do sistema, ignorando os parâmetros do controlador.

No trabalho de Huang e Jeng (2002) é realizada uma avaliação de performance em que a metodologia usada é o IAE, um ponto positivo nesse estudo, é que a avaliação de performance pode ser feita continuamente, ou seja, se tem um monitoramento online da qualidade de ajuste do controlador.

Ferreira (2006) faz um breve resumo histórico das avaliações existentes e propõe uma nova metodologia, o índice DECOR, que significa a derivada da correlação entre os dados de saída da planta. É um método interessante, pois é de rápida aplicação, uma vez que depende apenas dos valores de saída e que leva a resultados bem conclusivos, permitindo uma comparação entre malhas diferentes, fator esse, que é raro em outros métodos avaliativos.

## 2.2 Uso dos parâmetros do controlador

Este trabalho traz uma abordagem relativamente recente no cenário de avaliação de performance de malha de controle, onde se faz uso explicitamente dos parâmetros do controlador, e se busca pelo menor uso possível dos dados de tempo reais, ou seja, uma menor dependência do tempo de amostragem em relação a métodos convencionais de avaliação de performance.

Nos estudos de Desborough e Harris (1992) pode-se concluir que amostras com pouco banco de dados devem ser evitadas, pois as propriedades estatísticas são muito afetadas por pontos ruins e a variabilidade aumenta. Na contramão, amostras excessivamente grandes escondem mudanças no desempenho, fazendo com que o índice represente uma média do desempenho. Thornhill et al. (1996) indica que, para dados de refinarias, uma boa relação entre a confiança estatística e a caracterização adequada da malha é obtida com 1500 pontos de amostra. Atualmente, avaliações mais robustas estão disponíveis, usando informações implícitas do modelo contidas no processo, avaliações de integral absoluta do erro, estimações de atraso no tempo e outras informações são apresentadas nos trabalhos de (Jelali, 2006)(Yu e Li, 2021).

Após realizada a avaliação de performance das malhas de controle, e o diagnóstico detectar má sintonia, deve ser realizado um ajuste nos parâmetros para a devida correção. Logo, existem vários *softwares* específicos para isso difundidos no mercado, ou no caso de ausência deles, métodos iterativos são aplicados em modelos que simulam o processo, onde com poucas iterações, são obtidos os novos parâmetros ideais para a sintonia da malha de controle (Howard e Cooper, 2009)(Kempf, 2003).

As primeiras metodologias de sintonia de controladores PID foram feitas por Ziegler e Nichols (1942), sua proposta apresentava um sistema com baixa robustez, mas foi fundamental pela iniciativa, e até hoje, variantes aperfeiçoadas do processo são utilizadas. Outros métodos de sintonia são encontrados na literatura, como resposta em frequência, resposta ao degrau, CHR, Cohen e Coon, Integral do erro, Método do Modelo Interno, etc. (Paulino e De Araújo, 2015).

Vale ressaltar, que os ajustes dos parâmetros são diferentes para quais objetivos se pretendem corrigir, se é fazer com que a malha rejeite melhor aos distúrbios, ou tenha sua característica servo aprimorada, sempre considerando em primeiro lugar, manter a estabilidade do sistema. Em casos em que o ajuste dos parâmetros não resulta em melhoria, mudanças na estrutura da malha de controle é o passo seguinte a ser tomado, e por fim, adicionar mais sensores para ter um melhor monitoramento do processo, todavia, dependendo de um investimento financeiro para a realização do mesmo.

No trabalho de Yu et al.(2011) é apresentada uma metodologia de avaliação de performance invasiva, onde mudanças de *setpoint* são necessárias, e apresenta bons resultados quando se busca por uma avaliação no quesito de rastreamento de ponto de ajuste, sejam eles, degrau, rampa ou outros. Porém, deixa lacunas abertas quando o interesse é a avaliação de rejeição de distúrbios.

Em Gao et al. (2017b) uma avaliação de performance de malhas de controle é realizada com perturbações no processo, e um cálculo de Integral do erro quadrado é feito para então medição da qualidade de ajuste dos parâmetros. O método apresentou bons resultados de avaliação a mudanças de *setpoint* e é interessante para rejeição de alarmes falsos quando a malha tem por objetivo o controle rigoroso de níveis.

Poucas informações a respeito do uso explícito do controlador em avaliações de performance estão presentes na literatura, pois é uma abordagem recente comparada a métodos já consolidados e amplamente utilizados nas indústrias, conforme apresentado ao longo desse trabalho. Contudo, o que existe, indica um método bastante promissor com vantagens significativas como pode ser observado nos trabalhos de (De Francisco et al., 2019).

Um conceito que deve estar bem esclarecido na realização desse método de avaliação de performance é o esforço do controlador. Isso é fundamental na proposição do *benchmark* que será utilizado, pois deve se conciliar a qualidade do ajuste com o esforço empregado para garantir essa qualidade. Um esforço de controle muito elevado, se torna inviável industrialmente, porque exigiria uma atuação continua das válvulas envolvidas no processo, acarretando em um menor tempo de vida útil delas (Gao et al., 2017a).

Avaliações de performance de malhas de controle onde são realizadas perturbações, além de apresentarem resultados mais confiáveis, necessitam de menor quantidade de dados de amostras, geralmente, o suficiente para o sistema atingir o equilíbrio novamente, o que é positivo do ponto de vista de não ficar tão dependente da coleta dos dados, que podem trazer consigo erros de leitura (Pereira et al., 2018).

As vantagens do método que será apresentado no capítulo 3 incluem o fato de não ser necessário conhecer o processo, ou seja, não precisa de informações anteriores, nem do modelo para a implementação do mesmo. Também apresenta bons resultados quando empregado em processos não lineares, o que em outros casos é um problema significativo

---

na hora de se fazer a modelagem, pois processos desse tipo são complicados de se controlar e podem apresentar instabilidade. Possui bons resultados quando avaliado em controladores de alta ordem, o que também geralmente é complicado, e simplificações são feitas para facilitar o processo.

Com os resultados obtidos é possível ver se o processo apresenta uma melhoria, seja para o rastreamento do ajuste, ou a rejeição de distúrbios, sem a necessidade de uma implementação prática, levando em conta o cenário industrial no qual se está inserido é uma vantagem econômica.

### 3 Metodologia deste trabalho

A metodologia que será usada neste trabalho comunga algumas das ideias propostas por Ferreira (2006) tendo como principal diferença a inclusão da análise de autocorrelação da entrada como uma das principais alterações.

#### 3.1 Metodologia DECOR

Para a realização da avaliação de performance, seguindo o método proposto por Ferreira (2006), bastam apenas os dados de saída do processo, pois a função de autocorrelação, correlaciona os dados do processo entre eles. Basicamente, ela avalia o quanto um valor de saída é dependente do valor anterior, ou se eles são randômicos. Logo, quando o processo é afetado por um distúrbio ou uma mudança de *setpoint* é natural que os valores de saída tenham correlação ao valor anterior, mas essa dependência deve durar o menor tempo possível, e é isso que o índice DECOR avalia.

É necessário ter um horizonte de predição com dados maior do que o tempo morto e para controladores bem ajustados, a função de autocorrelação deve cair rapidamente para zero tão logo o tempo morto tenha transcorrido. Quando a função de autocorrelação está próxima de zero, ou seja, dentro do intervalo de confiança, é dito que seus valores não possuem correlação alguma, e conforme vão se afastando em direção ao 1 e ao -1, logo, fora do intervalo de confiança, significa que o grau de correlação entre os valores é maior.

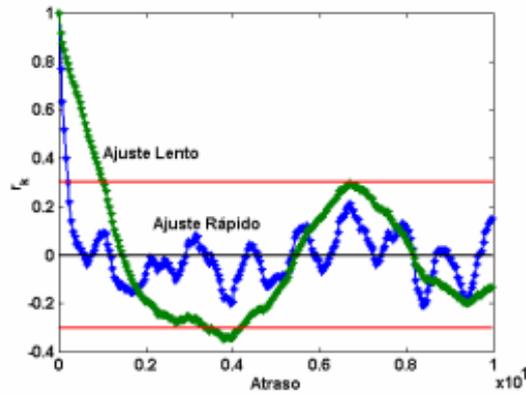
Quando se analisa o índice DECOR, a interpretação do resultado deve ser outra. São possíveis apenas valores positivos, sendo que quanto mais próximo a zero, indica uma lentidão na malha de controle, ou seja, um péssimo ajuste dos parâmetros, e um índice próximo a 1 diz que o controlador está bem ajustado. Valores maiores do que 1, indicam que o ajuste está muito rápido em relação a referência, podendo causar oscilações na planta.

A função de autocorrelação é dada pela Equação 3.1.

$$r_k = \frac{\sum_1^{n-k} (y_i - \bar{y})(y_{i+k} - \bar{y})}{\sum_1^n (y_i - \bar{y})^2} \quad (3.1)$$

Um fator importante e que facilita a interpretação futura dos resultados é que a função de autocorrelação não é dependente da amplitude ou intensidade do sinal, devido aos dados serem relacionados com eles mesmo. Isso diminui os erros de interpretação e permitem a comparação com controladores de outras malhas, o que não é possível com outros métodos convencionais. Também não é preciso realizar perturbações ou mudanças de *setpoint* para se obter o índice de desempenho, portanto, não é um método invasivo, o que se tratando de plantas industriais, é um fator importante para não acarretar perdas financeiras para a empresa.

Na realização de um gráfico da função de autocorrelação existe um intervalo de confiança, que é calculado baseado nos próprios dados. Uma vez que os valores entram neste intervalo de confiança, é declarado que eles são não correlacionados. O tempo que demora para os valores entrarem no intervalo diz respeito a performance da malha, como pode ser visto na Figura 3.1. A curva verde demora mais para entrar no intervalo, caracterizando um ajuste lento, o contrário é percebido na curva azul.

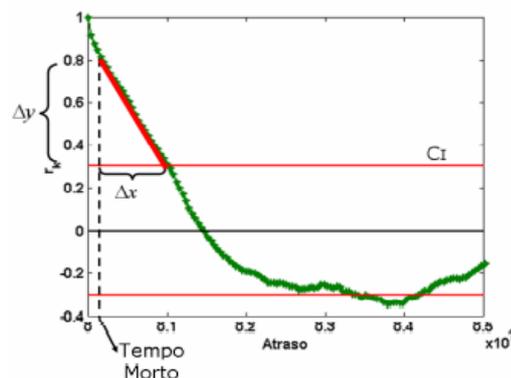


**Figura 3.1:** Função de autocorrelação para um controlador com ajuste rápido e um lento.  
Fonte:(Ferreira, 2006)

O intervalo de confiança é dado pela Equação 3.2. onde  $Z_1$  é a função de distribuição normal e  $\alpha$  é o nível de significância, sendo assumido como 95%.

$$C_I = Z_{1-\alpha/2} \sqrt{\frac{1}{n} \left( 1 + 2 \sum_{i=1}^k y_i^2 \right)} \quad (3.2)$$

Para a obtenção de um valor mensurável da qualidade de ajuste dos parâmetros do controlador é calculada a inclinação da reta obtida, através da relação  $\Delta y / \Delta x$ , que nesse trabalho será chamado de GAN. O valor para o cálculo não é pegado no instante zero, pois o controlador age após o tempo morto, logo, o cálculo possui a seguinte estrutura, conforme a Figura 3.2. Onde os pontos de extremidade da reta são o primeiro após o tempo morto ter transcorrido e o primeiro após a curva ingressar no intervalo de confiança.



**Figura 3.2:** Pontos para obtenção da inclinação GAN.  
Fonte: (Ferreira, 2006)

De posse do gráfico de autocorrelação e do valor da inclinação da derivada, é possível realizar o diagnóstico e afirmar se o comportamento da malha de controle é satisfatório ou passível de melhoria para a planta na qual ela está atuando. O próximo passo é uma espécie de engenharia reversa, onde de posse dos parâmetros do controlador, é estimado um modelo de planta para a qual o controlador atual teria seu melhor comportamento, ou seja, a planta com uma dinâmica específica na qual o controlador em estudo teria seu

melhor desempenho. Isso também funciona como um *benchmarking* para ter uma comparação de como estava a sintonia dos parâmetros do controlador para a planta que ele estava atuando.

Portanto, se deve ter posse dos parâmetros do controlador, o que na prática, são de fácil acesso, para assim simular um modelo de comportamento de planta.. A planta ideal neste trabalho foi estimada usando o método IMC.

O uso dos parâmetros do controlador é fundamental na estimação de um modelo de planta, pois mesmo que eles estejam mal sintonizados, permitem ter um norte para guiar a simulação. Caso contrário, a amplitude de possibilidades de comportamento de plantas dificultaria a realização da mesma.

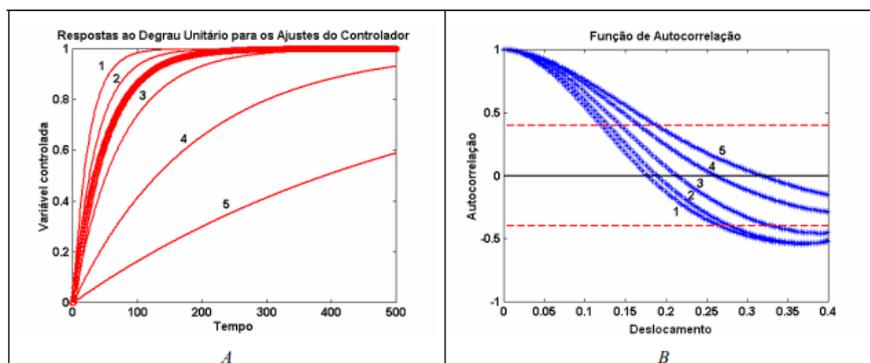
Para a obtenção do índice DECOR se deve possuir o GANr e o GANy. O GANr é a inclinação da função de autocorrelação para os valores estimados com o modelo ideal, logo, ele é a referência, pois apresenta a melhor situação possível de aplicação industrial, conforme foi mostrado anteriormente na figura 3.2. Enquanto isso, o GANy é a inclinação obtida na função de autocorrelação com os valores da planta atual, ou seja, os dados reais da planta. Vale ressaltar que ambos os ganhos são obtidos com o mesmo controlador, o que muda nesse trabalho são as plantas nas quais ele está atuando.

O índice DECOR é a razão entre o GANy e o GANr obtido através da Equação 3.3.

$$I_{DECOR} = \frac{GAN_y}{GAN_r} \quad (3.3)$$

Depois de estimado o modelo de planta para qual o controlador teria seu melhor desempenho, é possível realizarmos vários DECOR com os valores que seriam simulados com outras plantas, para assim, realizar a comparação com o controlador inicial e ver as diferenças que surgiram.

Conforme pode ser visto na Figura 3.3, onde foi realizado um degrau unitário e o comportamento a diferentes ajustes de controladores. À direita é visto a função de autocorrelação para cada controlador. Como pode ser analisado, a curva 1 apresenta a dinâmica mais rápida, e logo, a função de autocorrelação que entra no intervalo de confiança no menor tempo entre todas.



**Figura 3.3:** A – Resposta a um degrau unitário com diferentes ajustes de controladores. B- Funções de autocorrelação para os respectivos ajustes. Fonte: (Ferreira, 2006)

Na Figura 3.4 é apresentado o fluxograma que deve ser seguido para a realização correta da metodologia apresentada neste capítulo.

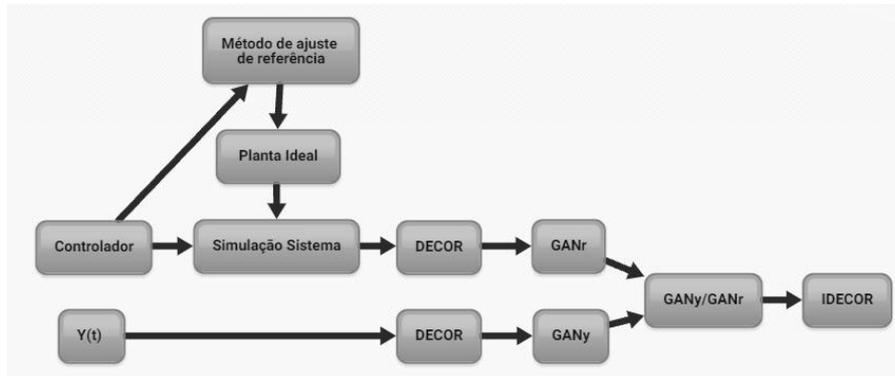


Figura 3.4: Diagrama de blocos para cálculo do  $I_{DECOR}$ .

### 3.2 Metodologia proposta

A diferença significativa do método que será empregado neste trabalho em relação aos outros existentes na literatura é o uso explícito dos parâmetros do controlador. Geralmente essas informações são de fáceis acesso no ambiente industrial, portanto, isso não é um empecilho na avaliação. Além disso, é requisitado dados de rotina do processo para a construção do *benchmark*. A metodologia é composta por 9 passos, sendo estes listados abaixo.

Passo 1: Ter os parâmetros do controlador. Neste trabalho foi utilizado um controlador PID conforme pode ser visto na Tabela 3.1.

Tabela 3.1: Parâmetros do controlador

$k_p$	$\tau_i$	$\tau_d$
2	8,8	2

Passo 2: Criar uma planta ideal para o controlador em estudo. Pelo método IMC foi obtida a seguinte dinâmica de planta apresentada na Tabela 3.2.

Tabela 3.2: Parâmetros da planta ideal

$k$	$\tau_1$	$\tau_2$	$\beta$	$\zeta$
1,05	4,19	5	5	1,05

Passo 3: Ter plantas reais para serem estudadas. Nesta metodologia será tomada a planta J, que está apresentada na Equação 3.4 a fim de exemplificar os passos a serem realizados.

$$G_J(s) = \frac{1}{32s^3 + 20,8s^2 + 4,4s + 1} \quad (3.4)$$

Passo 4: Aplicar mudanças de *setpoint* e distúrbios de carga nas plantas reais sob ação do controlador.

Passo 5: Utilizar a mesma ação de controle da planta real na planta ideal, conforme pode ser visto na Figura 3.5, onde P é a planta Real e Gm é a planta ideal.

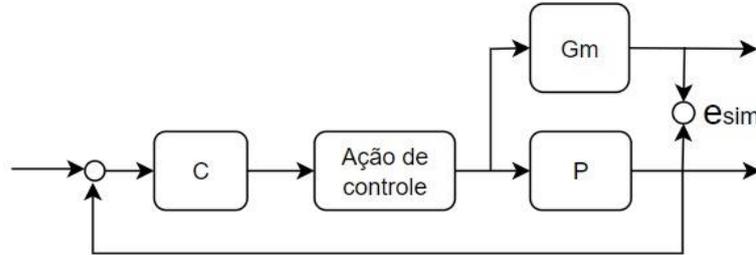


Figura 3.5: Mesma ação de controle sob a planta real e a ideal

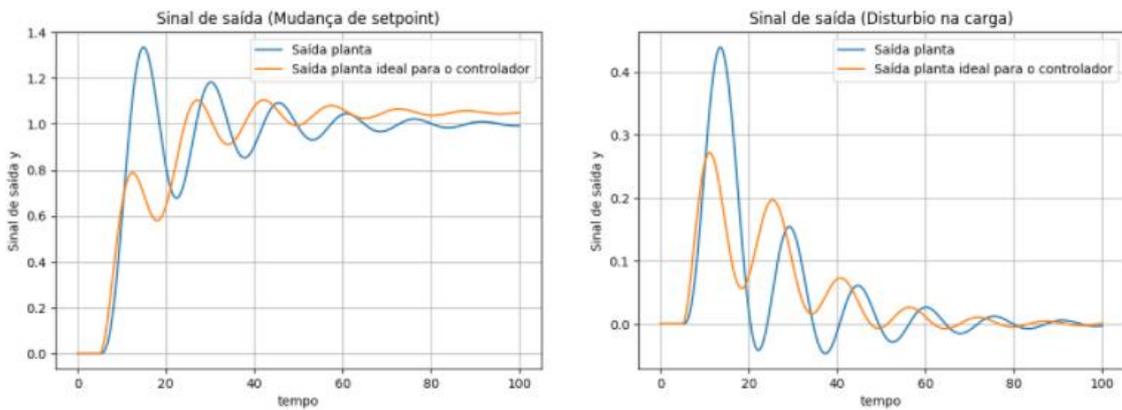


Figura 3.6: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta J

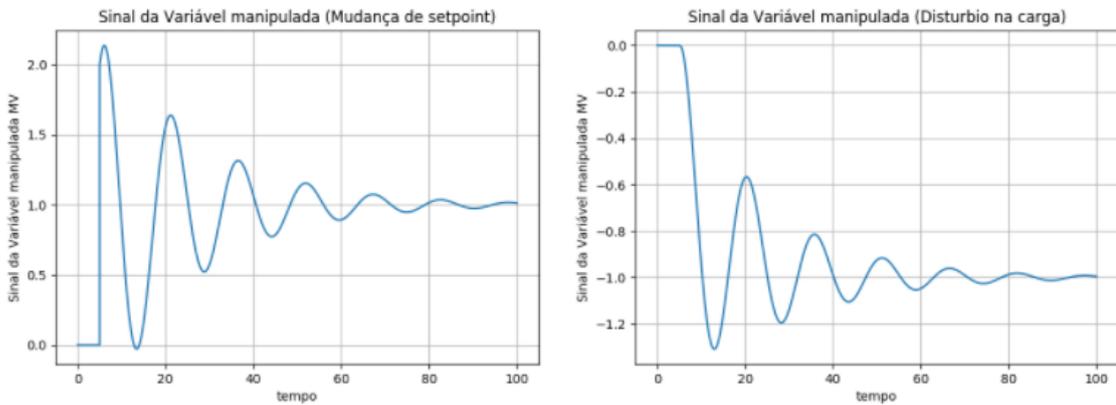


Figura 3.7: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta J

Passo 6: Realizar o cálculo da função de autocorrelação para a saída e para ação de controle.

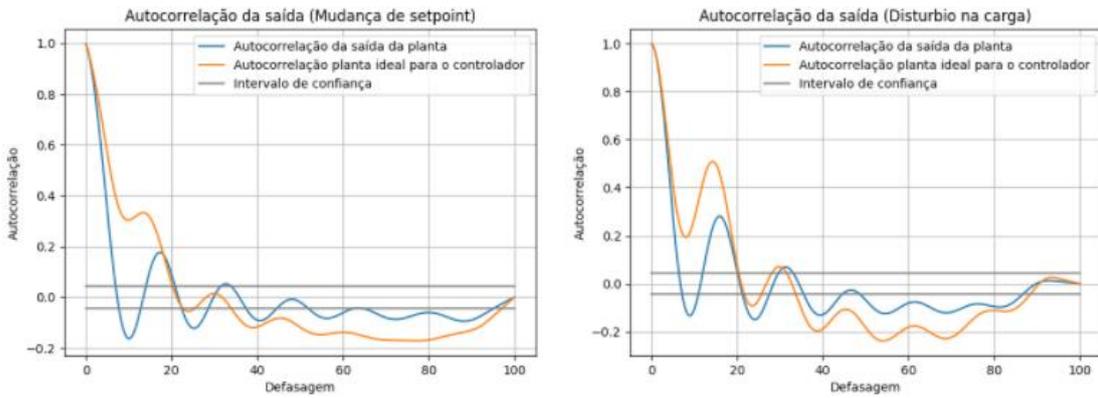


Figura 3.8: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta J

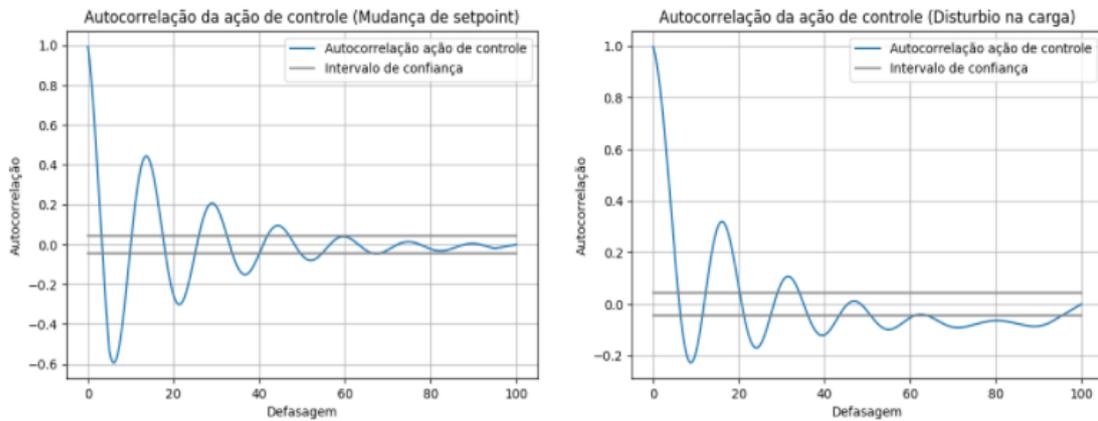


Figura 3.9: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta J

Passo 7: Plotar as duas autocorrelações juntas. Através deste gráfico é possível obter o desempenho do controlador, pois se existir oscilação no eixo X, o controlador não é robusto, devido a oscilação da ação de controle. Se apresentar oscilação no eixo Y o controlador não tem performance, pois uma oscilação na saída está presente.

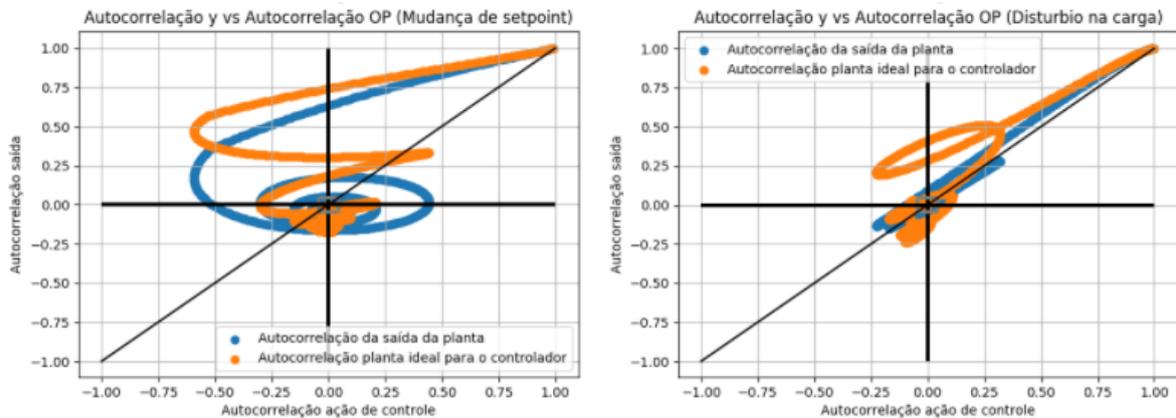


Figura 3.10: Autocorrelação da ação de controle VS autocorrelação de saída da planta J

Passo 8: Calcular o erro de simulação e o erro entre as autocorrelações.

Passo 9: Aplicar a função de sensibilidade em ambos os erros. A função de sensibilidade é utilizada a fim de reduzir a intensidade do sinal compensando a discrepância em malha aberta.

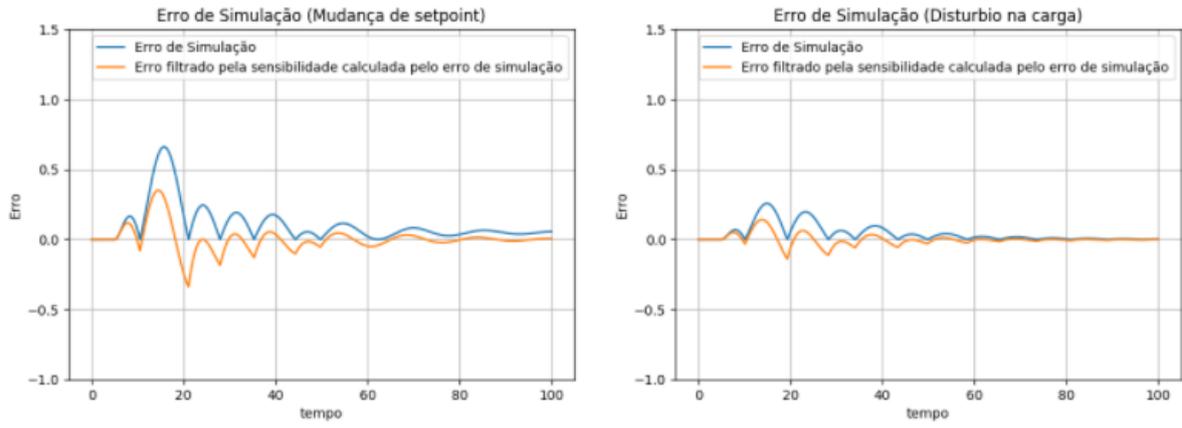


Figura 3.11: Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta J

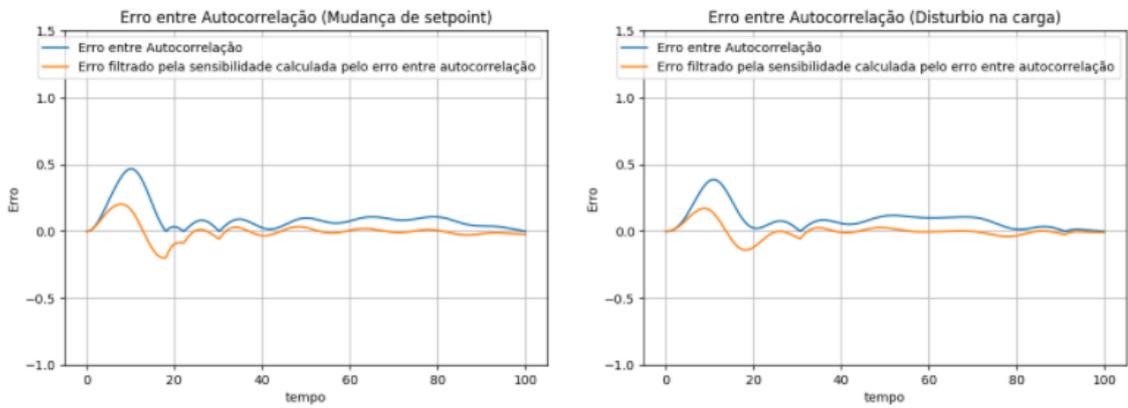


Figura 3.12: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta J

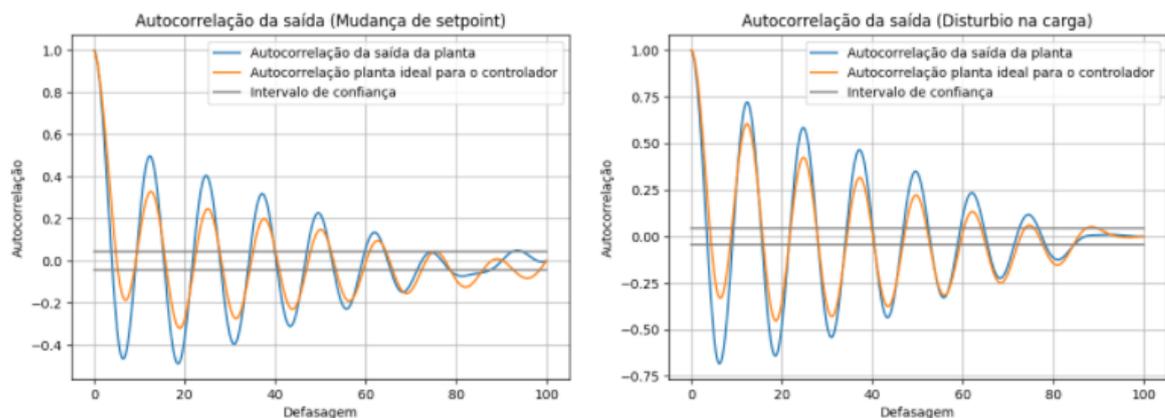
## 4 Resultados

Nesta seção de resultados, serão apresentados os estudos realizados segundo a metodologia do capítulo anterior. Realizou-se avaliações em 10 plantas diferentes, nomeadas em ordem alfabética, mediante mudanças de *setpoint*, no formato de degrau e distúrbios na carga, as quais todas geraram gráficos para interpretação dos resultados obtidos. Por uma questão de otimização de leitura e tamanho do trabalho, no corpo escrito conterà apenas 3 plantas estudadas e as outras se encontrarão no apêndice A.

As três primeiras plantas eram de primeira ordem, sendo que a A não possuía tempo morto enquanto a B e C sim, logo, como ambas são semelhantes optou-se por escolher apenas uma dessas para ser detalhada, no caso, a planta C. A Equação 4.1 apresenta a dinâmica da planta estudada.

$$G_C(s) = \frac{1}{5s + 1} e^{-5s} \quad (4.1)$$

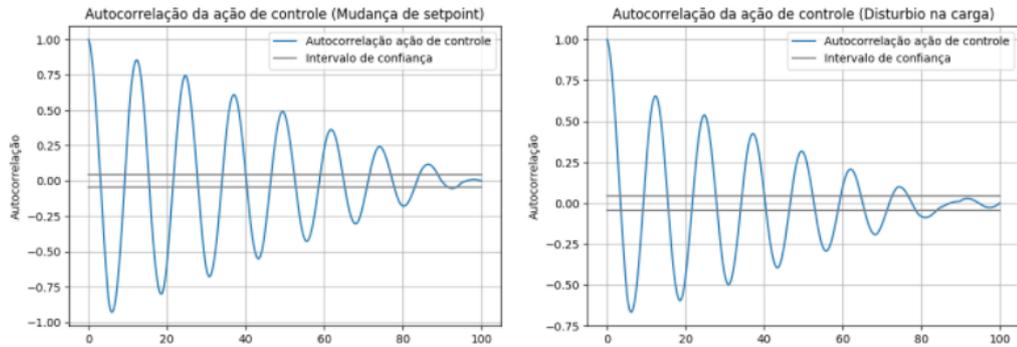
A seguir, são apresentados os gráficos obtidos para o respectivo estudo. Na Figura 4.1 é mostrada a autocorrelação de saída, para o caso de mudança de *setpoint* e para distúrbio na carga.



**Figura 4.1:** Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta C

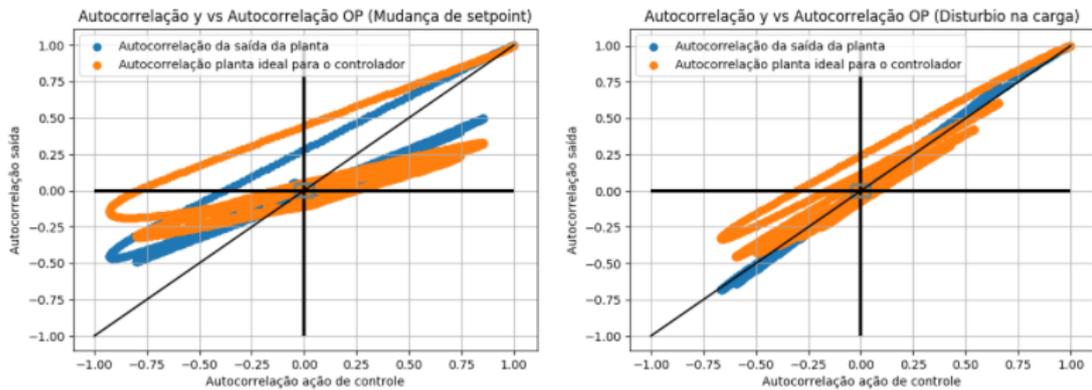
Neste gráfico é possível de se observar que o controlador estabilizou a planta de uma maneira que não pode ser considerada suficiente, pois os dados de saída permanecem correlacionados por um longo tempo. Em um cenário industrial seria esse o gráfico no qual o engenheiro de processo teria acesso para realizar a avaliação de performance da malha de controle.

Na Figura 4.2 é apresentada a autocorrelação da ação de controle frente a uma mudança de *setpoint* e a um distúrbio na carga.



**Figura 4.2:** Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta C

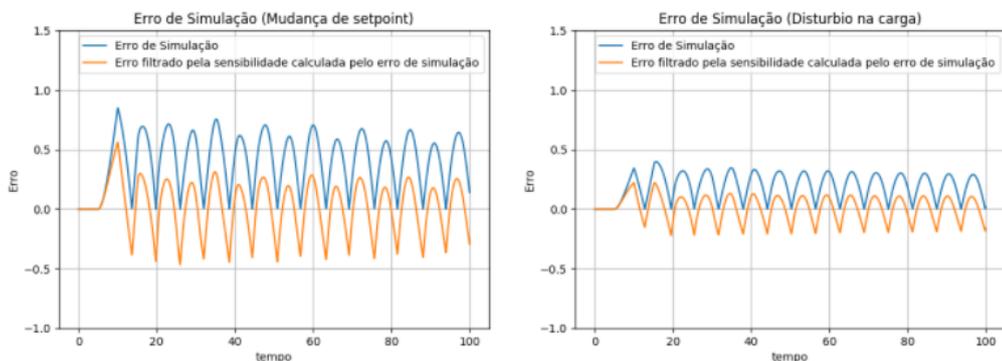
Aqui na Figura 4.2 é importante de se ressaltar que existe apenas uma curva, pois a ação de controle foi calculada apenas para a planta dita “real”, que foi enunciada na equação 4.1, ou seja, essa mesma ação de controle é usada depois para a planta ideal, a fim de se ter uma métrica de comparação entre as duas plantas com a mesma ação de controle. Por fim, é notável que o controlador tem que agir continuamente a fim de tentar estabilizar o processo.



**Figura 4.3:** Autocorrelação da ação de controle VS autocorrelação de saída da planta C

Na Figura 4.3 os dois gráficos mostrados anteriormente de certa forma são unificados, podendo tirar conclusões de que o controlador não tem robustez, pois oscila no eixo X e o desempenho dele também foi ruim, devido a oscilação no eixo Y. É possível observar também que para a planta ideal, a amplitude de oscilação é menor do que para a planta real, mostrando o péssimo desempenho dele na planta C.

Na Figura 4.4 e 4.5 são apresentados os erros de simulação e os de autocorrelações, e esses mesmos erros filtrados pela função de sensibilidade, onde a discrepância entre o modelo em malha aberta é compensado, reduzindo a intensidade do sinal de entrada.



**Figura 4.4:** Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta C

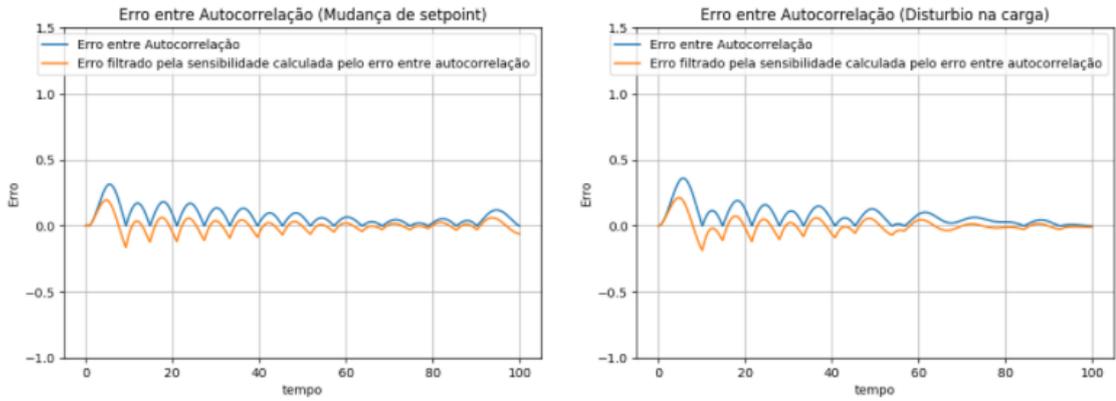


Figura 4.5: Erro entre autocorrelação frente a uma mudança de setpoint e um distúrbio na carga da planta

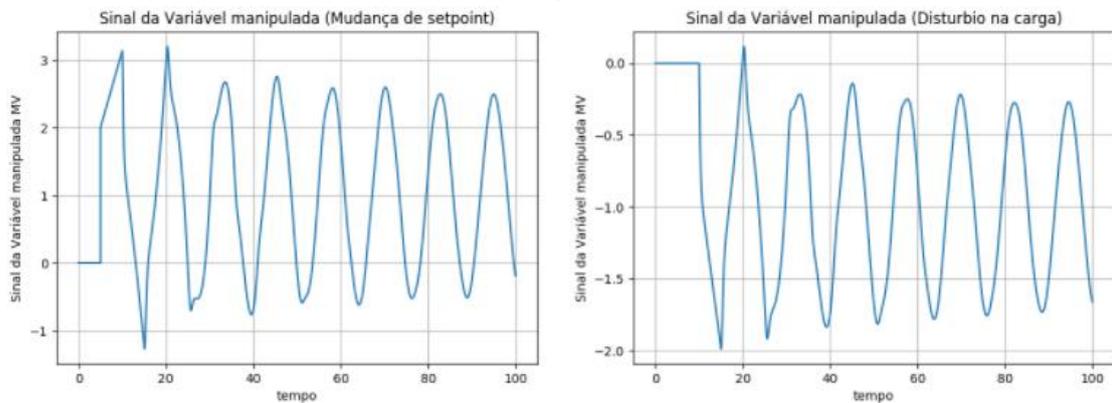


Figura 4.6: Sinal da variável manipulada frente a uma mudança de setpoint e a um distúrbio na carga da planta C

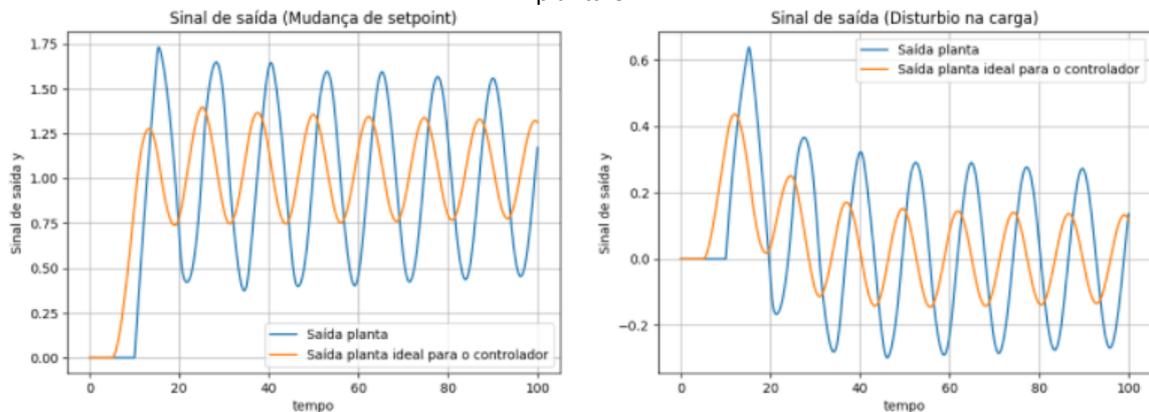


Figura 4.7: Sinal de saída frente a uma mudança de setpoint e a um distúrbio na carga da planta C

A Figura 4.6 e 4.7 estão presentes apenas para fim de confirmar o que foi explicado anteriormente, uma vez que elas não são geradas em um cenário rotineiro de indústria.

As plantas D,E e F eram de terceira ordem, logo, apenas uma delas foi escolhida para permanecer no corpo principal do trabalho, e neste caso foi a planta E. A equação 4.2 apresenta a dinâmica da planta em estudo

$$G_E(s) = \frac{1}{15s^3 + 23s^2 + 9s + 1} \tag{4.2}$$

Novamente, como foi feito com a planta C, serão apresentados todos os gráficos obtidos no estudo e discussões a respeito dos resultados encontrados.

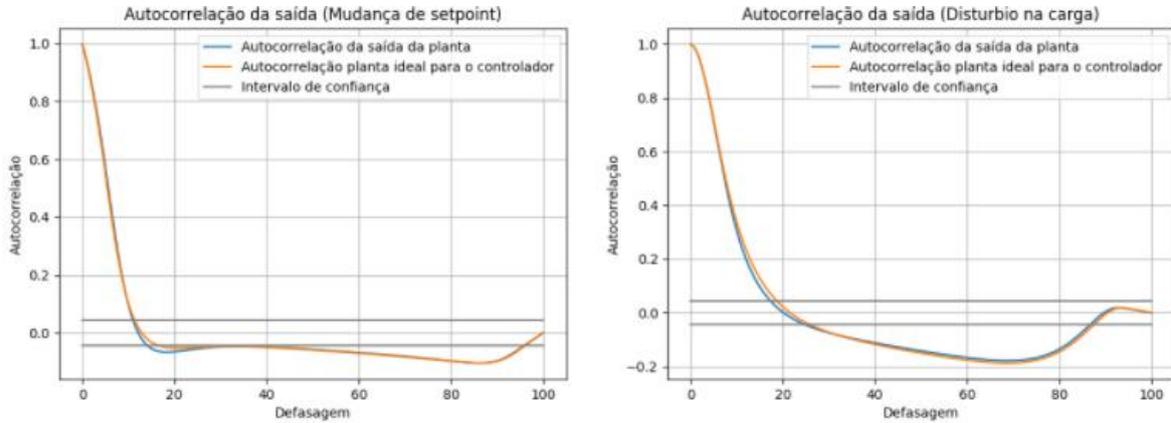


Figura 4.8: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta E

Diferente do ocorrido na planta C, aqui a autocorrelação de saída tanto para a mudança de *setpoint* quanto para um distúrbio na carga não apresentam oscilação, caindo rapidamente para dentro do intervalo de confiança, mostrando um bom desempenho.

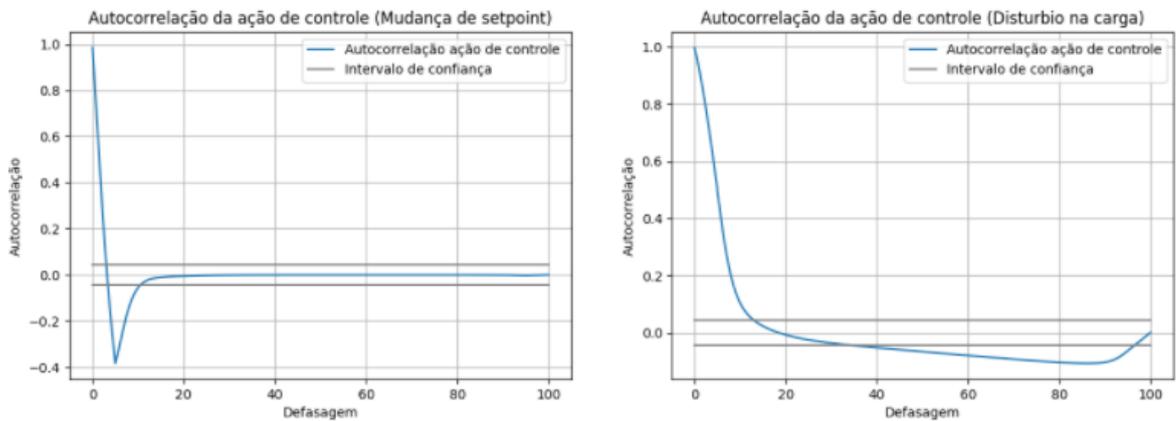


Figura 4.9: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta E

Aqui é perceptível a existência de um controlador robusto, principalmente frente a uma mudança de *setpoint*, onde num curto tempo, ele já atuou o suficiente para levar a planta para a estabilidade.

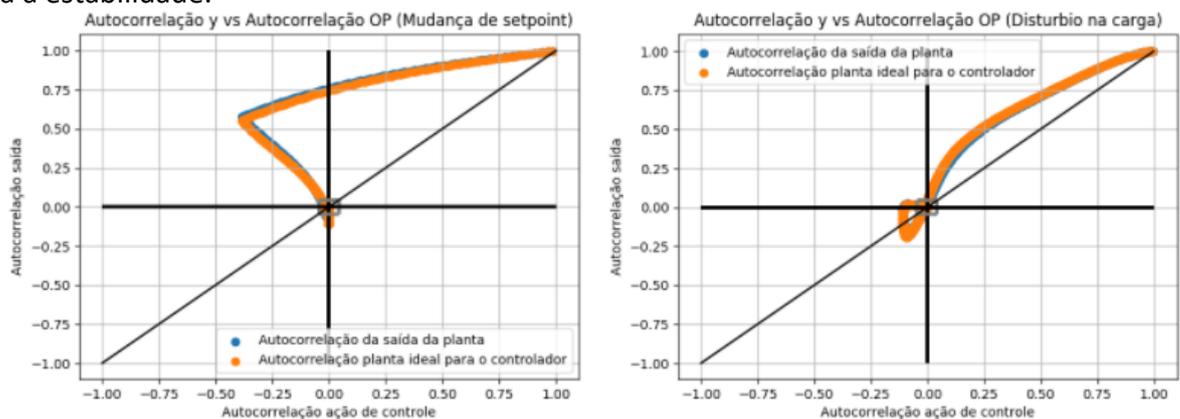
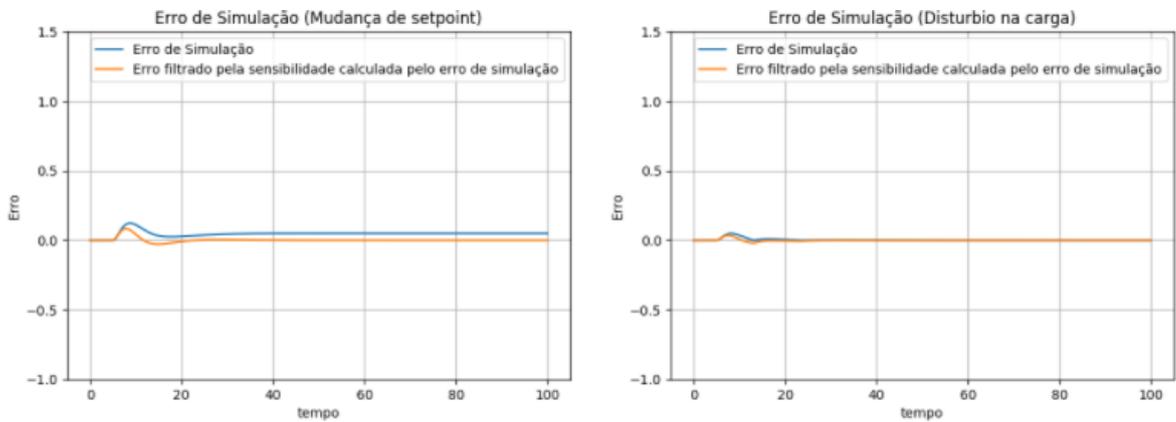
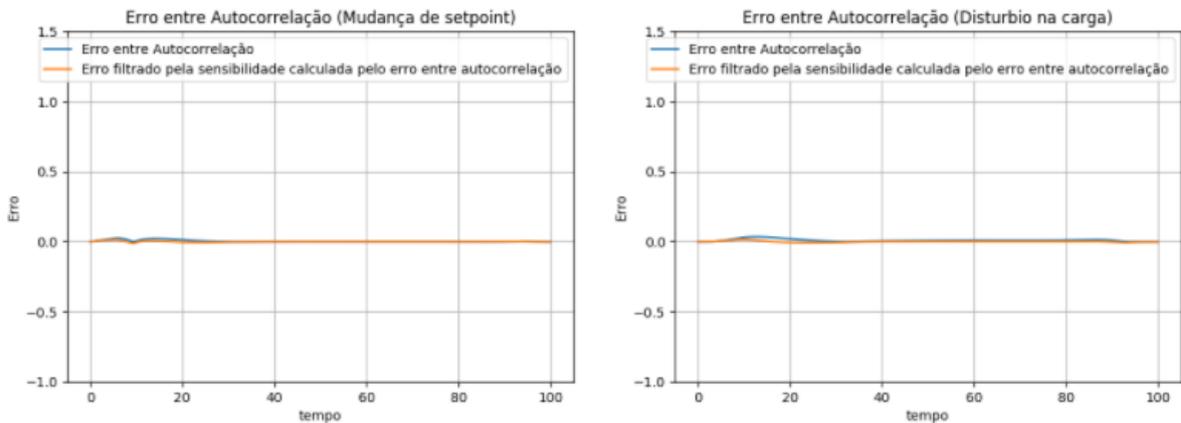


Figura 4.10: Autocorrelação da ação de controle VS autocorrelação de saída da planta E

Na Figura 4.10 fica claro a robustez e desempenho do controlador para a planta E, pois ele não oscila em nenhum eixo, indo para o centro do gráfico de forma quase que direta. Lembrando que a origem do gráfico, nada mais é do que os intervalos de confiança dos dois gráficos de autocorrelação mostrados anteriormente.

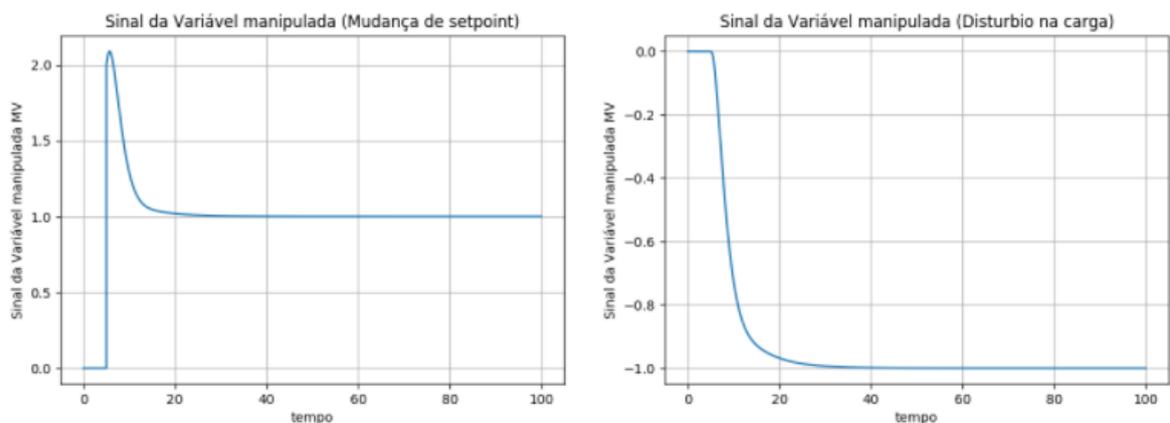


**Figura 4.11:** Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta E



**Figura 4.12:** Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta E

Percebe-se que o erro filtrado pela sensibilidade é praticamente zero durante todo o intervalo de amostragem, comprovando a robustez do controlador para essa planta de estudo.



**Figura 4.13:** Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta E

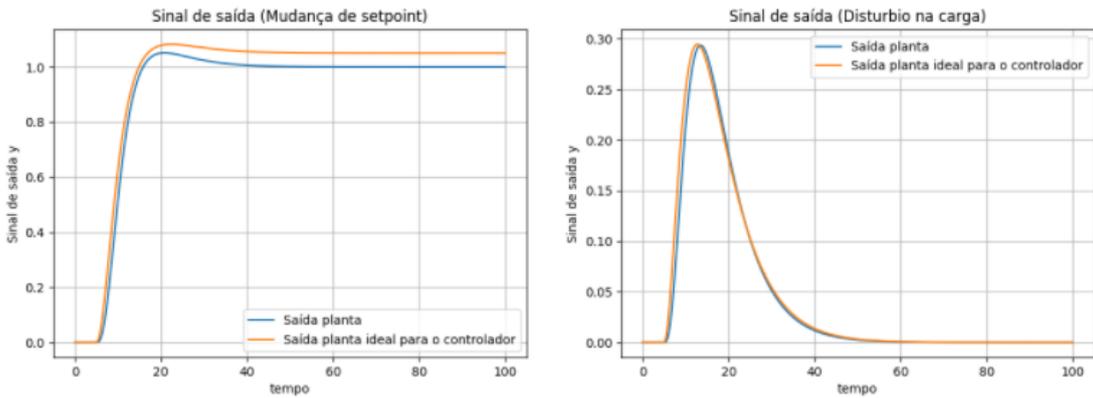


Figura 4.14: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta E

A Figura 4.14 apenas confirma o bom ajuste do controlador para essa planta, uma vez que ambas possuem comportamento basicamente igual. O pequeno *offset* existente entre elas é devido a ação de controle, que foi programada para levar a planta real ao *setpoint* e não a planta ideal.

Em estudo agora está a planta G, e essa provavelmente seja a que requer mais atenção para os resultados obtidos, uma vez que ela é instável em malha aberta. Sua dinâmica é apresentada na equação 4.3.

$$G_G(s) = \frac{10}{25s^2 + 24s - 1} \tag{4.3}$$

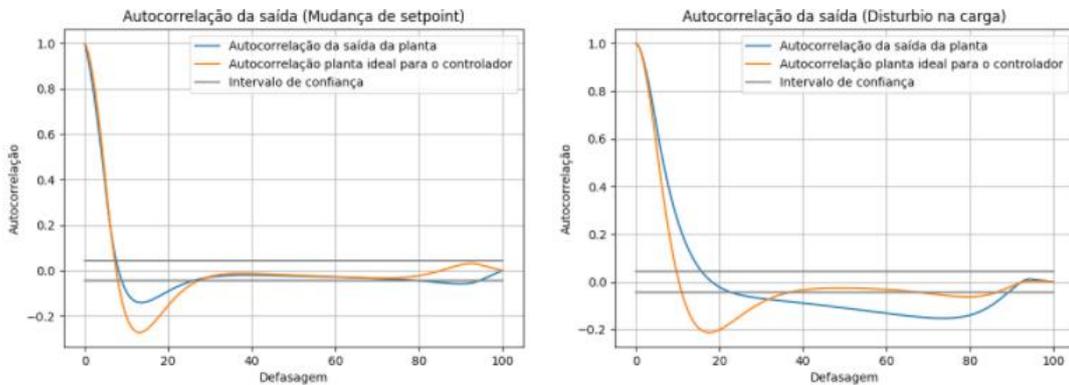


Figura 4.15: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta G

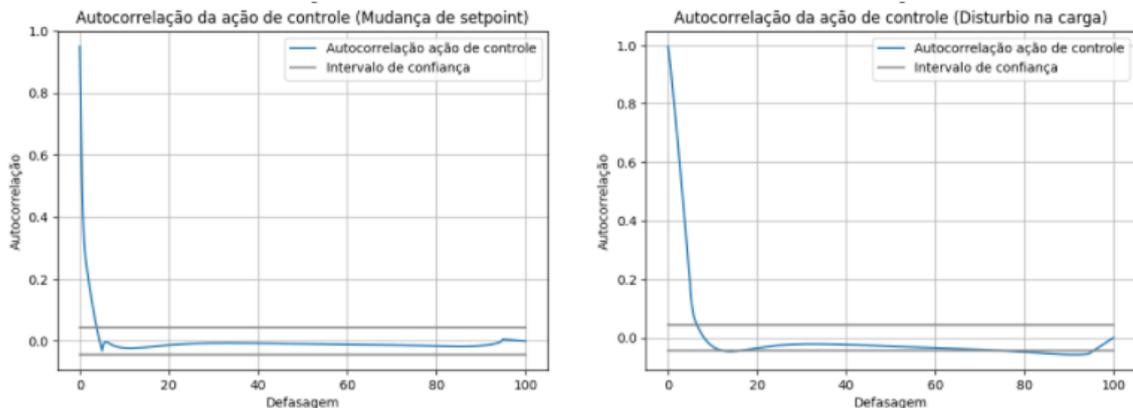
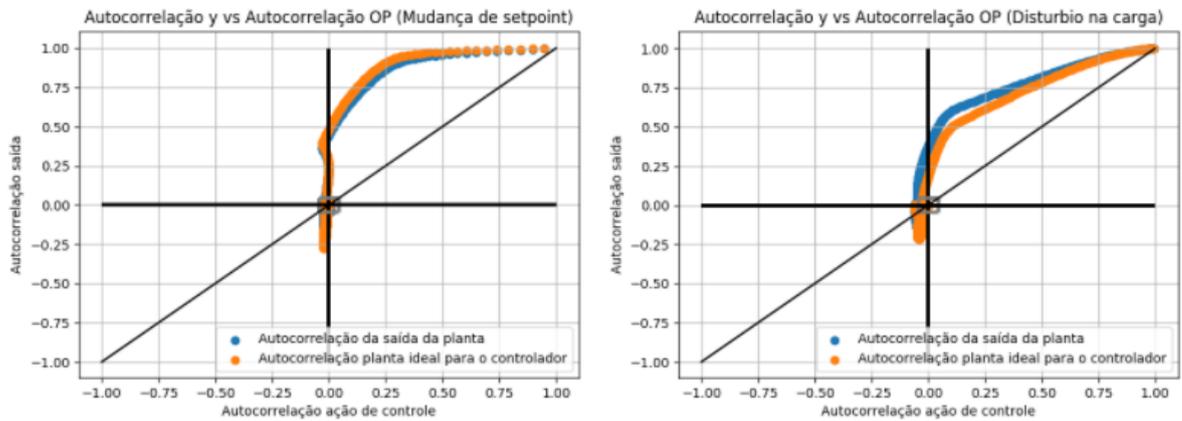


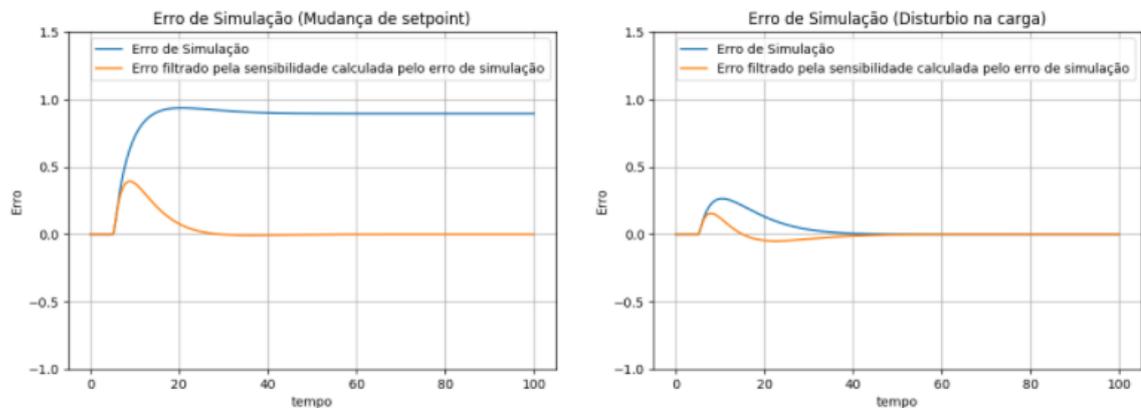
Figura 4.16: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta G



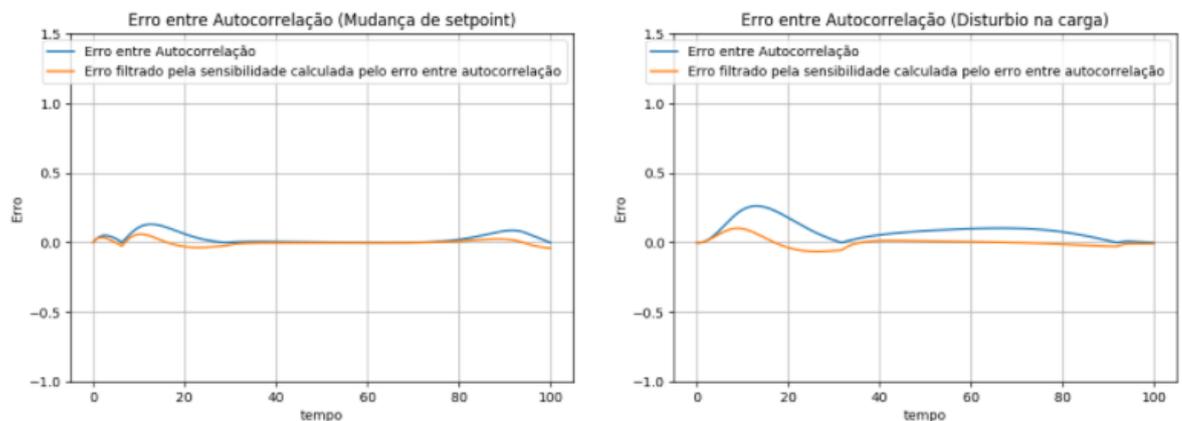
**Figura 4.17:** Autocorrelação da ação de controle VS autocorrelação de saída da planta G

As Figuras 4.15, 4.16 e 4.17 mostram um controlador robusto e com bom desempenho, afinal, as autocorrelações não apresentam comportamento oscilatório e praticamente nenhuma lentidão, ambas migram rapidamente para dentro do intervalo de confiança.

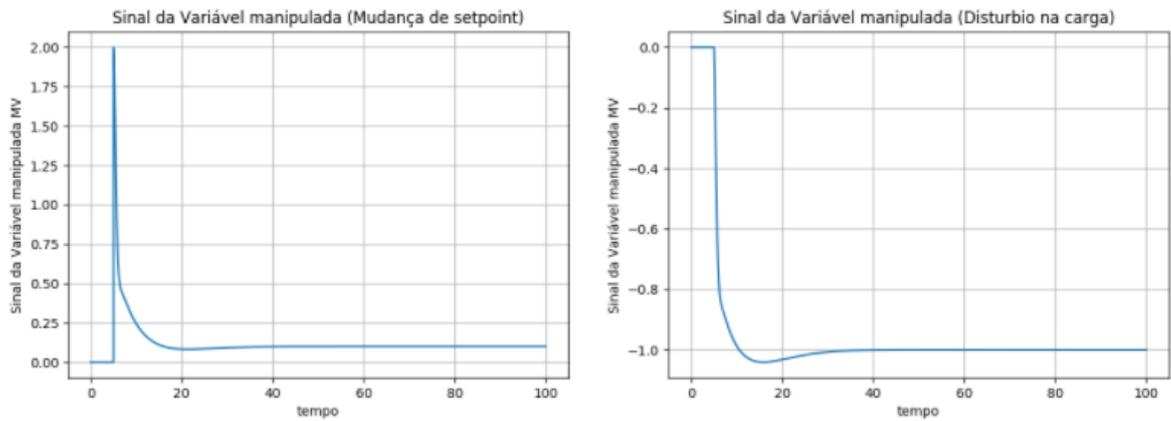
Agora, nas Figuras 4.18 e 4.19 têm-se um exemplo claro, de uma das principais vantagens da função de autocorrelação, pois a planta G tem um ganho aproximadamente 10 vezes maior do que a planta ideal, logo, com outros métodos convencionais não seria possível a comparação entre elas. Porém, como a função de autocorrelação, correlaciona os valores de saída do processo, ela ignora essa diferença, permitindo a comparação entre essas duas plantas de comportamento distinto.



**Figura 4.18:** Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta G

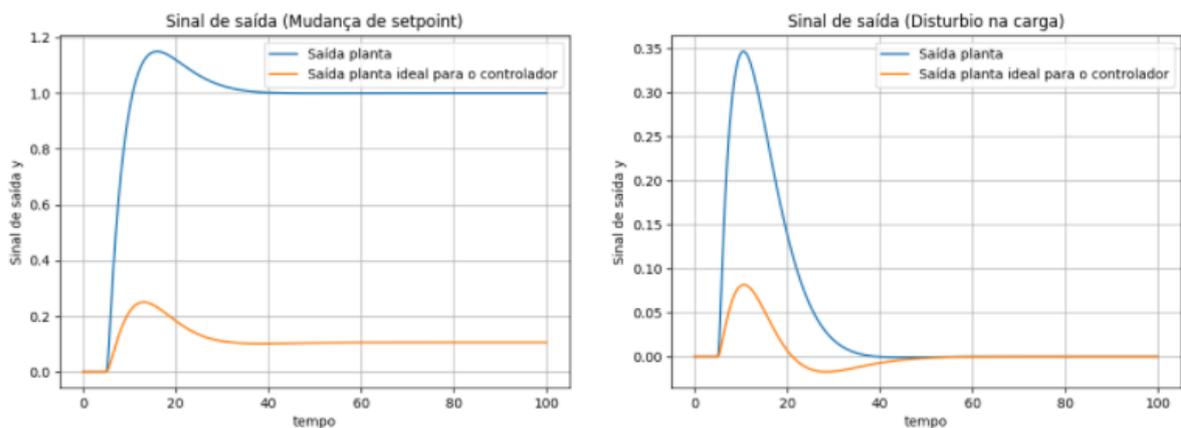


**Figura 4.19:** Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta



**Figura 4.20:** Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta G

A Figura 4.20 confirma a robustez do controlador, onde com um curto tempo de atuação o sistema estabilizou, tanto para a mudança de *setpoint* quanto para o distúrbio na carga.



**Figura 4.21:** Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta G

Aqui, na Figura 4.21 é apresentando essa diferença grande dos sinais de saída entre a planta ideal e planta G. Diferença essa, que a função de autocorrelação ignora em seus cálculos.

A Tabela 4.1 permite ter uma boa noção de quando o controlador conseguiu ter uma boa atuação sobre a planta, pois quanto menor o valor da integral, melhor o ajuste. Integral essa que foi calculada pelo método dos trapézios, sendo considerado sempre o valor absoluto da integral. A planta C que foi exibida durante o trabalho tem os maiores erros em três dos quatro calculados, caracterizando um péssimo ajuste, como foi visto anteriormente. O erro simulado para a planta G foi maior, mas isso se deve ao seu ganho muito maior do que a planta ideal, quando se aplica a autocorrelação, a C se mostra ser a pior atuação do controlador. Por sua vez, a planta E teve o melhor comportamento com o controlador utilizado, e os menores valores de erro, apresentando dinâmica quase que igual a planta ideal.

**Tabela 4.1:** Tabela de integrais das plantas

Plantas	Mudança de <i>setpoint</i>		Distúrbio na carga	
	Erro Simulação Filtrado pela Sensibilidade	Erro Autocorrelação filtrado pela sensibilidade	Erro Simulação Filtrado pela Sensibilidade	Erro Autocorrelação filtrado pela sensibilidade
A	0,21	0,02	0,0001	0,04
B	0,21	0,03	0,0006	0,01
C	1,76	0,24	0,73	0,04
D	0,21	0,02	0,002	0,03
E	0,21	0,006	6,6e-6	0,008
F	0,20	0,07	0,004	0,09
G	3,75	0,17	1,13e-6	0,03
H	0,21	0,07	0,0002	0,03
I	0,21	0,04	0,0001	0,02
J	0,21	0,09	0,013	0,03

Na Tabela 4.2 são apresentados todos os  $I_{DECOR}$  calculados que também permitem ter uma noção do ajuste do controlador para as plantas. Na planta C, o valor encontrado para o distúrbio na carga mostra que a autocorrelação está aumentando, e que um comportamento bastante oscilatório existe no controlador.

O  $I_{DECOR}$  tem o defeito de analisar apenas o desempenho do controlador, já que ele analisa a inclinação da autocorrelação e não o comportamento total dos dados de saída. Um exemplo disso é a planta B, onde o  $I_{DECOR}$  foi 0,90, indicando um bom desempenho, porém a robustez da planta é baixa, como pode ser visto nos gráficos do apêndice A.

**Tabela 4.2:** Todos os  $I_{DECOR}$  calculados

Planta	Mudança de <i>setpoint</i>	Distúrbio na carga
A	1,05	0,88
B	0,90	0,64
C	0,08	-1,21
D	0,69	0,11
E	1,1	1,1
F	1,34	0,89
G	0,79	0,51
H	3,85	2,99
I	3,42	1,69
J	4,51	6,99

## 5 Conclusões e Trabalhos Futuros

A metodologia de avaliação de performance de malhas de controle utilizando a função de autocorrelação demonstrou ser eficiente, uma vez que levou a resultados conclusivos, tanto para situações positivas em que a planta se comportou bem com o controlador, tanto para situações em que o ajuste nitidamente não era bom.

O papel do engenheiro é fundamental na avaliação, pois mesmo que os resultados sejam claros, tem que haver interpretação para nos casos em que o comportamento não esteja ideal, saber identificar qual a causa e como proceder perante o problema.

No caso da planta G, onde ela era instável e com ganho significativamente diferente da planta ideal, o controlador conseguiu estabilizar ambas, e a função de autocorrelação permitiu que essa comparação entre elas fosse feita. Além dos gráficos gerados, o uso dos parâmetros do controlador permite ter uma melhor visão sobre o que está acontecendo no processo e entender a dinâmica na qual o sistema está se comportando.

Para trabalhos futuros, aconselha-se pensar em maneiras de utilizar esses gráficos para ressintonizar a malha de controle e também métodos que sejam capazes de entender se a oscilação é proveniente da planta ou de uma má sintonia do controlador. Também é aconselhado realizar este estudo com uma abordagem não determinística, em que os distúrbios de carga não sejam conhecidos, com dados de rotina de uma planta industrial.

Por fim, acredita-se que este trabalho demonstra a eficiência da função de autocorrelação para auditoria de malhas de controle e que abre um leque de ramificações, com essa mesma metodologia para que sejam aplicadas, produzindo resultados ainda melhores do que esse.

## 6 Referências Bibliográficas

- AIRIKKA, P. **Simple continuous-time identification method for PID controlled crushing plant processes**. IFAC Proceedings Volumes (IFAC-PapersOnline). **Anais...IFAC Secretariat**, 2012
- DE FRANCISCO, D. O.; TRIERWEILER, J. O.; FARENZENA, M. **A novel PID autotuning approach: How to correct bad tuning by closed-loop performance assessment**. IFAC-PapersOnLine. **Anais...Elsevier B.V.**, 2019
- DESBOROUGH, L.; HARRIS, T. Performance Assessment Measures for Univariate Feedback Control Minimum variance control: A performance benchmark. **the Canadian Journal of Chemical Engineering**, v. 70, p. 1189–1195, 1992.
- FARENZENA, M. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL Novel Methodologies for Assessment and Diagnostics in Control Loop Management Novel methodologies for assessment and diagnostics in Control Loop Management. 2008.
- FERREIRA, M. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL ESCOLA DE ENGENHARIA DEPARTAMENTO DE ENGENHARIA QUÍMICA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA **A Função de Autocorrelação Aplicada à Auditoria de Desempenho de Controladores**. [s.l.: s.n.].
- GAO, X.; YANG, F.; SHANG, C.; et al. A Novel Data-Driven Method for Simultaneous Performance Assessment and Retuning of PID Controllers. **Industrial and Engineering Chemistry Research**, v. 56, n. 8, p. 2127–2139, 1 mar. 2017a.
- GAO, X.; SHANG, C.; HUANG, D.; et al. A novel approach to monitoring and maintenance of industrial PID controllers. **Control Engineering Practice**, v. 64, p. 111–126, 1 jul. 2017b.
- GHOUSIYA BEGUM, K.; SESHAGIRI RAO, A.; RADHAKRISHNAN, T. K. Assessment of Proportional Integral Derivative Control Loops for Large Dominant Time Constant Processes. **Chemical Product and Process Modeling**, v. 15, n. 1, 1 mar. 2020.
- HOWARD, R.; COOPER, D. J. Performance assessment of non-self-regulating controllers in a cogeneration power plant. **Applied Energy**, v. 86, n. 10, p. 2121–2129, 2009.
- HUANG, H. P.; JENG, J. C. Monitoring and assessment of control performance for single loop systems. **Industrial and Engineering Chemistry Research**, v. 41, n. 5, p. 1297–1309, 6 mar. 2002.
- JELALI, M. An overview of control performance assessment technology and industrial applications. **Control Engineering Practice**, v. 14, n. 5, p. 441–466, 2006.
- KEMPF, A. DE O. **Avaliação de Desempenho de Malhas de Controle**. [s.l.] Universidade Federal do Rio Grande do Sul, 2003.
- LIU, H.; YOO, C. K. Performance assessment of cascade controllers for nitrate control in a wastewater treatment process. **Korean Journal of Chemical Engineering**, v. 28, n. 3, p. 667–673, 2011.
- PAULINO, A.; DE ARAÚJO, V. UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE CENTRO DE TECNOLOGIA DEPARTAMENTO DE ENGENHARIA DE COMPUTAÇÃO E AUTOMAÇÃO CURSO DE ENGENHARIA MECATRÔNICA **Sintonia de Controladores de um Sistema Não-Linear com Aplicações na Indústria Petroquímica**. [s.l.: s.n.].
- PEREIRA, R. D. O.; CORREIA, W. B.; NOGUEIRA, F. G.; et al. **Automatic Tuning**

**Method for PID Controllers Applied to Integrating and Unstable Processes; Automatic Tuning Method for PID Controllers Applied to Integrating and Unstable Processes.** [s.l: s.n.].

RENGASWAMY, R.; SRINIVASAN, B.; PRAVINBHAI BHATT, N. **Process Control Fundamentals; Analysis, Design, Assessment, and Diagnosis.** [s.l: s.n.].

SHAHNI, F.; YU, W.; YOUNG, B. Rapid estimation of PID minimum variance. **ISA transactions**, v. 86, p. 227–237, mar. 2019.

THORNHILL, N. F.; SADOWSKI, R.; DAVIS, J. R.; et al. Practical experiences in refinery control loop performance assessment. **IEE Conference Publication**, n. 427 /1, p. 175–180, 1996.

VERONESI, M.; VISIOLI, A. **Performance Assessment and Retuning of PID Controllers for Load Disturbance Rejection.** [s.l: s.n.].

YU, S.; LI, X. Proportional-Integral-Derivative Controller Performance Assessment and Retuning Based on General Process Response Data. **ACS Omega**, v. 6, n. 15, p. 10207–10223, 20 abr. 2021.

YU, Z.; WANG, J.; HUANG, B.; et al. Performance assessment of PID control loops subject to setpoint changes. **Journal of Process Control**, v. 21, n. 8, p. 1164–1171, set. 2011.

## Apêndice - A

Planta A:

$$G(s)_A = \frac{1}{5s + 1}$$

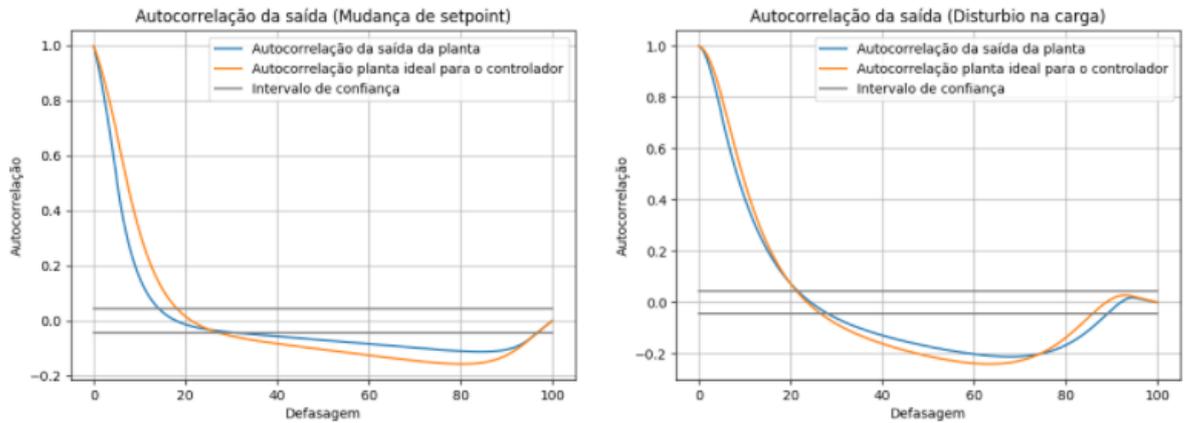


Figura A1: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta A

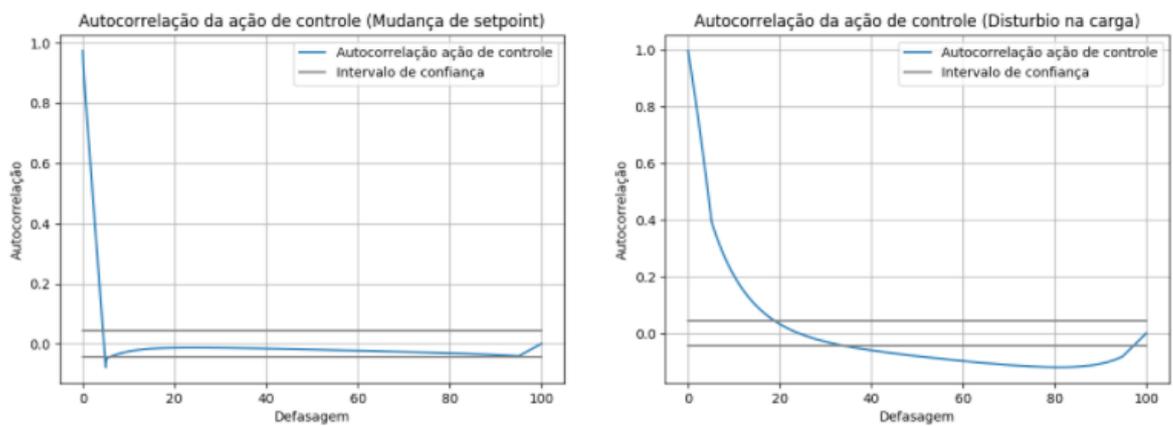


Figura A2: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta A

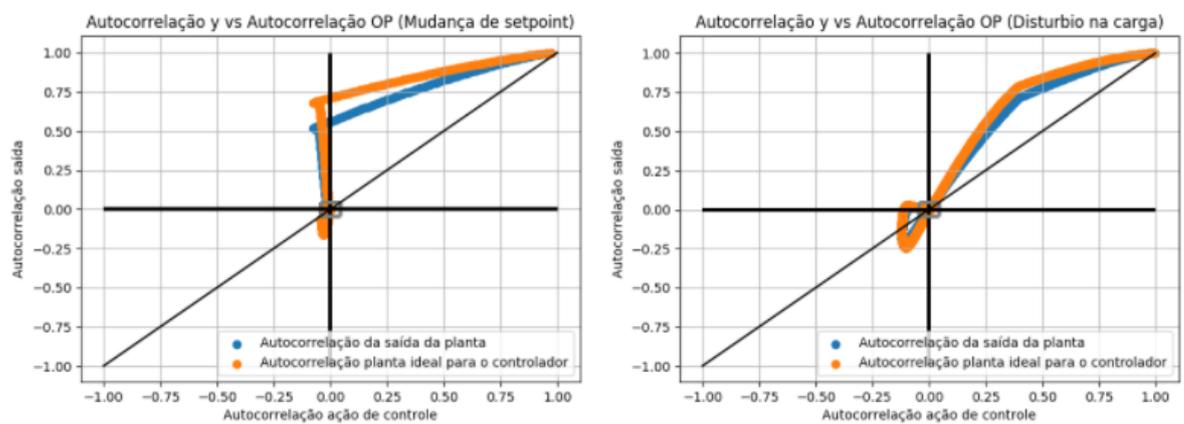


Figura A3: Autocorrelação da ação de controle VS autocorrelação de saída da planta A

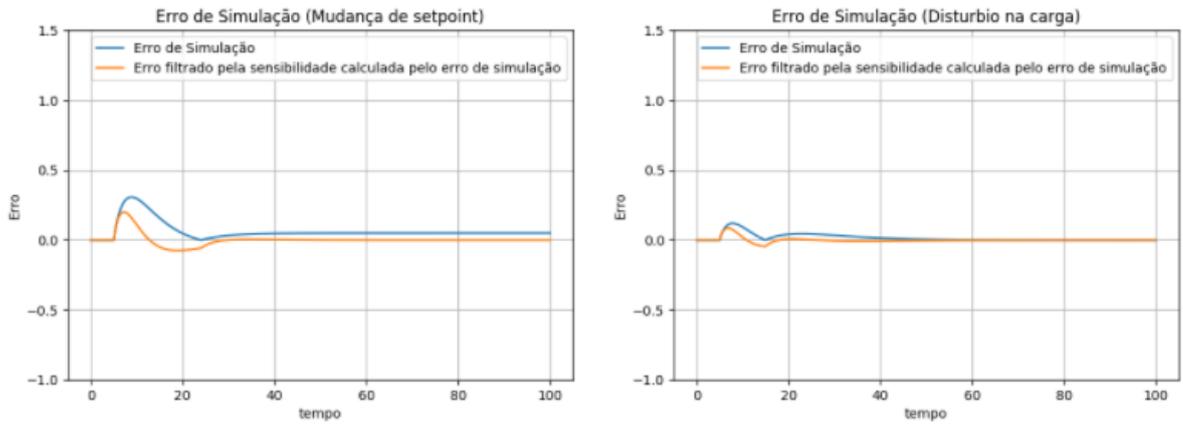


Figura A4: Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta A

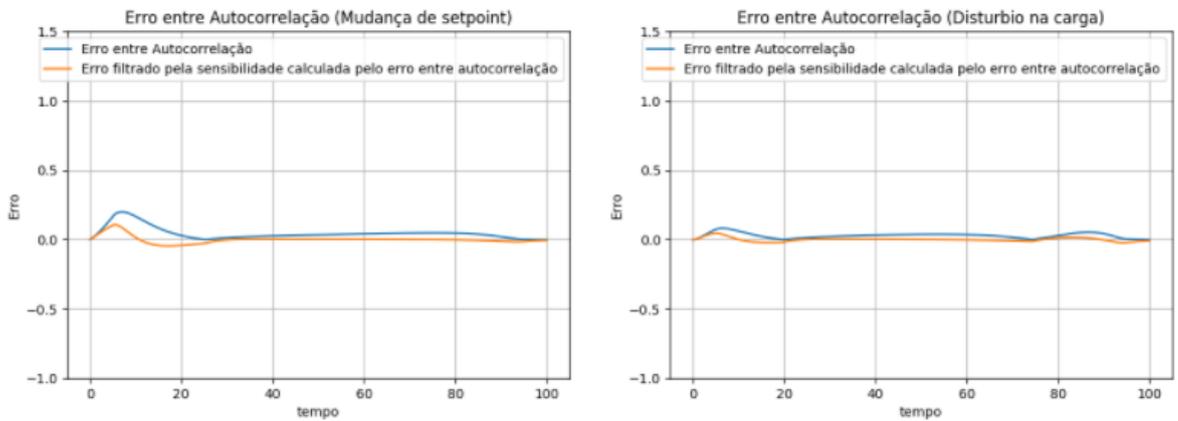


Figura A5: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta A

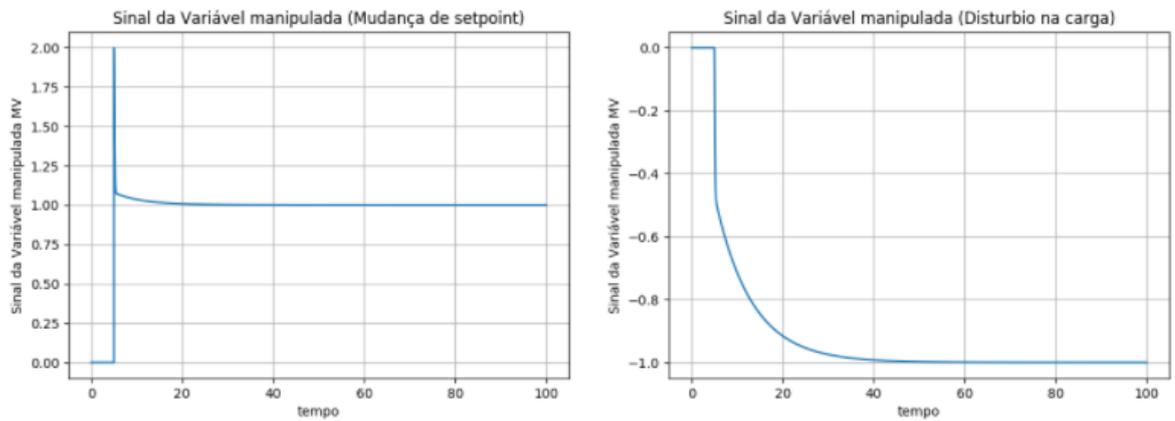


Figura A6: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta A

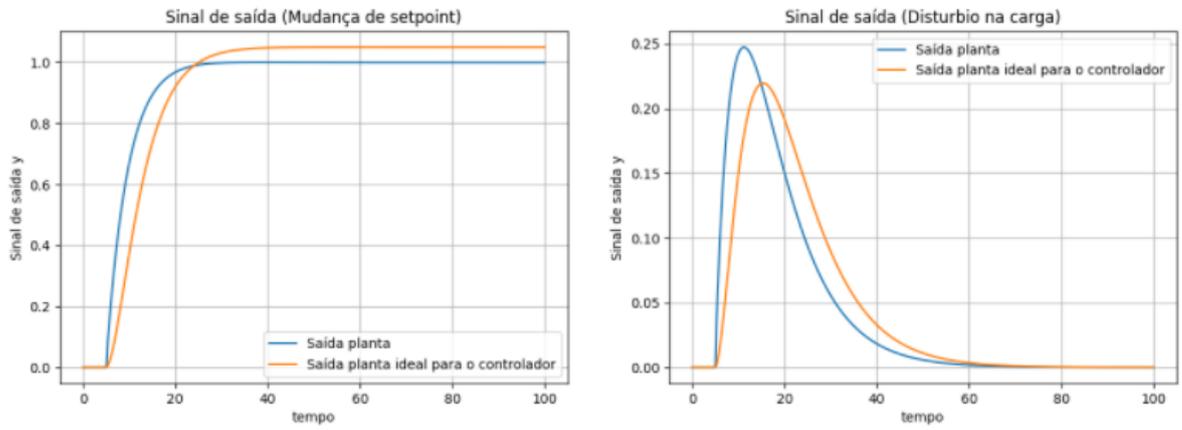


Figura A7: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta A

Planta B:

$$G(s)_B = \frac{1}{5s + 1} e^{-2s}$$

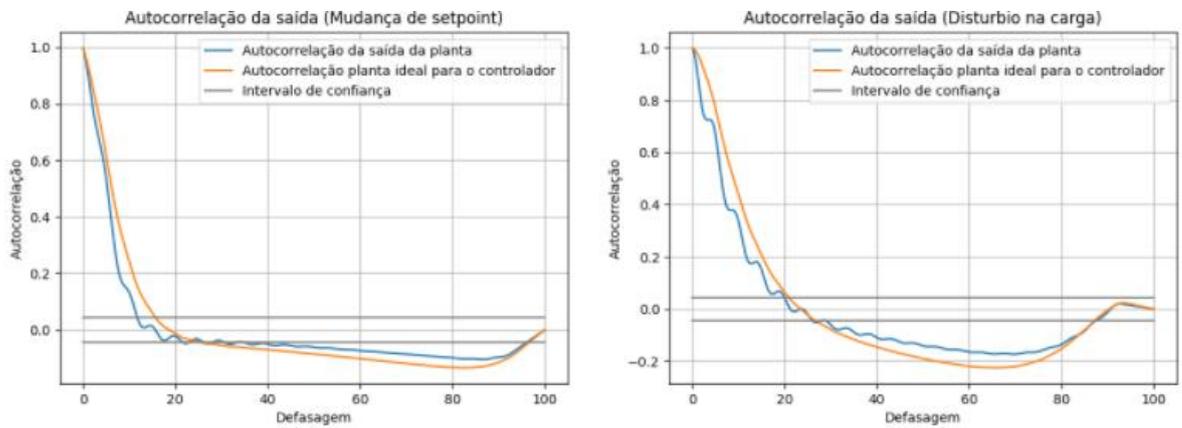


Figura A8: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta B

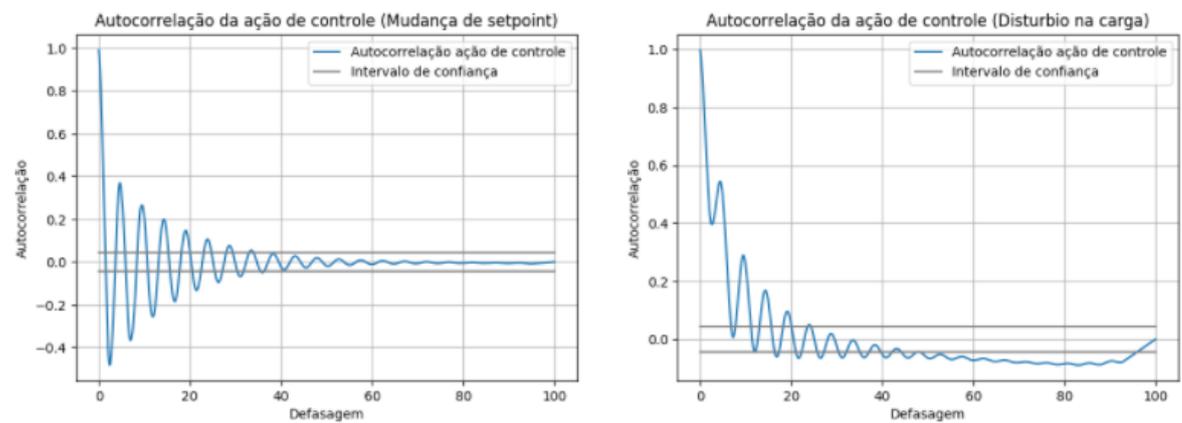


Figura A9: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta B

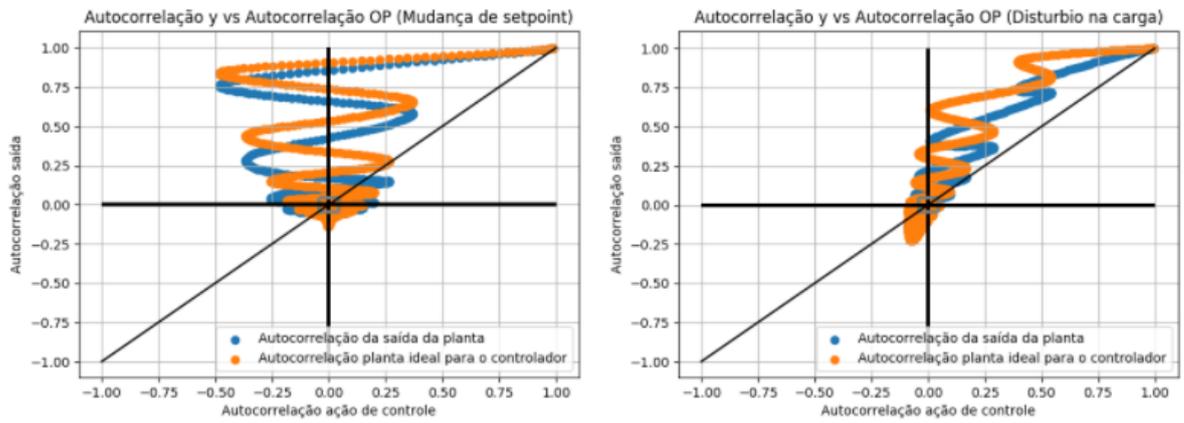


Figura A10: Autocorrelação da ação de controle VS autocorrelação de saída da planta B

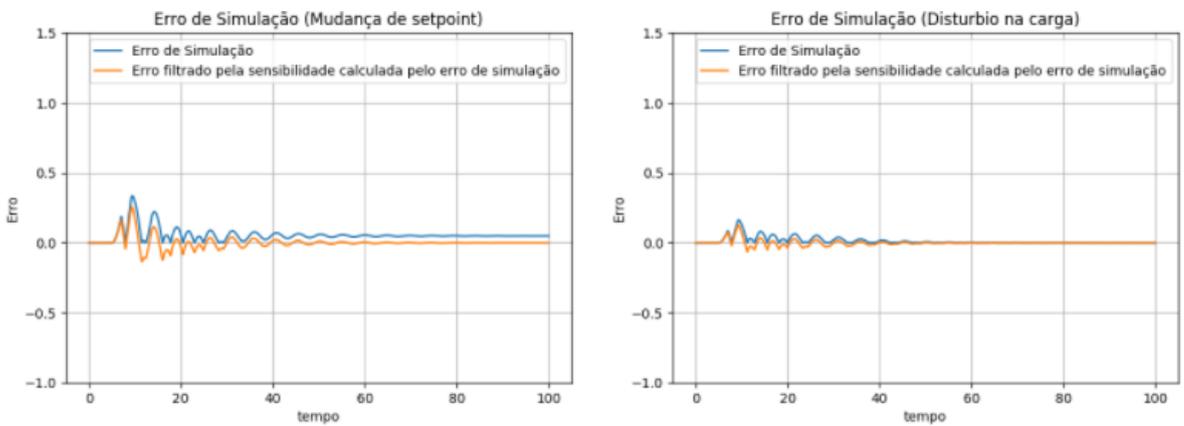


Figura A11: Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta B

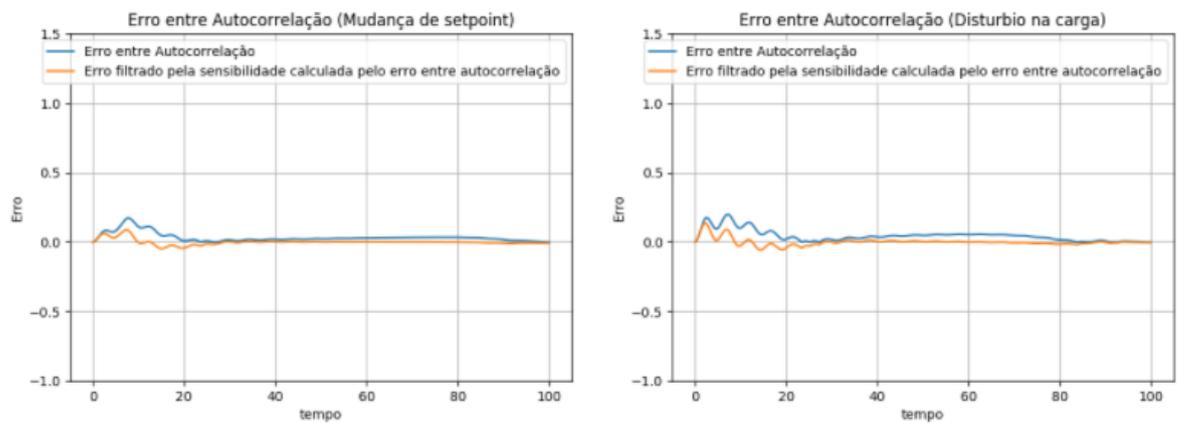


Figura A12: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta B

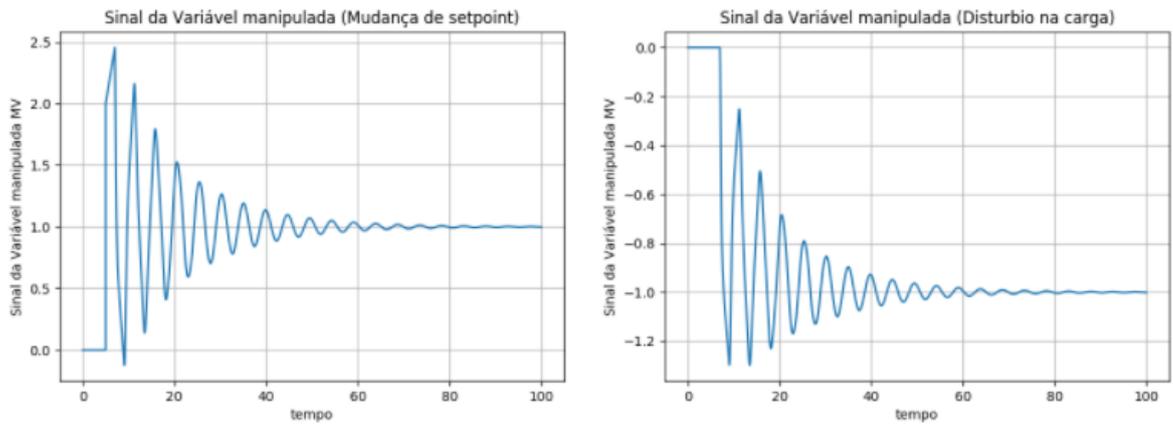


Figura A13: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta B

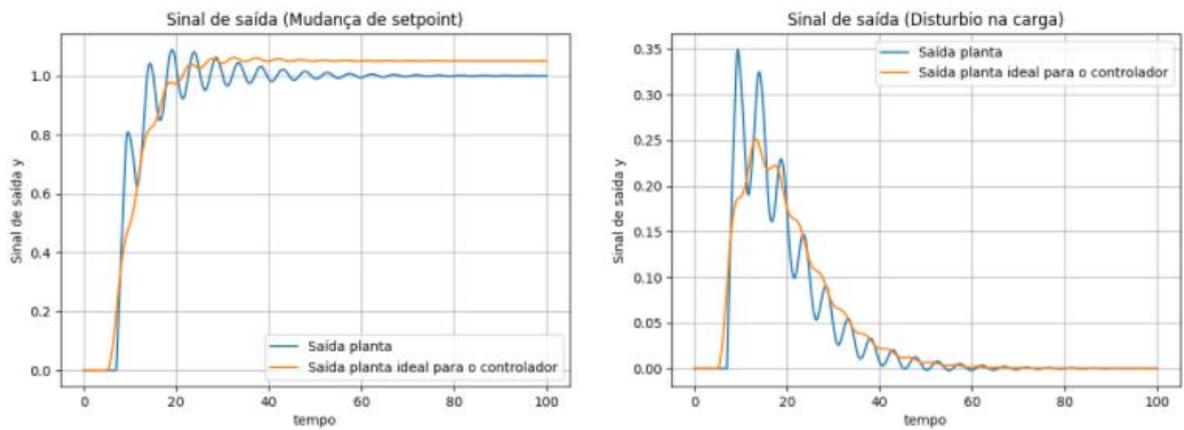


Figura A14: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta B

Planta D:

$$G(s)_D = \frac{-3s + 1}{15s^3 + 23s^2 + 9s + 1}$$

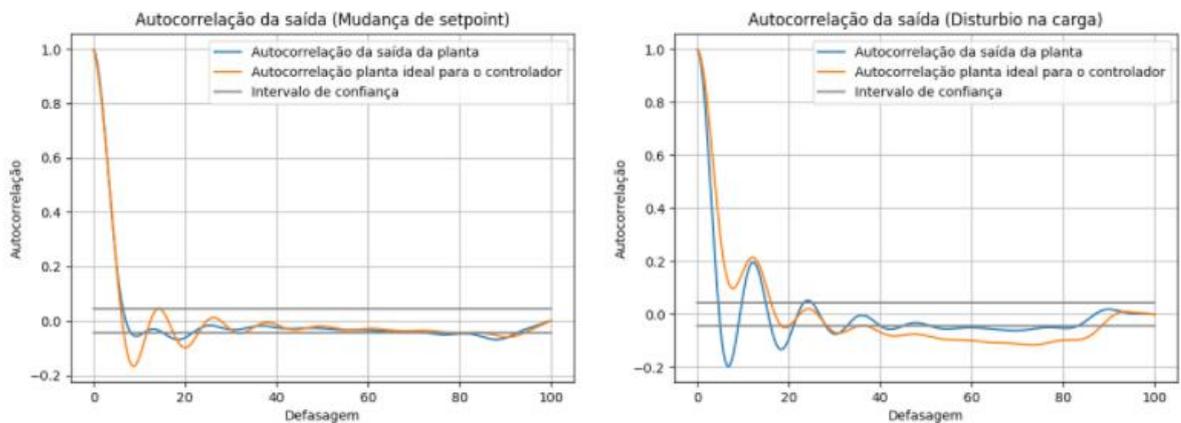


Figura A15: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta D

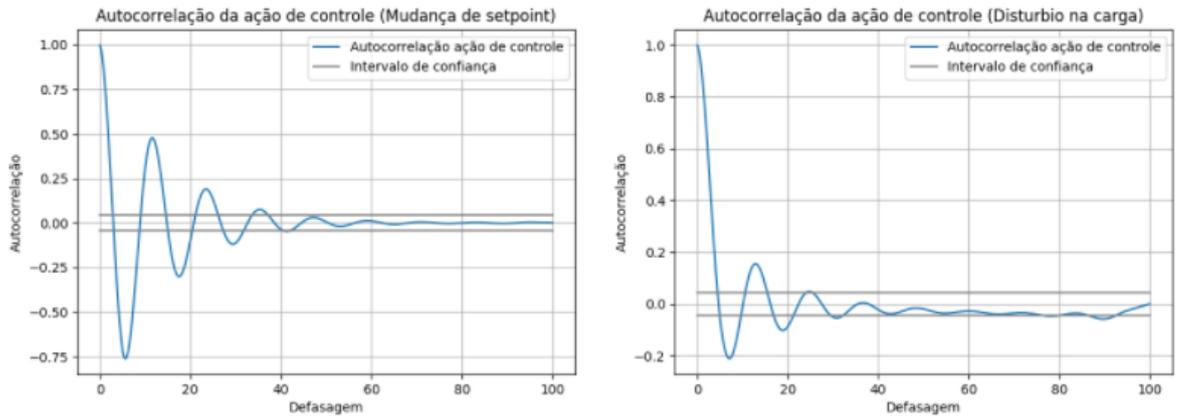


Figura A16: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta D

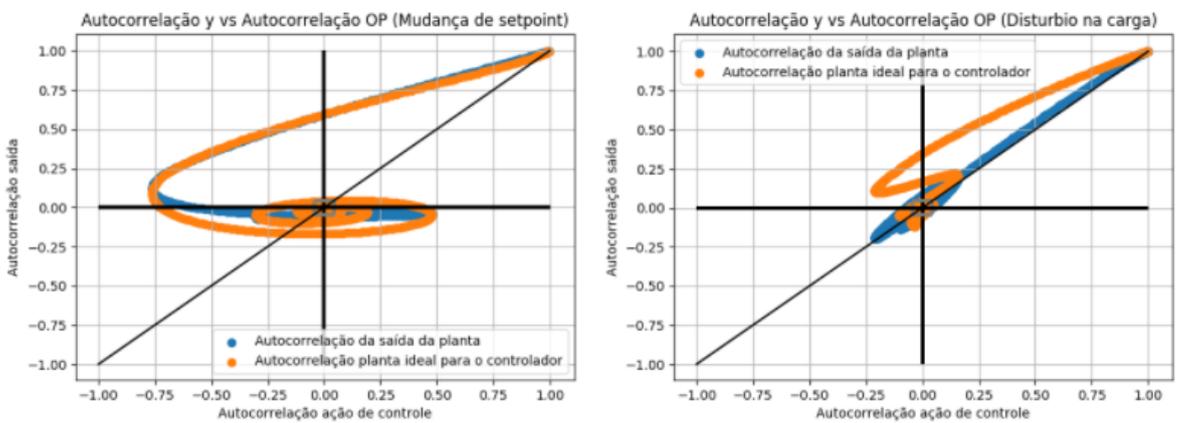


Figura A17: Autocorrelação da ação de controle VS autocorrelação de saída da planta D

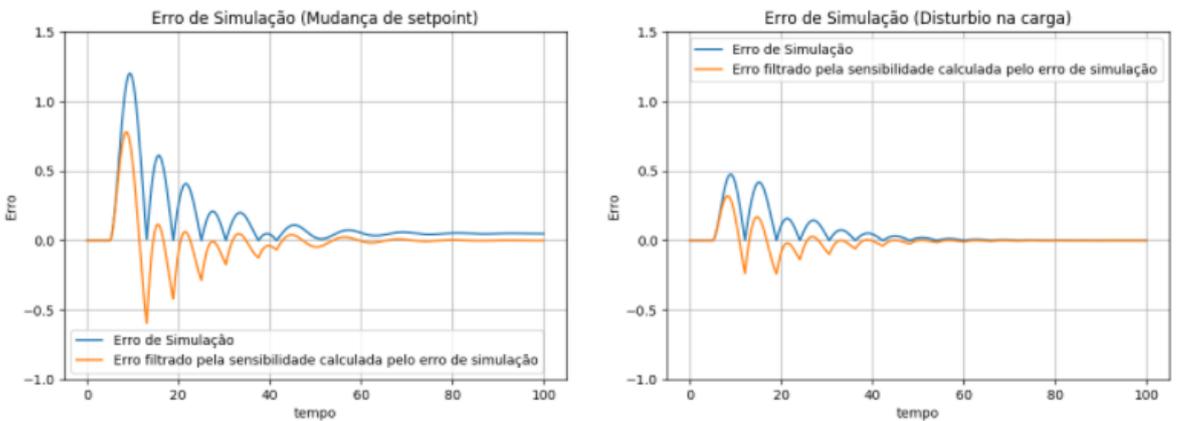


Figura A18: Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta D

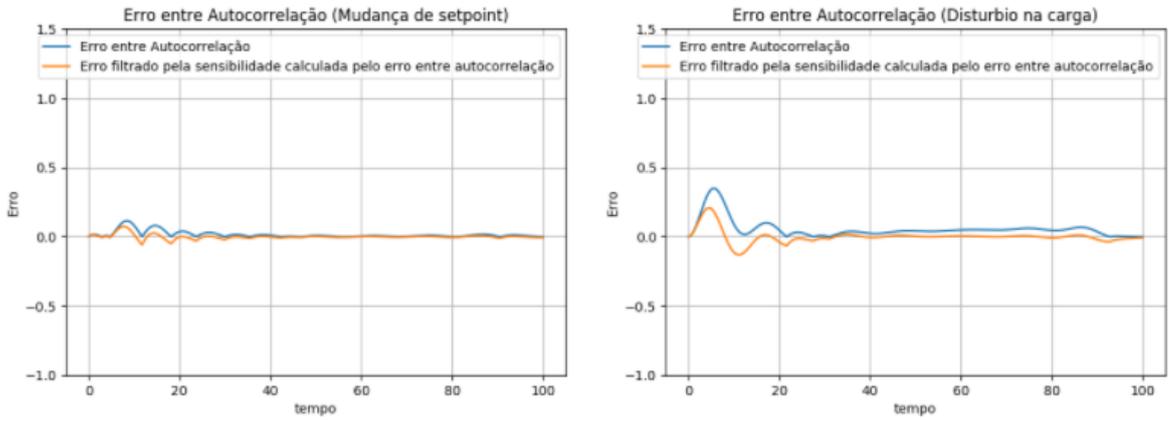


Figura A19: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta D

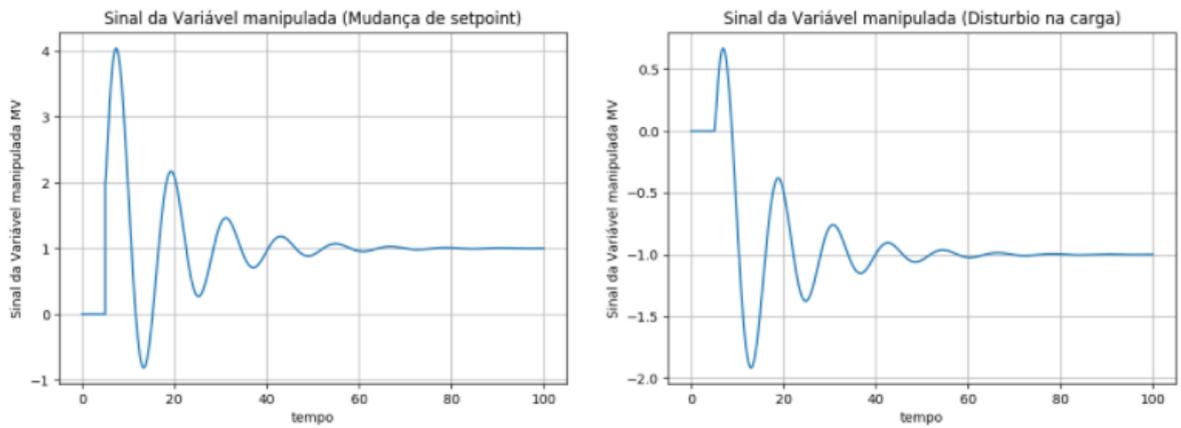


Figura A20: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta D

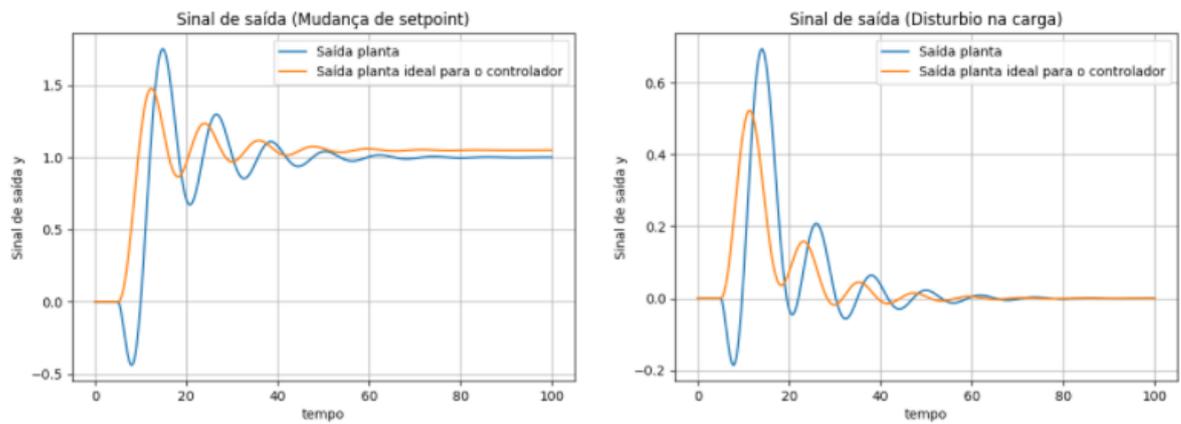


Figura A21: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta D

Planta F:

$$G(s)_F = \frac{10s + 1}{15s^3 + 23s^2 + 9s + 1}$$

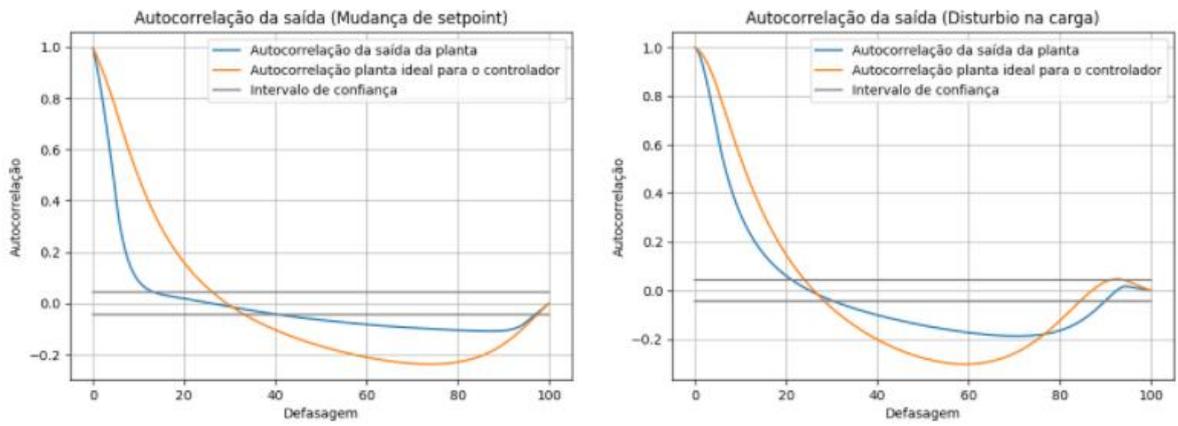


Figura A22: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta F

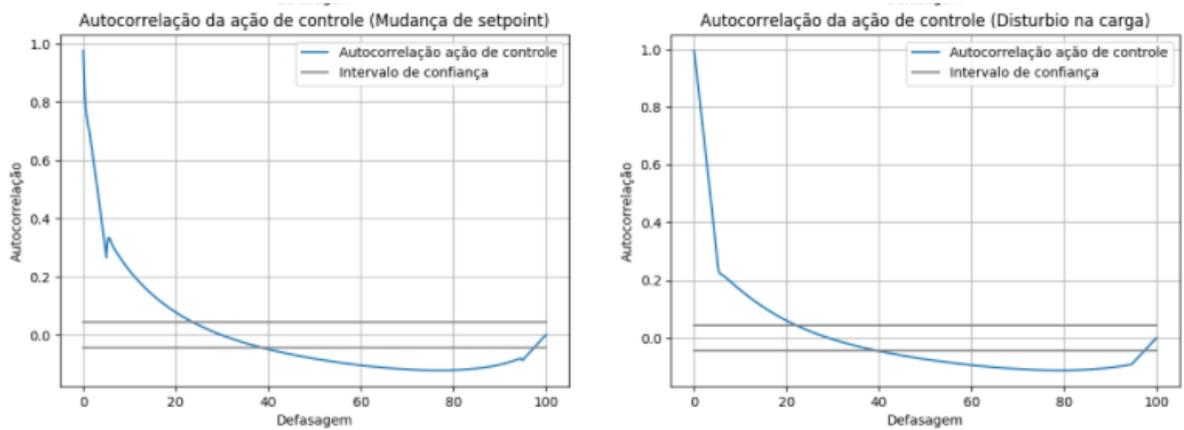


Figura A23: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta F

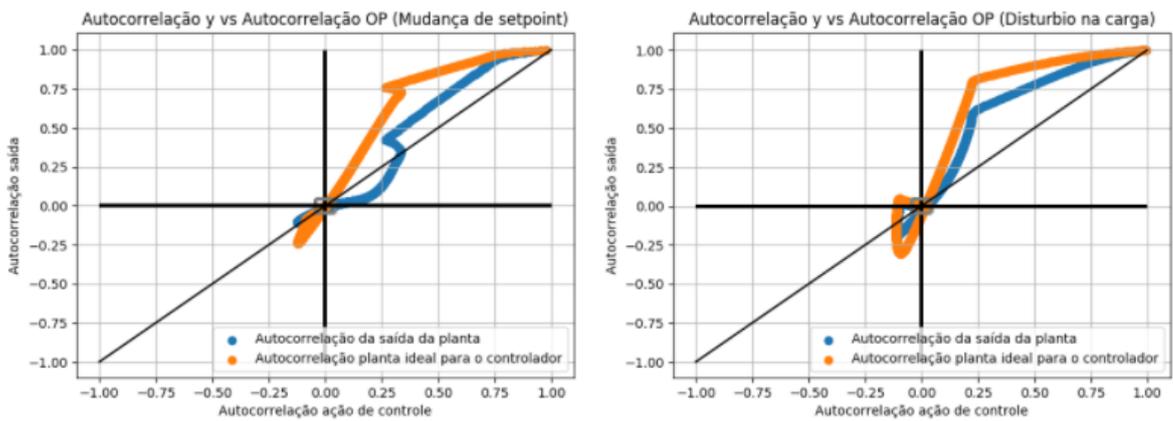


Figura A24: Autocorrelação da ação de controle VS autocorrelação de saída da planta F

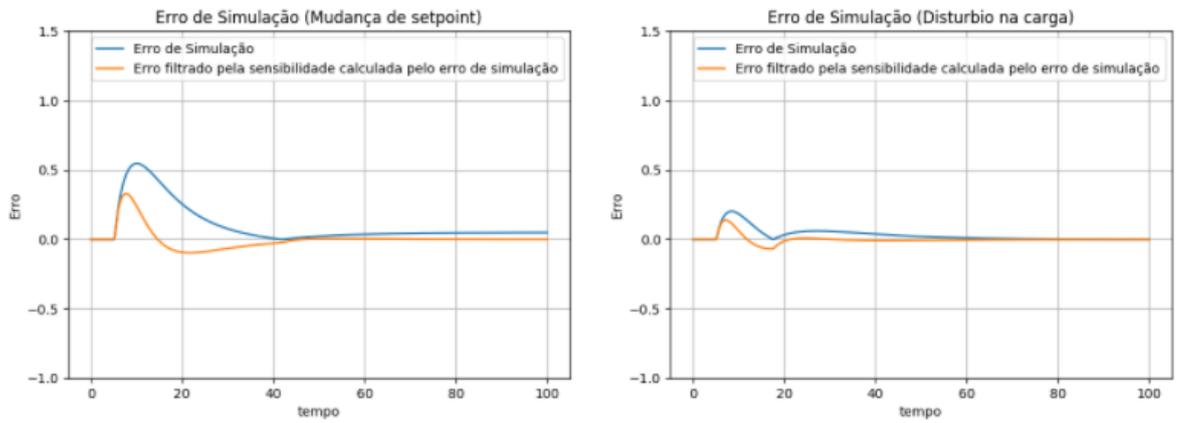


Figura A25: Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta F

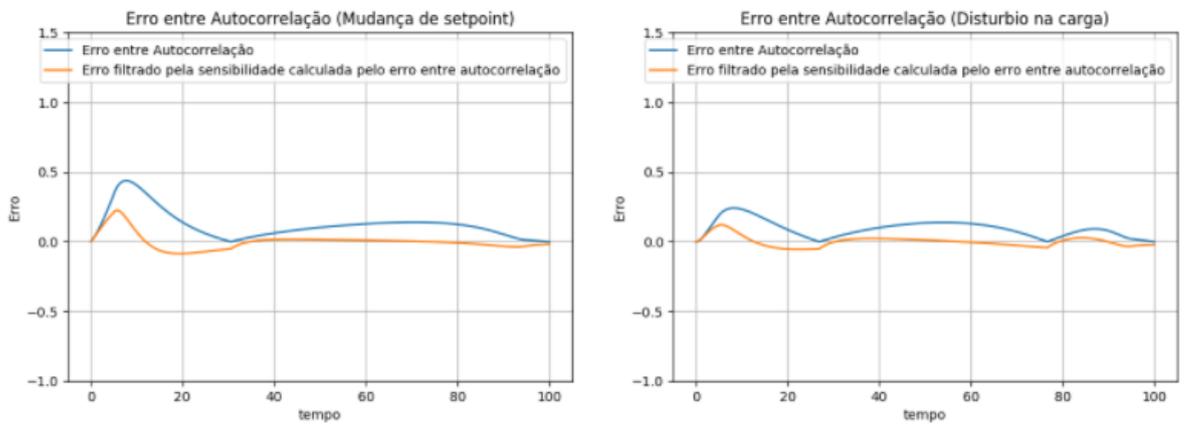


Figura A26: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta F

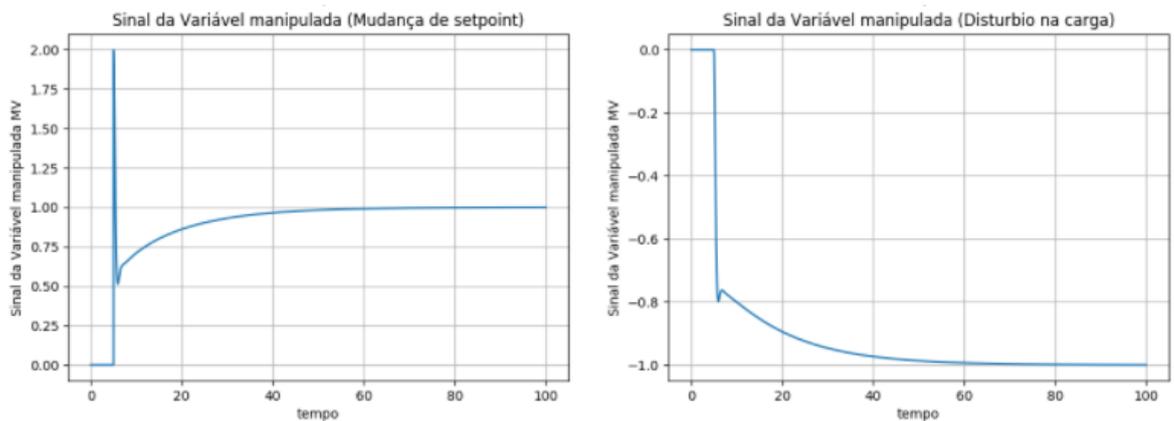


Figura A27: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta F

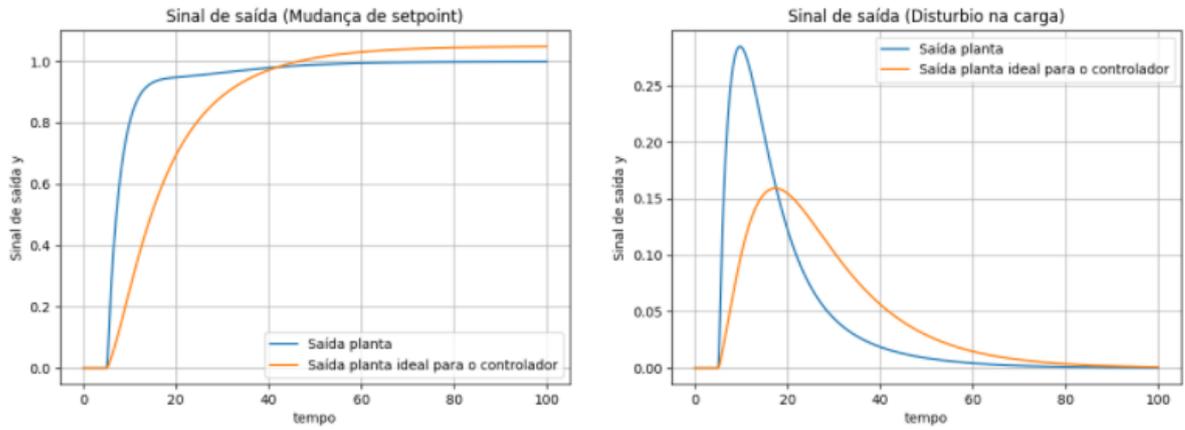


Figura A28: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta F

Planta H:

$$G(s)_H = \frac{1}{32s^3 + 27,2s^2 + 4,4s + 1}$$

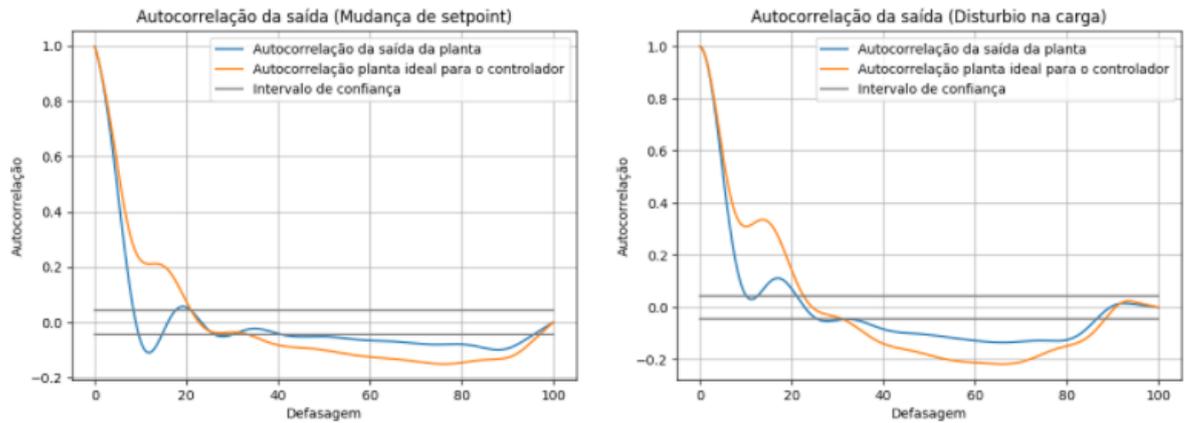


Figura A29: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta H

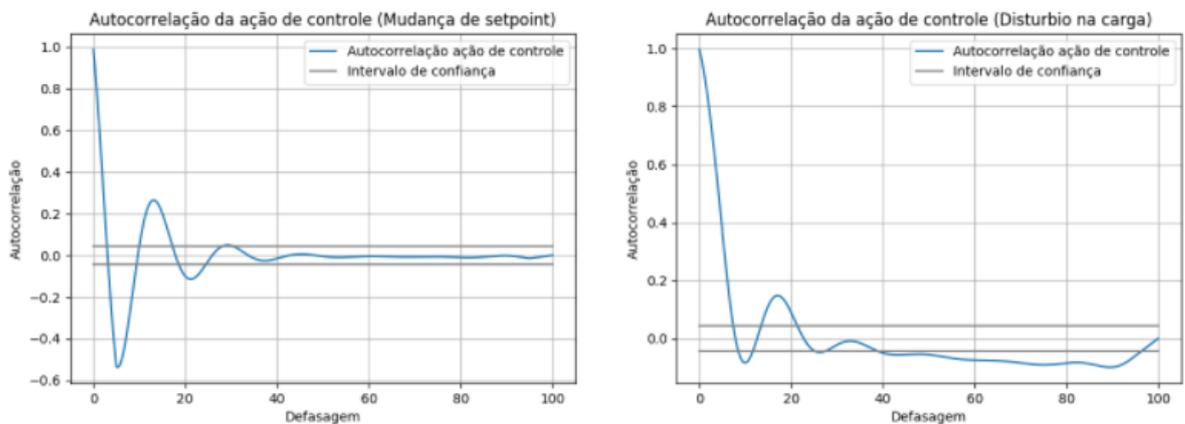


Figura A30: Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta H

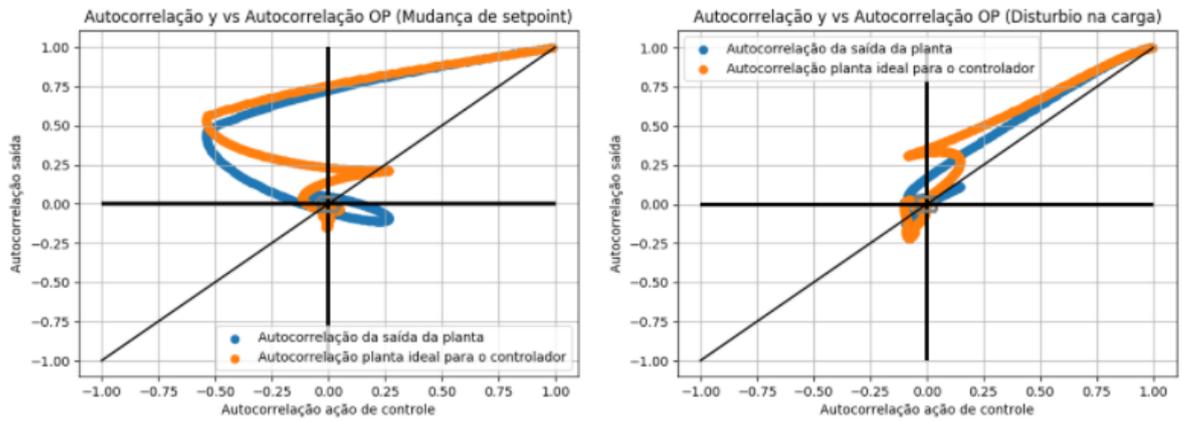


Figura A0.11: Autocorrelação da ação de controle VS autocorrelação de saída da planta H

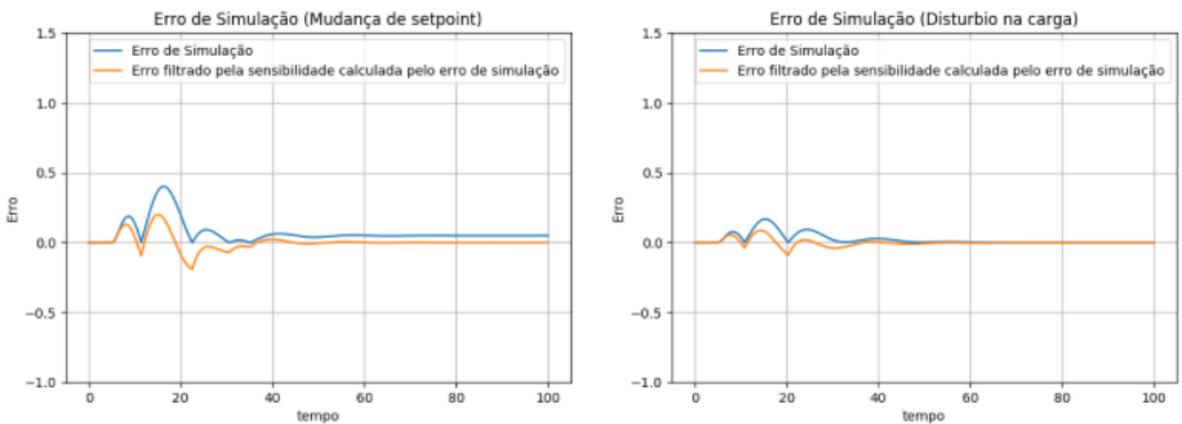


Figura A32: Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta H

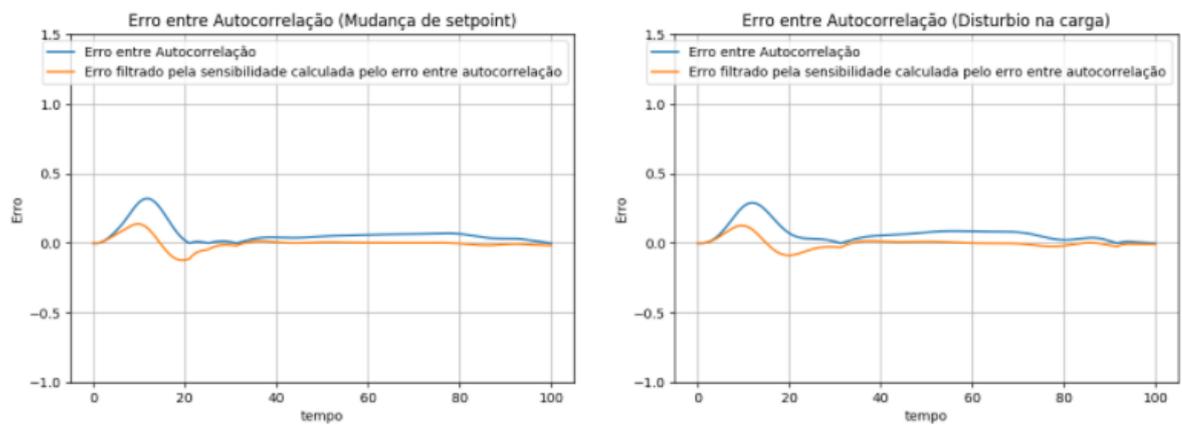


Figura A33: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta

H

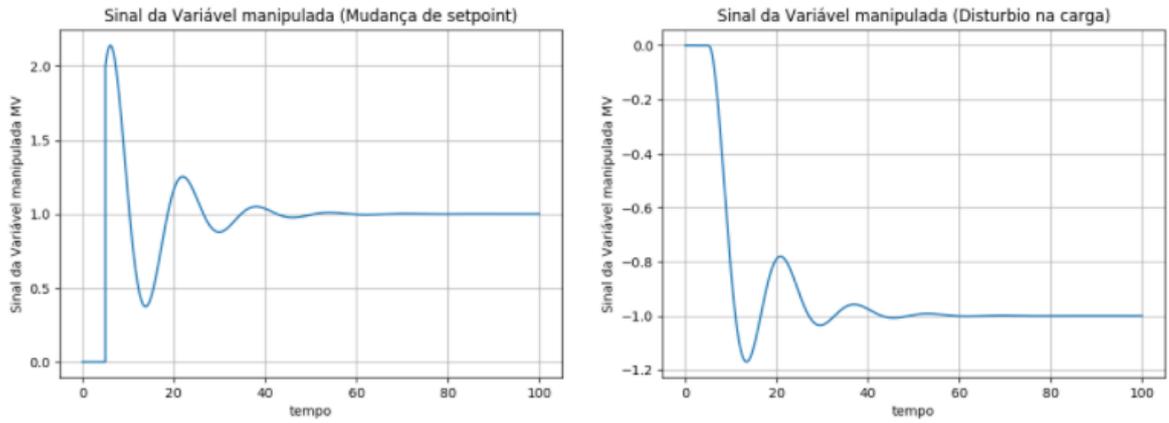


Figura A34: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta H

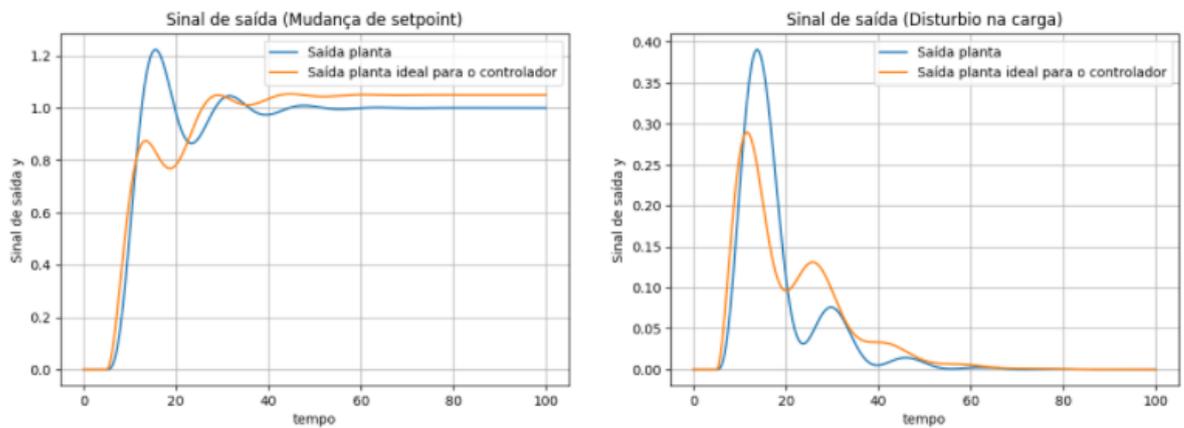


Figura A35: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta H

Planta I:

$$G(s)_I = \frac{1}{32s^3 + 24s^2 + 6s + 1}$$

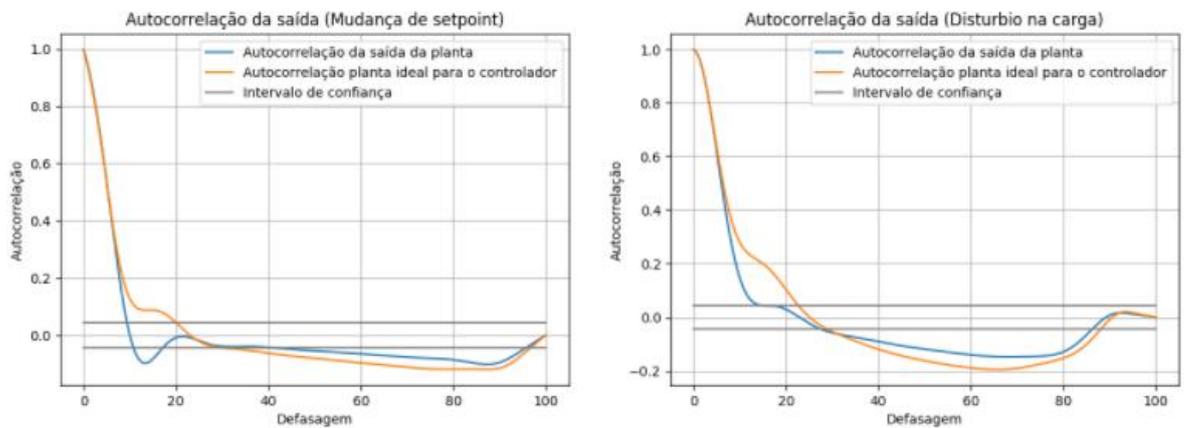
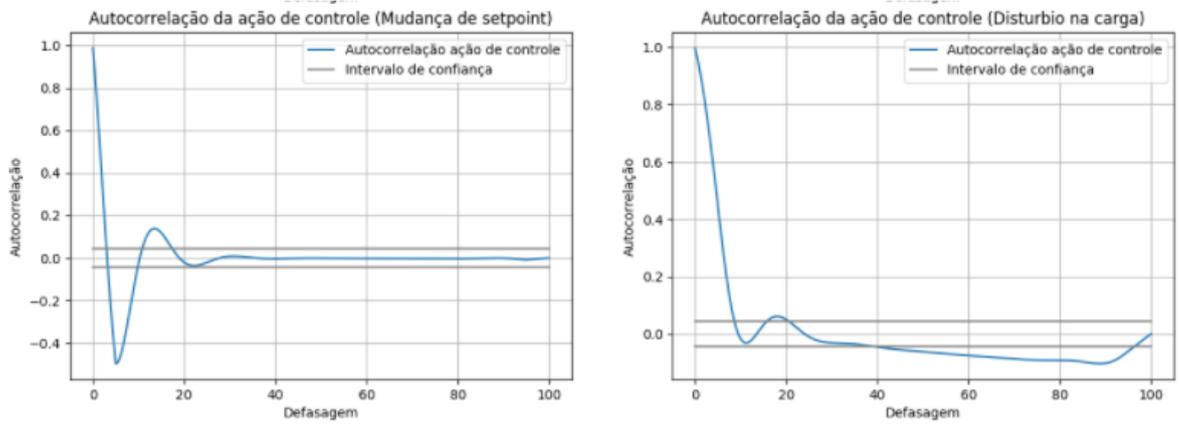
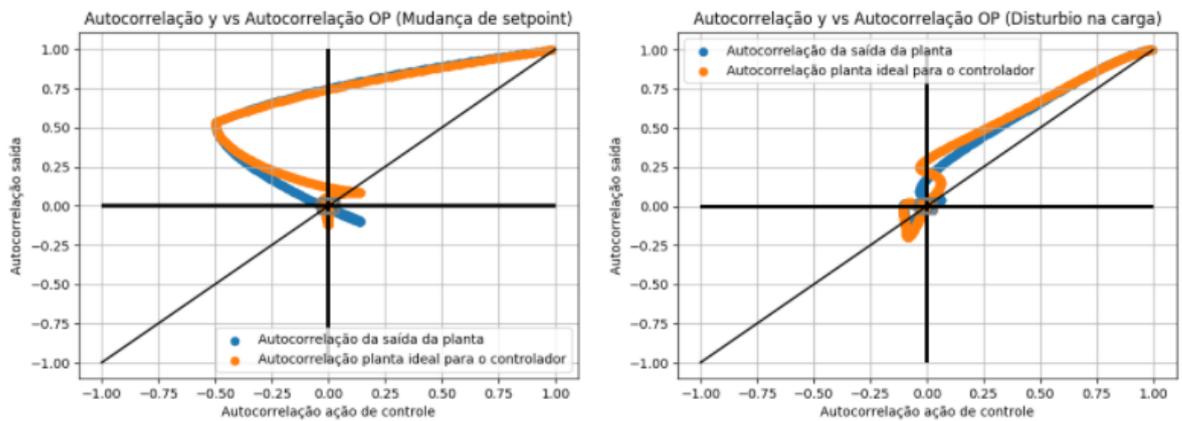


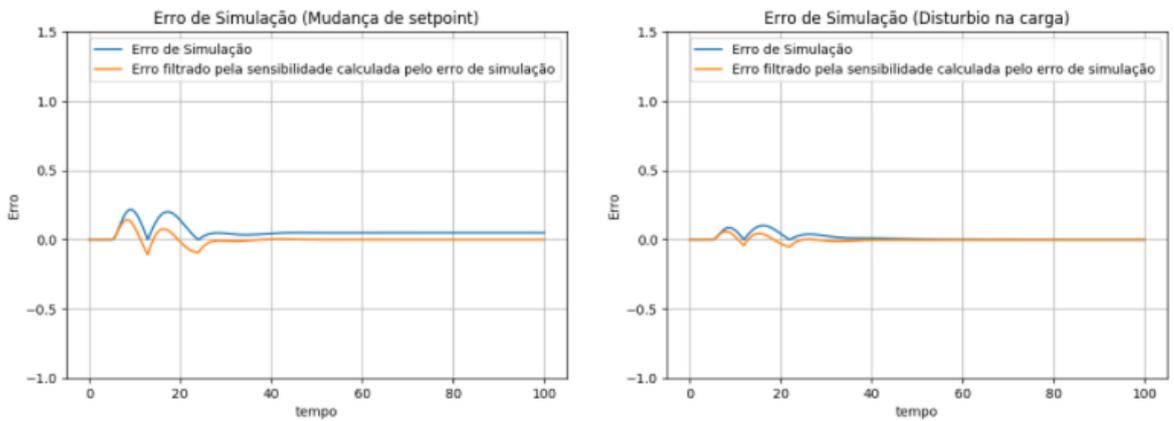
Figura A36: Autocorrelação de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta



**Figura A37:** Autocorrelação da ação de controle frente a uma mudança de *setpoint* e um distúrbio na carga da planta I



**Figura A38:** Autocorrelação da ação de controle VS autocorrelação de saída da planta I



**Figura A39:** Erro de simulação frente a uma mudança de *setpoint* e um distúrbio na carga da planta I

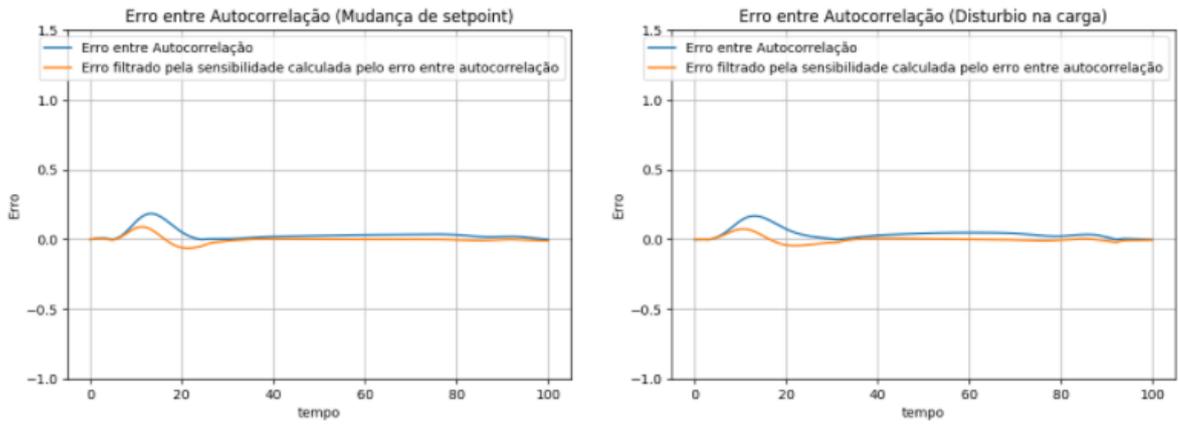


Figura A40: Erro entre autocorrelação frente a uma mudança de *setpoint* e um distúrbio na carga da planta I

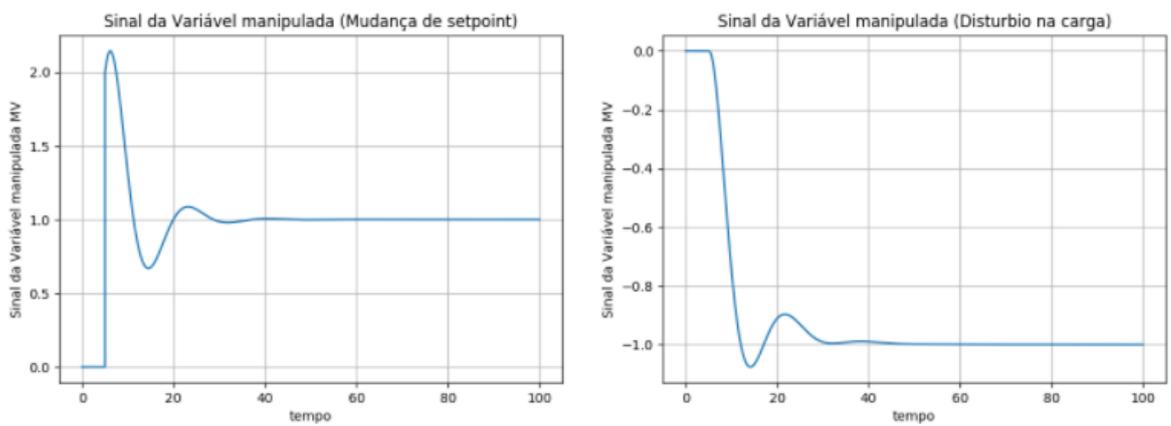


Figura A41: Sinal da variável manipulada frente a uma mudança de *setpoint* e a um distúrbio na carga da planta I

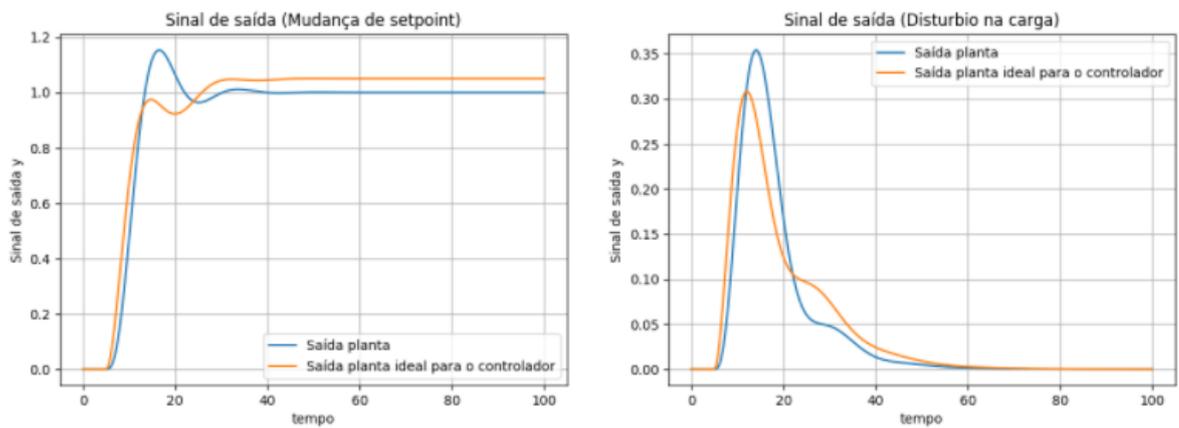


Figura A42: Sinal de saída frente a uma mudança de *setpoint* e a um distúrbio na carga da planta I