

**UNESP – UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE BAURU
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

GUSTAVO JOSÉ CORRÊA GONÇALVES

**AVALIAÇÃO DE DESEMPENHO DE CONTROLADORES
AVANÇADOS APLICADOS A UM PROCESSO DE
CONTROLE DE NÍVEL**

**Bauru
2017**

Gustavo José Corrêa Gonçalves

**AVALIAÇÃO DE DESEMPENHO DE CONTROLADORES
AVANÇADOS APLICADOS A UM PROCESSO DE CONTROLE DE
NÍVEL**

Dissertação apresentada à Faculdade de Engenharia de Bauru, como requisito para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. José Alfredo Covolan
Ulson

Bauru
2017

Gonçalves, Gustavo José Corrêa.

Avaliação de desempenho de controladores avançados aplicados a um processo de controle de nível / Gustavo José Corrêa Gonçalves, 2017
133 f.

Orientador: João Alfredo Covolan Ulson

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2017

1. Controladores avançados. 2. Controle de nível.
3. Avaliação comparativa de controladores. I.
Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.



UNIVERSIDADE ESTADUAL PAULISTA


Câmpus de Bauru




ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE GUSTAVO JOSÉ CORRÊA GONÇALVES, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 26 dias do mês de abril do ano de 2017, às 15:00 horas, no(a) Anfiteatro da Seção Técnica de Pós-graduação da FEB, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. JOSE ALFREDO COVOLAN ULSON - Orientador(a) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. DANILO HERNANE SPATTI do(a) Departamento Acadêmico de Elétrica / Universidade Tecnológica Federal do Paraná, Prof. Dr. FERNANDO DE SOUZA CAMPOS do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de GUSTAVO JOSÉ CORRÊA GONÇALVES, intitulada **AVALIAÇÃO DE DESEMPENHO DE CONTROLADORES AVANÇADOS APLICADOS A UM PROCESSO DE CONTROLE DE NÍVEL**. Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: APROVADO.


Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.



Prof. Dr. JOSE ALFREDO COVOLAN ULSON



Prof. Dr. DANILO HERNANE SPATTI



Prof. Dr. FERNANDO DE SOUZA CAMPOS

Agradecimentos

A Deus por minha vida, família e amigos.

Aos meus pais, José Mauro e Wandelena, ao meu irmão, Vinícius, e à minha namorada, Gabriela, pelo apoio incondicional.

Ao professor Dr. José Alfredo Covolan Ulson, pela orientação, apoio e confiança.

Aos professores e funcionários da FEB/UNESP, por contribuírem com meu desenvolvimento pessoal e profissional.

RESUMO

O uso de técnicas de controle preditivo e de sistemas inteligentes na resolução de problemas de controle de grande complexidade tem crescido significativamente na última década. Parte disso se deve ao fato destas abordagens já terem sido utilizadas com sucesso em uma vasta gama de aplicações, demonstrando sua robustez e eficiência. Porém, o uso destas técnicas ainda é pequeno quando comparado com o controle PID (proporcional integral derivativo) clássico, ainda que apresentem resultados melhores. Assim, a maioria das publicações presentes na literatura que utilizam estas técnicas de controle mais sofisticadas tem como objetivo resolver um problema específico de controle. Para isso, em geral, adota-se uma determinada abordagem sem que necessariamente se faça uma avaliação a respeito de qual dos métodos existentes seria o mais eficiente, uma vez que o foco é apenas a resolução do problema. Nesse contexto, o objetivo deste trabalho foi avaliar o desempenho de três das técnicas de controle inteligente e/ou preditivo mais aceitas para o controle de processos industriais frente ao controlador PID clássico, de uso generalizado na indústria. Mais especificamente, optou-se por utilizar o controlador MPC, o controlador Fuzzy e o controlador Neural Preditivo para o controle de um processo industrial e, então, avaliar o desempenho por meio das métricas ISE e ITSE, além de comparar o sobressinal máximo, erro estacionário e tempo de acomodação. Por fim, os resultados de desempenho de cada controlador foram confrontados com o controlador PID clássico. Os resultados indicaram que os controladores com melhor desempenho foram os controladores MPC e fuzzy de duas entradas, apresentando melhores resultados quando comparados com o controlador PID. Ainda, observou-se que o controlador fuzzy de uma entrada e preditivo neural não foram capazes de controlar o sistema em todos os patamares considerados.

Palavras-chave: Controle MPC. Controle preditivo neural. Controle fuzzy. Sistemas inteligentes. Controle de nível. Comparação entre técnicas de controle.

ABSTRACT

The use of predictive control techniques and intelligent systems in the resolution of complex control problems has increased in the last decade. Part of this is due to the fact that these approaches have already been used successfully in a wide range of applications, demonstrating their robustness and efficiency. However, the use of these techniques is still small when compared to the classic PID (derivative proportional integral) control, although they present better results. Thus, most publications in the literature that use these more sophisticated control techniques aim to solve a specific control problem. For this, in general, a certain approach is adopted without necessarily making an evaluation as to which of the existing methods would be the most efficient, since the focus is only the resolution of the problem. In this context, the objective of this work was to evaluate the performance of three of the most accepted intelligent and / or predictive control techniques for the control of industrial processes against the classical PID controller, widely used in industry. More specifically, it was decided to use the MPC controller, the Fuzzy controller and the Neural Predictive controller to control an industrial process, and then evaluate the performance through the ISE and ITSE metrics, in addition to comparing the maximum overshoot, stationary error and accommodation time. Finally, the performance results of each controller were confronted with the classic PID controller. The results indicated that the best performing controllers were the MPC and the two input fuzzy controllers, presenting better results when compared to the PID controller. Also, it was observed that the fuzzy controller of an input and predictive neural were not able to control the system at all levels considered.

Keywords: MPC control. Neural predictive control. Fuzzy control. Intelligent Systems. Level control. Comparison of control techniques.

SUMÁRIO

CAPÍTULO 1- INTRODUÇÃO E OBJETIVOS	12
1.1. Motivação e Justificativa	12
1.2. Objetivos	14
1.3. Organização do trabalho.....	14
CAPÍTULO 2- REVISÃO BIBLIOGRÁFICA	16
2.1. Controle PID	16
2.2. Controle Preditivo Baseado em Modelo	19
2.3. Controle Preditivo Neural	26
2.4. Controle Fuzzy	30
CAPÍTULO 3- MATERIAIS E MÉTODOS	33
3.1. Modelagem do processo de controle de nível	33
3.2. Controlador PID	37
3.3. Controlador Fuzzy	39
3.4. Controlador Preditivo Baseado em Modelo	45
3.5. Controlador Preditivo Neural	49
3.6. Critérios de Avaliação	50
CAPÍTULO 4- RESULTADOS E DISCUSSÃO	53
4.1. Resposta do sistema mediante uma entrada degrau ideal.....	53
4.2. Resposta do sistema mediante uma entrada degrau ruidosa	69
4.3. Resposta do sistema mediante uma entrada rampa ideal.....	80
CAPÍTULO 5- CONCLUSÕES.....	92
REFERÊNCIAS	94
APÊNDICE	100

LISTA DE ILUSTRAÇÕES

Figura 2. 1- Fluxograma de um sistema de controle em malha fechada usando o PID	17
Figura 2. 2- Fluxograma de um processo sendo controlado pelo MPC.....	20
Figura 2. 3- Estratégia de controle do MPC	21
Figura 2. 4- Fluxograma de treinamento de um controlador preditivo neural	26
Figura 2. 5- Fluxograma de um processo controlado pelo controlador preditivo neural	27
Figura 2. 6- Etapas do sistema de inferência de um controlador fuzzy	31
Figura 3. 1- Desenho esquemático de um processo de controle de nível de água em um tanque	33
Figura 3. 2- Desenho esquemático do fluxo de líquido em um tanque cilíndrico	34
Figura 3. 3- Comportamento da vazão pela ação de controle de uma válvula proporcional real.....	35
Figura 3. 4- Curva de vazão da válvula proporcional utilizada no processo de controle de nível	36
Figura 3. 5- Diagrama de blocos do processo de nível de líquido	36
Figura 3. 6- Curva de resposta do controlador PID a uma entrada degrau unitário, com estado inicial em 0,5m	38
Figura 3. 7- Simulação da malha de controle do controlador PID	38
Figura 3. 8- Funções de pertinência da variável de entrada Nível	39
Figura 3. 9- Funções de pertinência da variável de saída Válvula	40
Figura 3. 10- Gráfico de controle do controlador fuzzy de uma entrada.....	41
Figura 3. 11- Simulação da malha de controle do controlador fuzzy de uma entrada	42
Figura 3. 12- Funções de pertinência da variável de entrada Nível	42
Figura 3. 13- Funções de pertinência da variável de entrada Variação	43
Figura 3. 14- Funções de pertinência da variável de saída Válvula	43
Figura 3. 15- Superfície de controle do controlador fuzzy de duas entradas	45
Figura 3. 16- Simulação da malha de controle do controlador fuzzy de duas entradas	45

Figura 3. 17- Gráfico de resposta do controlador MPC mediante uma entrada degrau unitário	46
Figura 3. 18- Gráfico do sinal de controle do controlador MPC quando submetido a uma entrada degrau unitário	47
Figura 3. 19- Gráfico de resposta do controlador MPC quando submetido a uma entrada degrau de amplitude cinco	48
Figura 3. 20- Simulação da malha de controle do controlador MPC	48
Figura 3. 21- Simulação da malha de controle do controlador preditivo neural.....	50
Figura 3. 22- Implementação dos critérios de avaliação ISE e ITSE para a malha de controle do controlador PID.....	51
Figura 3. 23- Gráfico de resposta de um sistema subamortecido quando submetido a uma entrada do tipo degrau unitário.....	52

LISTA DE TABELAS

Tabela 3. 1- Valores dos parâmetros utilizados para o processo de controle de nível.....	37
Tabela 3. 2- Valores dos parâmetros do controlador PID paralelo	37
Tabela 3. 3- Regras que relacionam entrada e saída do controlador fuzzy de uma entrada	40
Tabela 3. 4- Regras que relacionam entradas e saída do controlador fuzzy de duas entradas	44
Tabela 3. 5- Parâmetros de configuração utilizados para o treinamento da rede neural	49
 Tabela 4. 1- Comparação dos valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores para a entrada degrau ideal.....	59
Tabela 4. 2- Comparação dos valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores para a entrada degrau ruidoso	76
Tabela 4. 3- Comparação dos valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores para a entrada rampa ideal.....	86

LISTAS DE ABREVIATURA E SIGLAS

EQM – Erro Quadrático Médio

ISE – *Integral Square Error*

ITSE – *Integral of Time multiplied by Square Error*

MPC – *Model Predictive Control*

PH – Potencial hidrogeniônico

PID – Proporcional integral derivativo

RNA – Rede neural artificial

CAPÍTULO 1- INTRODUÇÃO E OBJETIVOS

1.1. Motivação e Justificativa

O controle linear de plantas não lineares é, atualmente, o mais utilizado pela indústria de processos e emprega o controlador a três termos conhecido como controlador PID (proporcional, integral e derivativo) e suas variações, em que uma ou mais ações podem ser desconsideradas. O controlador PID possui basicamente três parâmetros que irão ponderar as ações proporcionais, integrais e derivativas ao sinal de erro, que é obtido a partir da diferença entre o sinal de referência e a saída da planta. O controlador PID vem sendo utilizado no controle de processos industriais há décadas e está presente em praticamente todas as plataformas de controle comerciais, devido principalmente à sua simplicidade de implementação e à sua robustez. No entanto, seu uso é limitado em processos que apresentam grau de não-linearidade e atrasos de pequena magnitude (SHARMA; VERMA; MATHEW, 2016).

Deve ser observado que em plantas não lineares com alto grau de complexidade como o controle de neutralização de pH (FAVARO, 2012), produção de bioetanol (CONDORENA, 2012), aplicação de herbicidas a taxas variáveis (OLIVI, 2009) entre outras, o desempenho de controladores lineares como o PID não é satisfatório. Isso se deve principalmente a não linearidades e atrasos característicos desses processos.

Neste contexto, outras técnicas de controle foram desenvolvidas para serem utilizados em aplicações específicas em que o controlador PID não apresentava desempenho satisfatório, como em refinarias petrolíferas (ESTURILIO, 2011). No entanto, atualmente várias técnicas de controle preditivo e/ou inteligente estão presentes em uma grande diversidade de aplicações devido ao seu desempenho altamente eficiente, tais como em controle de compressores (CORREIA, 2010), processos de destilação (MARTIN, 2011), controle de processo de fresagem (HABER et al., 2003), controle de processo de refrigeração (FILETI et al., 2007), controle de sistema de pulverização, (FELIZARDO, 2013), entre outros.

Apesar de estas técnicas de controle preditivo e de controle inteligente apresentarem resultados melhores do que os do controlador PID clássico em

determinadas aplicações, seu uso ainda é restrito (WUERGES; BORBA, 2010). Parte disso se deve ao fato de que o uso de um controlador preditivo, por exemplo, depende do uso de um modelo matemático preciso que descreva o processo (FELIZARDO, 2013). Além disso, sua aplicação em processos de dinâmica rápida exige um hardware robusto e que seja capaz de resolver problemas de otimização multivariável rapidamente. Assim, a complexidade de alguns processos faz com que o uso de controladores mais adequados à sua dinâmica seja desconsiderado.

De acordo com um estudo feito em 2010, o uso de técnicas de inteligência artificial tem crescido muito nos últimos anos (WUERGES; BORBA, 2010). Dentre as soluções mais aplicadas estão as Redes Neurais Artificiais (RNA), a Lógica Fuzzy e os Algoritmos Genéticos. Do ponto de vista do controle de processos, as RNA e a Lógica Fuzzy tem sido utilizadas com sucesso em diversos tipos de aplicações tais como o controle de emissões de poluentes por motores de combustão interna (SARDARMEHNI et al., 2013), controle de temperatura em incubadoras (ROMANINI, 2009), controle de velocidade de um motor de indução (REN; ZHANG, 2013), craqueamento analítico do petróleo (VIEIRA, 2002), entre várias outras.

Além das técnicas de controle inteligente, o Controlador Preditivo baseado em Modelo (MPC) tem sido utilizado em muitas aplicações que apresentam não linearidades, em que o controlador PID clássico não apresenta resultados plenamente satisfatórios (ESTURILIO, 2011) (MARTIN, 2011).

Pode-se verificar que na maior parte das publicações em que se utiliza técnicas de controle preditivo ou inteligente tem como objetivo resolver um determinado problema de controle (CORREIA, 2010) (MARTIN, 2011) (FELIZARDO, 2013). A escolha do método de controle a ser utilizado é normalmente realizada com base em outras publicações similares, em que o referido método foi aplicado com sucesso em um processo com características dinâmicas parecidas. Desta forma, não é possível avaliar a aplicabilidade de outras técnicas de controle para o problema considerado e, principalmente, não é possível saber se o método de controle adotado é o mais eficiente, visto que apenas uma técnica é utilizada no controle do processo.

Assim, pode-se observar que essas técnicas de controle foram utilizadas com sucesso em várias aplicações específicas. No entanto, ainda existem poucos estudos que comparem diferentes técnicas de controle aplicadas em um determinado

processo, de forma que seja possível saber de fato qual método é o mais indicado para o processo considerado.

1.2. Objetivos

Diante do cenário previamente exposto, o objetivo deste trabalho foi avaliar o desempenho de três das técnicas de controle inteligente e/ou preditivo mais aceitas para o controle de processos industriais frente ao controlador PID clássico, de uso generalizado na indústria. Mais especificamente, optou-se por utilizar o controlador Preditivo Baseado em Modelo, o controlador Fuzzy e o controlador Neural Preditivo para o controle de um processo industrial e, então, avaliar o desempenho por meio das métricas ISE e ITSE, além de comparar o sobressinal máximo, erro estacionário e tempo de acomodação. Por fim, os resultados de desempenho de cada controlador serão confrontados com o controlador PID clássico.

Tendo em vista que cada método de controle exige um determinado conhecimento acerca do processo, optou-se por um processo amplamente utilizado na indústria e presente na literatura: o processo de controle de nível de líquido em um tanque, que é um processo naturalmente não linear e, em geral, apresenta escoamento turbulento. Desta forma, foi possível obter todas as informações necessárias do processo para atender as exigências de cada método de controle proposto. Uma vez que este processo é amplamente utilizado na indústria, os resultados obtidos por este trabalho poderão ser utilizados na escolha do método de controle mais eficiente para este problema ou para aplicações similares.

1.3. Organização do trabalho

Este trabalho está organizado de forma que o Capítulo 2 apresenta uma revisão bibliográfica recente a respeito das publicações sobre o controle de processos utilizando os métodos que serão tratados no decorrer do texto. Além disso, uma conceituação específica de cada método é apresentada, com ênfase nas aplicações de controle. O Capítulo 3 mostra como foi feita a modelagem do processo de controle de nível, as configurações dos controladores utilizados e os critérios de avaliação que foram utilizados para realizar a comparação entre eles. Além disso, serão

apresentados os diagramas de blocos de cada malha de controle individualmente. O Capítulo 4 apresenta os resultados obtidos através das simulações. Diferentes cenários de simulações são utilizados de forma que seja possível realizar comparações sob várias condições de entrada distintas. Ainda neste capítulo, os resultados obtidos através das métricas de comparação serão confrontados com o desempenho do controlador PID clássico. O Capítulo 5 apresenta as conclusões obtidas ao longo do desenvolvimento do trabalho e, mais especificamente, sobre as comparações realizadas entre os diferentes controladores quando aplicados ao processo de controle de nível. O Apêndice traz os conceitos fundamentais sobre as Redes Neurais Artificiais e sobre a Lógica Fuzzy com o objetivo de apresentar em detalhes a fundamentação desses métodos.

CAPÍTULO 2- REVISÃO BIBLIOGRÁFICA

Neste capítulo serão apresentados uma conceituação e o estado do desenvolvimento atual das técnicas de controle utilizadas: controle PID, controle MPC, controle Preditivo Neural e controle Fuzzy. Assim, será possível verificar as características de cada técnica e o resultado de suas aplicações em diferentes processos.


2.1. Controle PID

O controle proporcional integral derivativo (PID) é o mais utilizado na indústria e está presente em mais da metade das aplicações de controle em processos, seja na sua versão clássica ou em alguma versão modificada. Esta popularidade se deve ao fato de que o controle PID é aplicável à maioria dos sistemas de controle, resultando em um controle robusto e eficiente. Além disso, como o controle PID não necessita que se tenha a modelagem matemática do processo a ser controlado, ele normalmente surge como primeira opção de método de controle (OGATA, 2011).

Desta forma, devido a sua grande praticidade e facilidade de sintonização quando comparado com outros métodos de controle que exigem um projeto analítico do processo e do controlador, o controle PID também é muitas vezes sintonizado automaticamente, através de algoritmos de sintonização, e o ajuste fino é feito manualmente após a primeira sintonização (OGATA, 2011).

O motivo pelo qual o controlador PID não necessita de um projeto analítico para funcionar é que ele trata o erro do processo em malha fechada, de forma que apenas o ajuste dos parâmetros do controlador já são o suficiente, na maioria dos casos, para se conseguir um controle eficiente, sem que seja necessário avaliar a resposta em frequência ou as raízes da função de transferência do processo. A figura 2.1 apresenta o desenho esquemático do funcionamento do controle PID evidenciando que o erro entre o sinal de referência e a saída do processo é realimentado no controlador, que calcula o sinal de controle e atua sobre o processo. A cada ciclo, espera-se que o erro diminua até que se torne nulo ou muito pequeno.

Figura 2. 1- Fluxograma de um sistema de controle em malha fechada usando o PID



Assim, o valor da ação de controle y em um dado instante de controle é determinada através da expressão apresentada na equação 2.1, em que e é o erro entre a referência e a saída real da planta:

$$y = K_p \cdot e + K_i \cdot \int e \, dt + K_d \cdot \frac{de}{dt} \quad (2.1)$$

Nesta expressão, K_p , K_i e K_d são as constantes que ajustam o comportamento do controlador PID. Cada uma delas tem uma função importante no comportamento do sinal e precisam ser sintonizadas adequadamente para que o controle atenda as especificações de projeto, principalmente no que se refere ao sobressinal máximo, tempo de acomodação e erro estacionário.

Desta forma, o parâmetro proporcional, K_p , é o parâmetro responsável por reduzir o tempo de subida e o erro estacionário, fazendo com que a saída do processo se aproxime da referência. Porém, o ganho proporcional aumenta o sobressinal da resposta do processo. O termo integral é capaz de eliminar completamente o erro estacionário, fazendo com que a saída atinja exatamente o valor de referência, mas para isso ele aumenta o tempo de estabilização da resposta. Por fim, o termo derivativo consegue diminuir o sobressinal e o tempo de estabilização, tornando a resposta mais rápida e com amplitudes de oscilação menores.

Dentro do contexto mais atual, o controle PI foi utilizado em uma planta de controle de nível de água em uma caldeira (QINGLI; PINGRONG; YANGXI, 2013), sendo que o controlador estava integrado ao controlador lógico programável do sistema. Inicialmente, fez-se o teste do parâmetro proporcional k_p , de forma que o ganho do sistema de controle fosse adequado para o setpoint. Feito isso, foi-se variando os valores do parâmetro integral k_i . Os parâmetros utilizados para k_p e k_i

durante os testes foram, respectivamente: 1 e 0,5 (teste 1) e 2 e 1,5 (teste 2). Com os primeiros parâmetros, o tempo de subida e de estabilização foram relativamente altos, enquanto o sobressinal foi de 15%. Na segunda configuração, o ganho foi aumentado, o que tornou a resposta de subida mais de 50% mais rápida, porém, aumentando o sobressinal para aproximadamente 23%. Ainda, o tempo de acomodação foi reduzido e o erro estacionário chegou a próximo de zero.

O controlador PID foi utilizado remotamente em um processo de controle de nível, em que se utilizou um navegador padrão de internet com uma interface gráfica para editar os parâmetros do controlador (IKHLEF et al., 2016). Os parâmetros do controlador foram definidos conforme o método de Ziegler-Nichols, de forma que foi necessária uma avaliação da resposta do sistema em malha aberta e em malha fechada. De acordo com a pesquisa, o controle foi realizado de forma satisfatória utilizando os parâmetros de sintonia propostos pelo método, de forma que o erro estacionário foi próximo de 7% para o método de sintonia em malha fechada e em torno de 13% para a sintonia feita pelo método de malha aberta.

Utilizou-se o controlador PID sintonizado pelo método de Ziegler-Nichols e otimizado pelo algoritmo Bat para controlar um sistema de controle de nível (KATAL; KUMAR; NARAYAN, 2014). Após a sintonia inicial, encontrou-se os valores de 28,21, 4,15 e 47,89 para k_p , k_i e k_d , respectivamente. Apesar de eficiente, esta configuração se mostrou inferior após a otimização por algoritmo Bat, uma vez que os parâmetros do PID otimizados reduziram o sobressinal e o tempo de estabilização do controle. O erro estacionário em todos os casos chegou a próximo de zero em instantes de tempo parecidos.

A fim de controlar e demonstrar a eficiência do controle fuzzy em processos não lineares, utilizou-se um controlador nebuloso aplicado a uma simulação de processo de controle de nível. A fim de comparar a eficiência do controle fuzzy, comparou-se este controle com um controle PID (BHANDARE; KULKARNI, 2015). Foi observado que o controlador fuzzy foi mais rápido para estabilizar e não apresentou nenhum sobressinal, ao passo que o controlador PID apresentou vários níveis de sobressinal durante o processo de controle. No entanto, o controle PID conseguiu reduzir melhor o erro estacionário. Assim, conclui-se que o controle fuzzy, para esta aplicação, seria melhor utilizado para uma resposta mais rápida e precisa, trazendo a

variável controlada para próxima da referência, enquanto o controlador PID entraria em ação apenas depois, de forma a realizar um ajuste fino do controle.


Considerando um processo de controle de nível em uma indústria nuclear, utilizou-se uma simulação em ambiente MATLAB juntamente com um controlador PID e um controlador misto PID/FUZZY (CHENG-ZE; ZHI; SHAN, 2012). Ambos os controladores conseguiram um erro estacionário abaixo de 5% do valor de referência, porém, o controlador PID tradicional apresentou um sobressinal de 10,1%, enquanto o controlador misto apresentou apenas 1,67% de sobressinal. Ainda, o tempo de resposta do controlador misto foi 27% mais rápido do que o controlador PID tradicional.

Um estudo comparativo de métodos de sintonia de controladores PID utilizou os métodos de Ziegler-Nichols, Kappa-Tau, AMIGO (*Approximate M-constrained Integral Gain Optimization*) e sintonia através de erro. Assim, os critérios ISE (*Integral Square Error*), IAE (*Integral Absolute Error*), ITSE (*Integral of Time multiplied Square Error*) e ITAE (*Integral of Time multiplied Absolute Error*) foram utilizados. Para fins de comparação, definiu-se que o erro estacionário deveria ser nulo, o sobressinal máximo de 5% e o tempo de acomodação máximo em malha fechada fosse metade do tempo de acomodação em malha aberta. Assim, conclui-se que os métodos de sintonia através do erro conduziram a boas configurações de controladores. Ainda, o melhor controlador foi obtido usando o método ITAE para sintonia (FERMINO, 2014).

2.2. Controle Preditivo Baseado em Modelo

O controle preditivo baseado em modelo (MPC) se refere aos métodos de controle que utilizam um modelo do processo a ser controlado para estimar os estados futuros. Assim, estes métodos geram o sinal de controle através da minimização de uma função custo, que leva em consideração o erro estimado (predito) pelo controlador e as restrições das variáveis manipuladas. A figura 2.2 mostra um desenho esquemático de um processo usando controle por MPC.


Figura 2. 2- Fluxograma de um processo sendo controlado pelo MPC



A partir do modelo do processo, o controlador é capaz de prever as saídas futuras da planta, utilizando os valores de entrada e os valores medidos da saída. Desta forma, o MPC utiliza os dados passados para estimar dados futuros, otimizando assim a ação de controle mais adequada. A predição é realizada dentro do chamado horizonte de predição N_p , enquanto o controle é realizado dentro do horizonte de controle N_c .

A figura 2.3 mostra o funcionamento da estratégia utilizada por um controlador preditivo baseado em modelo. As variáveis de entrada $r(k)$ e de saída $y(k)$ são os valores em um dado instante $k = nT$ do sinal de referência e da variável controlada, respectivamente, sendo que T é o período de amostragem. Desta forma, as saídas preditas com base nas informações disponíveis até o instante k são denotadas por $\hat{y}(k+ilk)$, tal que i varia de 1 até N_p . Da mesma forma, o sinal de controle $\hat{u}(k+ilk)$ ótimo é estimado com base no otimizador, com i variando de 1 até N_c . O algoritmo de otimização atua de forma a minimizar o erro existente entre a saída da planta e o sinal de referência (CAMACHO; BORDONS, 2007).

Figura 2. 3- Estratégia de controle do MPC



(Fonte: FELIZARDO, 2013)

Após ter realizado a predição e a otimização para o instante k , o sinal de controle é aplicado no processo, produzindo uma nova saída que é medida e inserida no modelo da planta presente no controlador. A entrada deste novo dado permite que o controlador inicie novamente o ciclo de predição e otimização, de forma que os sinais de controle futuros são corrigidos para os novos valores otimizados, o que é feito através de um sinal de controle incremental $\Delta \hat{u}(k+il|k)$, com i variando dentro do horizonte de controle. Desta forma, o controlador reavalia as predições a cada novo ciclo e atua sempre de forma a otimizar o sinal de controle que será enviado para o processo (CAMACHO; BORDONS, 2007).

O modelo do preditor tem um papel muito importante no MPC, uma vez que predições pouco precisas levam a sinais de controle que não serão capazes de levar a saída do processo até o sinal de referência. Assim, não existe uma função de otimização única e ela pode ser escrita de acordo com cada processo. No entanto, todas elas irão estabelecer uma relação entre a saída e a referência (FAVARO, 2012).

Apesar de ser possível utilizar diversos tipos de funções custo, será apresentada a seguir a função com a qual as simulações serão realizadas. Assim, a equação 2.2 representa a função custo utilizada para as simulações, em que cada elemento trata de um aspecto específico do problema de controle (MATHWORKS, 2016):

$$J(z_k) = J_y(z_k) + J_u(z_k) + J_{\Delta u}(z_k) + J_\varepsilon(z_k) \quad (2.2)$$

O primeiro termo, $J_y(z_k)$, se refere à necessidade do controlador em seguir uma referência. Assim, este parâmetro é definido na equação 2.4, em que z_k é a matriz de decisão da variável manipulada, apresentada na equação 2.3:

$$z_k = [u(k|k)^T \ u(k+1|k)^T \ ... \ u(k+N_p-1|k)^T \ k] \quad (2.3)$$

$$J_y(z_k) = \sum_{j=1}^{n_y} \sum_{i=1}^{N_p} \left(\frac{w_{i,j}^y}{s_j^y} [r_j(k+i|k) - y_j(k+i|k)] \right)^2 \quad (2.4)$$

Nesta equação, n_y é o número de variáveis de saída do processo, $y_j(k+i|k)$ é o j-ésimo valor de saída predito no instante $k+i$, $r_j(k+i|k)$ é o j-ésimo valor de referência no instante $k+i$. Ainda, s_j^y é o fator de escala para o j-ésimo valor de saída da planta e $w_{i,j}^y$ é o valor do peso para o j-ésimo valor de saída da planta no instante $k+i$. Estes dois últimos parâmetros, assim como o número de variáveis de saída n_y e o horizonte de predição e de controle, são parâmetros do controlador e, portanto, constantes. Desta forma, este parâmetro é função apenas da variável manipulada, que atua no valor de saída predito. Além disso, este parâmetro faz a relação entre o valor de referência e o valor de saída predito, que é o erro predito.

O segundo termo, $J_u(z_k)$ apresentado na equação 2.5, diz respeito às variáveis manipuladas. Em determinados casos, como por exemplo no caso de existirem mais variáveis manipuladas do que variáveis controladas, o controlador MPC precisa mandar algumas variáveis próximas de valores específicos. Assim, esta expressão relaciona o valor medido para determinada variável manipulada $u_j(k+i|k)$ com o valor desejado para ela mesma, $u_{j,alvo}(k+i|k)$, em determinado instante k . Os outros parâmetros desta expressão são análogos aos da expressão anterior, em que neste caso n_u é o número de variáveis manipuladas do processo a ser controlado.

$$J_u(z_k) = \sum_{j=1}^{n_u} \sum_{i=1}^{N_p-1} \left(\frac{w_{i,j}^u}{s_j^u} [u_j(k+i|k) - u_{j,alvo}(k+i|k)] \right)^2 \quad (2.5)$$

O terceiro parâmetro, $J_{\Delta u}(z_k)$, representado pela equação 2.6, diz respeito ao incremento no valor das variáveis manipuladas ao longo de cada intervalo de controle k . Assim, esta expressão utiliza apenas os valores de cada variável manipulada nos instantes $k + i$ e $k + i - 1$. Analogamente, os outros parâmetros são especificações do controlador e, portanto, permanecem constantes. Assim, tendo em vista que um controle suave é desejado, este parâmetro avalia o passo máximo das variáveis manipuladas em cada intervalo de controle, evitando oscilações bruscas indesejadas.

$$J_{\Delta u}(z_k) = \sum_{j=1}^{n_u} \sum_{i=1}^{N_p-1} \left(\frac{w_{i,j}^{\Delta u}}{s_j^u} [u_j(k + i|k) - u_j(k + i - 1|k)] \right)^2 \quad (2.6)$$

O último termo, $J_{\varepsilon}(z_k)$, diz respeito às violações de limites das variáveis e está descrito pela equação 2.7. Nesta expressão, o termo ε_k quantifica o pior cenário para esta violação nos limites das variáveis e o termo ρ_{ε} estabelece o peso da violação de limites. Assim, o termo $J_{\varepsilon}(z_k)$ penaliza os estados em que as variáveis estão próximas de seus limites físicos estabelecidos, de forma que a otimização evite estas condições.

$$J_{\varepsilon}(z_k) = \rho_{\varepsilon} \varepsilon_k^2 \quad (2.7)$$

Para o cálculo dos limites de cada variável, seja ela controlada ou manipulada, o controlador utiliza as expressões 2.8, 2.9 e 2.10, em que o termo V é um peso que está relacionado com a suavização dos limites das variáveis. Assim, as expressões a seguir são usadas para a variável controlada (i varia de 1 até N_p e j varia de 1 até n_y), para a variável manipulada (i varia de 1 até N_p e j varia de 1 até n_u) e para a variação da variável manipulada (i varia de 1 até N_p e j varia de 1 até n_u), respectivamente:

$$\frac{y_{j,min}(i)}{s_j^y} - kV_{j,min}^y(i) \leq \frac{y_j(k + i|k)}{s_j^y} \leq \frac{y_{j,max}(i)}{s_j^y} + kV_{j,max}^y(i) \quad (2.8)$$

$$\frac{u_{j,min}(i)}{s_j^u} - kV_{j,min}^u(i) \leq \frac{u_j(k + i - 1|k)}{s_j^u} \leq \frac{u_{j,max}(i)}{s_j^u} + kV_{j,max}^u(i) \quad (2.9)$$

$$\frac{\Delta u_{j,min}(i)}{s_j^y} - kV_{j,min}^{\Delta u}(i) \leq \frac{\Delta u_j(k+i-1k)}{s_j^u} \leq \frac{\Delta u_{j,max}(i)}{s_j^u} + kV_{j,max}^{\Delta u}(i) \quad (2.10)$$

Desta forma, sabendo-se que o controlador MPC utiliza uma função custo que é otimizada durante o processo de controle, pode-se resumir a implementação deste tipo de controlador em cinco passos (ADÃO, 2011):

- i) Desenvolver o modelo matemático para o processo a ser controlado.
- ii) Estimar os valores futuros para a variável controlada e manipulada, a partir dos valores presentes medidos dessas variáveis e do modelo do processo.
- iii) Minimizar a função custo a cada intervalo de controle e recalculas as estimativas para as variáveis, de forma a otimizar o controle.
- iv) Aplicar o primeiro valor estimado do sinal de controle na planta, em malha fechada e medir o novo valor da variável controlada. Uma vez que apenas o primeiro valor do sinal de controle é efetivamente aplicado à planta (pois os valores futuros serão recalculados), esta técnica é denominada de horizonte deslizante.
- v) O intervalo de controla que antes era uma estimativa, se torna o intervalo atual. Seus valores são efetivamente medidos e utilizados para realizar novas predições. Este ciclo se reinicia a partir do passo ii.

Tendo em vista que o controle preditivo baseado em modelo é uma técnica bastante eficiente, ele foi utilizado em uma planta de neutralização de pH, que é considerado uma referência de problema não-linear, uma vez que ele pode sofrer variações sensíveis quando na presença de pequenas mudanças nos estados iniciais (YOO et al., 2004). Através da comparação do controlador MPC com o controlador PID, observou-se- que o controlador preditivo foi mais eficiente, apresentando um erro menor em relação ao setpoint, bem como um tempo menor para a estabilização (FAVARO, 2012).

No ano de 2013, realizou-se um trabalho com o intuito de avaliar os critérios de desempenho de controladores preditivos. Assim, foram utilizados os seguintes critérios: *Controller Performace Index* (CPI), C_p , C_{pk} e Índice de Yu e Qin. Após efetuada a avaliação, conclui-se que as técnicas utilizadas de controle apresentaram maior sensibilidade a mudanças nos pesos das variáveis controladas do que nas

variáveis manipuladas. Ainda, observou-se que o índice C_{pk} é importante para saber o quão próximo o controlador está das suas restrições, mostrando se o processo está ou não sendo otimizado. O índice C_p foi considerado um bom avaliador para saber se o processo é ou não controlável. Por fim, o trabalho ressaltou que o Índice de Yu e Qin fornece uma métrica para avaliar quando o controlador melhora ou piora o desempenho do processo. Assim, é possível utilizar para saber até quais pontos de operação do processo é recomendável a utilização de um MPC (BARROS, 2013).

O controlador MPC foi utilizado para controlar um sistema de pulverização com injeção direta, de forma a possibilitar o uso de diferentes agrotóxicos em uma mesma aplicação, reduzindo assim os gastos desnecessários e reduzindo os impactos ambientais decorrentes deste processo. Através do uso do controlador, foi possível reduzir os erros de vazão do agrotóxico para o patamar admissível de 5%. Ainda, utilizando a estratégia de antecipar as taxas de aplicação, obteve-se uma redução de até 40% nos erros de aplicação (FELIZARDO, 2013).


Com o intuito de controlar um reator de amônia de uma das unidades de fertilizantes da PETROBRAS (Unidade de Fertilizantes Nitrogenados da Bahia), foi utilizado um MPC de horizonte de predição infinito, de forma a maximizar o teor de amônia na saída do reator. Simulações mostraram que o controlador foi capaz de realizar o controle de forma eficiente, tanto do ponto de vista do controle econômico de processos, uma vez que ele maximizou a conversão de reagentes em amônia, quanto do ponto de vista da robustez, dado que o MPC se mostrou eficiente mesmo na presença de distúrbios no processo (ESTURILIO, 2011).

O controlador MPC robusto foi escolhido para controlar um processo de destilação, cujo comportamento não linear foi comprovado através de ensaios realizados. Além disso, foi provado matematicamente que o MPC robusto é sempre estável para todos os estados considerados, o que garante a segurança da sua utilização no processo de destilação. Os resultados mostraram que o controlador MPC foi eficiente quando inserido na malha de controle do processo, obtendo um erro estacionário da ordem de 0,6% em relação ao setpoint, ainda que a eficiência do controle variasse conforme cada estado do processo (MARTIN, 2011).

2.3. Controle Preditivo Neural

O controle preditivo neural consiste de duas etapas. Primeiramente, é necessário treinar uma rede neural artificial do tipo *Time Delay Neural Network* (TDNN) para que ela aprenda o comportamento do processo (detalhes sobre o treinamento pode ser visto no Apêndice A). Isto é feito pela rede neural inserindo valores aleatórios de entrada, dentro dos limites reais do processo, e medindo suas saídas. Feito isso, o algoritmo de aprendizagem irá generalizar o comportamento da planta para todos os pontos de operação possíveis. Uma vez que se deseja um modelo preditivo, utiliza-se uma rede neural do tipo atrasada no tempo. A figura 2.4 mostra o fluxo de dados durante o processo de treinamento da rede neural.

Figura 2. 4- Fluxograma de treinamento de um controlador preditivo neural




Após obter uma rede neural devidamente treinada para o comportamento do processo, utiliza-se a configuração mostrada na figura 2.5 para o controle preditivo. Neste caso, o sinal de referência é o *setpoint* desejado para o processo, que irá passar por um otimizador, assim como acontece com o controlador MPC. A otimização consiste em minimizar uma função custo, apresentada pela equação 2.11.

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 \quad (2.11)$$

Nesta função, o valor desejado para a saída do controlador, y_r , é comparado com o valor real de saída do modelo neural, y_m . N_1 e N_2 representam o intervalo para o horizonte de predição, enquanto o horizonte de controle é definido entre 1 e N_u . Como u' representa o sinal de controle teste para o estado considerado, a função custo J é minimizada levando em consideração o erro de predição e a variação do sinal de controle de um dado intervalo de controle. Ainda, ρ é uma constante que atribui o peso para a expressão que considera a variação do sinal de controle. Assim, o otimizador é responsável por encontrar u' tal que minimize a função J . Uma vez encontrado, este valor é utilizado como ação de controle no processo, que irá produzir uma saída que é medida e realimentada para o modelo neural do processo, de forma que se possa ajustar a variação no sinal de controle para o próximo intervalo de controle. A figura 2.5 mostra o fluxograma de um processo controlado pelo controlador preditivo neural.

Figura 2. 5- Fluxograma de um processo controlado pelo controlador preditivo neural



As redes neurais preditivas, quando aplicadas em um processo extrativo de fermentação alcoólica, obtiveram resultados satisfatórios no controle. Quando comparada com o controle realizado pela matriz dinâmica de controle, as redes neurais foram mais eficientes, uma vez que o controle através da matriz dinâmica apresentou instabilidade nas variáveis manipuladas (DUARTE, 2007).

Em 2006, uma rede neural do tipo *feedforward* foi utilizada para aprender o comportamento e controlar um exemplo de reator químico, sendo descrito como um processo químico altamente não linear. Quando comparada com uma rede neural comum, a rede neural preditiva apresentou a mesma eficiência no controle, porém,

com significativa redução de utilização computacional de até 50%. (KONSEY; CUTRIGHT; BEQUETTE, 2006)

No ramo automobilístico, uma rede neural preditiva foi utilizada para controlar a emissão de poluentes em motores de combustão interna, atuando na quantidade de ar que era enviado para o motor. Um modelo do motor foi criado através de uma rede neural artificial do tipo Perceptron Multicamada treinada pelo método da retropropagação do erro. O controle foi feito utilizando uma RNA preditiva de mesmo formato, mas com treinamento online. Como resultado, foi observado que a rede neural preditiva apresentou melhor desempenho do que uma rede neural padrão, tendo um custo de tempo até 4 vezes menor para o treinamento. Além disso, observou-se que o uso da RNP foi satisfatório quando aplicada a um motor com dinâmica variante no tempo. (SARDARMEHNI et al., 2013)

Uma simulação realizada através do ambiente Matlab utilizou uma rede neural preditiva do tipo recorrente, de forma a fazer previsões baseadas nos dados de 1 período a frente. As previsões foram de 1, 3, 5, 7, 10 e 15 estados a frente. Esta rede foi aplicada para realizar o controle de um modelo completo de um tanque, contando com um motor, válvulas e sensores para medir o fluxo de água e o nível do reservatório. O trabalho demonstrou que o principal desafio foi escolher adequadamente o melhor método matemático para realizar a otimização da rede neural. No entanto, o comportamento da rede neural treinada foi capaz de realizar o controle, ainda que o sistema em questão não tenha levado em consideração um modelo para distúrbios, o que aproximaria mais a simulação do processo real (PATAN; KORBICZ, 2013).

Em 2013, utilizou-se uma configuração de rede neural atrasada no tempo para realizar o controle de velocidade de um sistema que também foi modelado utilizando uma rede neural do tipo *feedforward*. Uma vez que a planta em questão apresentava um tempo morto relativamente alto, utilizou-se uma rede neural atrasada no tempo junto com uma rede neural preditiva, de forma a melhorar a performance do algoritmo de otimização da rede neural preditiva. Desta forma, foi possível comprovar a eficiência de uma rede neural preditiva aplicada a um processo com alto tempo morto, bem como propor uma configuração nova para estes casos, em que o uso de 2 redes

neurais torna o processo de treinamento mais rápido e eficiente, alcançando o treinamento em até metade do tempo (REN; ZHANG, 2013).

Feng Li avaliou a capacidade de predição de duas redes neurais artificiais do tipo *feedforward*, uma treinada pelo algoritmo de Levenberg-Marquardt e outra pelo algoritmo da retropropagação do erro (LI, 2010). A primeira tinha uma estrutura neuronal 26-5-1 enquanto a outra possuía uma estrutura 26-11-1. A rede treinada pelo algoritmo de Levenberg-Marquardt requereu 99,45% menos iterações do que a rede treinada pelo algoritmo da retropropagação do erro e, além disso, se mostrou mais eficaz e estável.

Um estudo comparativo foi realizado entre quatro construções distintas de Redes Neurais Autorregressivas com Referência Móvel, que são novas redes com capacidade preditiva (RATHER, 2012). As construções foram: rede de três camadas com alimentação direta, Perceptron multicamada, rede de 3 camadas escondidas paralelas e rede recorrente. Utilizando 6 ações negociadas em bolsa e 5 ordens de regressão (2,3,4,5 e 6), o estudo avaliou o desempenho preditivo de cada rede, bem como a precisão dos resultados. Segundo os dados experimentais, todas as redes apresentaram o Erro Quadrático Médio (EQM) abaixo de 0,004, havendo uma variação máxima de 32% entre os EQM calculados, o que demonstra a alta capacidade preditiva das Redes Neurais Autorregressivas com Referência Móvel. Os melhores resultados foram obtidos com a ordem de regressão igual a 4.

Um MPC multivariável baseado em uma rede neural foi usado como modelo interno do controlador para controlar uma planta de craqueamento analítico em leito fluido, que representava um processo de refino de petróleo com características altamente não lineares. O controlador apresentou resultados satisfatórios mesmo quando o processo foi submetido a ruídos externos nas variáveis controladas, comprovando sua robustez quando aplicado a processos não lineares. (VIEIRA, 2002)


2.4. Controle Fuzzy

Dentre as várias estratégias de controle existentes, o controle fuzzy se destaca por conseguir tratar problemas que apresentam não linearidades, sem que para isso seja necessário realizar a exata modelagem matemática do sistema (CARULO, 2008). Apesar disso, a falta do modelo matemático não traz nenhuma imprecisão na realização do controle (SHAW; SIMÕES, 2007).

Os controladores fuzzy são capazes de tomar decisões baseados nos graus de pertinência das variáveis de entrada. Isto é possível porque existe um processamento das informações de entrada disponíveis para o sistema, que são confrontadas com uma base de conhecimento previamente determinada. Esta base de conhecimento representa todo o conhecimento disponível sobre o processo em que atuará o controlador fuzzy, desta forma, ela pode ser formada pela experiência de um especialista do processo em questão. Este processamento das informações disponíveis para o sistema fuzzy é chamado de processo de inferência.

Na figura 2.6 é apresentado um fluxograma que mostra como se relacionam as etapas de inferência fuzzy. Neste processo ocorre o mapeamento de uma ou mais entradas para uma ou mais saídas, através da lógica fuzzy. Inicialmente, ocorre a chamada fuzzificação das entradas, em que valores crisp são transformados em funções de pertinência fuzzy (mais detalhes sobre esse processo podem ser encontrados no Apêndice B), usando para isso a base de dados que contém os conjuntos fuzzy previamente definidos. Assim, se torna possível utilizar a base de regras para determinar quais e com qual intensidade as variáveis linguísticas de entrada irão se relacionar com as variáveis linguísticas de saída. Este processo é feito através da implicação e da agregação, que é o sistema de inferência propriamente dito. Por fim, após se obter a função de saída, ocorre o processo de defuzzificação, em que funções de pertinência são transformadas em valores crisp, que são as saídas do controlador fuzzy (SIVANANDAM; SUMATHI; DEEPA, 2007).

Figura 2. 6- Etapas do sistema de inferência de um controlador fuzzy



(Fonte: adaptado de KOVACS, 2010)

Em 2008, desenvolveu-se um controlador fuzzy aplicado ao processo de produção de biodiesel, uma vez que o exato controle da temperatura do processo influencia diretamente na taxa de produção de biodiesel (CARULO, 2008). Além do controlador fuzzy, foi utilizado um controlador do tipo PID, que também é capaz de fornecer um controle ótimo a um sistema, desde que se possua sua exata modelagem matemática. Neste caso, apesar de ambos os controladores se mostrarem aptos a realizar adequadamente o controle, aquele utilizando a lógica fuzzy se mostrou mais eficiente, apresentando uma redução de 10% no consumo de energia elétrica e uma redução de 15 minutos na duração do processo, quando comparado com o controlador PID.

Em 2007, um estudo comparativo entre controladores dos tipos PID e fuzzy foi desenvolvido para um sistema de refrigeração (FILETI et al., 2007). Apesar de todos serem capazes de realizar o controle de maneira adequada, o controlador fuzzy

apresentou uma redução de 14% no consumo de energia elétrica, tendo em vista a maior precisão obtida no controle.

No ano de 2009, um sistema fuzzy foi desenvolvido e implementado para controlar a temperatura ambiente de uma incubadora para ovos (ROMANINI, 2009). Tendo como parâmetro desejado a temperatura dos ovos, o sistema fuzzy foi capaz de controlar a temperatura da incubadora de forma eficiente, apesar de se tratar de um sistema não linear, uma vez que a massa dos ovos, a produção de calor embrionária, a interação entre cada ovo e o ambiente são parâmetros que dificultam o controle.

Em 2003, implementou-se um controlador fuzzy para atuar em um processo industrial de fresagem (HABER et al., 2003). Tal processo é caracterizado por seu aspecto não linear e com grande variação nos parâmetros do processo. O sistema fuzzy desenvolvido foi eficaz no controle do processo de fresagem, apresentando ainda capacidade de sincronização com os sinais produzidos pelo Controle Numérico Computadorizado (CNC), responsável por atuar no processo. O uso do controlador fuzzy proporcionou uma redução de 10% no tempo de processo e uma economia de até 78% em custos, quando comparado com o mesmo processo sem o uso de qualquer controlador.


CAPÍTULO 3- MATERIAIS E MÉTODOS

Neste capítulo são apresentadas as configurações utilizadas para a criação dos controladores bem como a modelagem matemática do processo de controle de nível de líquido em um tanque. O software MATLAB, no seu ambiente de simulações Simulink, foi utilizado para modelar o processo e realizar as avaliações comparativas.

3.1. Modelagem do processo de controle de nível

Um processo de controle de nível consiste em um tanque, que é usado como reservatório para o líquido, de forma que ele recebe uma quantidade de líquido controlada através de uma válvula de controle de nível. O fluxo saída do reservatório de líquido não é controlado e varia conforme a altura do nível de líquido no tanque. A figura 3.1 ilustra o processo considerado, tomando como exemplo de líquido a água:


Figura 3. 1- Desenho esquemático de um processo de controle de nível de água em um tanque



A fim de modelar o processo, utiliza-se o desenho esquemático apresentado pela figura 3.2. Nele, o fluxo de entrada é representado por f_e , enquanto o fluxo de saída é dado por f_s , apresentado pela equação 3.1. Considerando que o fluxo de saída é drenado exclusivamente pela ação da gravidade, é possível estimar f_s , em que a é

a área da secção transversal do furo de saída, h é a altura do fluido no tanque e v_s é a velocidade de saída do fluido.

Figura 3. 2- Desenho esquemático do fluxo de líquido em um tanque cilíndrico



$$f_s = a v_s \quad (3.1)$$

Uma vez que o fluido é drenado exclusivamente pela ação da gravidade e desconsiderando os efeitos da fricção e da viscosidade, pode-se aplicar a equação de Bernoulli conforme a equação 3.2 (POTTER; WIGGERT, 2004):

$$\frac{v_e^2}{2} + \frac{p_1}{\rho} + gh_1 = \frac{v_s^2}{2} + \frac{p_2}{\rho} + gh_2 \quad (3.2)$$

Como a variação de pressão durante o escoamento é praticamente inexistente, a altura h_2 do tubo de saída é zero e a velocidade de entrada é muito pequena quando comparada com a velocidade de saída, tem-se a expressão apresentada equação 3.3:

$$v_s = \sqrt{2gh} \quad (3.3)$$

Portanto, o fluxo de saída varia de maneira não linear com a altura do fluido no tanque, conforme apresentado pela equação 3.4

$$f_s = a \sqrt{2gh} \quad (3.4)$$

Como a variação de volume no tanque depende apenas da variação da altura do fluido (uma vez que a área da secção transversal do tanque, A , é constante), tem-se a relação mostrada pela equação 3.5:

$$A \frac{dh}{dt} = f_e - f_s \quad (3.5)$$


Portanto, pode-se definir o fluxo de entrada em função da altura de fluido no tanque conforme a equação 3.6:

$$f_e = A \frac{dh}{dt} + a \sqrt{2gh} \quad (3.6)$$

Desta forma, o controlador é capaz de atuar no fluxo de entrada do tanque de forma a controlar a altura de fluido estipulada pelo valor do *setpoint* a cada instante de tempo.

O modelo da válvula considerado foi o direcional proporcional. Este tipo de válvula apresenta uma saturação conforme apresentado na figura 3.3:


Figura 3. 3- Comportamento da vazão pela ação de controle de uma válvula proporcional real



(Fonte: CARMO, 2003)


A figura 3.4 apresenta a curva da vazão utilizada para a válvula de controle do processo. Apesar de esta curva abranger valores positivos e negativos para a vazão, conforme a figura 3.3 sugere, é possível observar que os valores de fluxo negativo não são aplicados na prática, de forma que apenas indicam que a válvula está totalmente fechada.

Figura 3. 4- Curva de vazão da válvula proporcional utilizada no processo de controle de nível



O modelo do processo é mostrado na figura 3.5, em que é possível verificar o modelo da válvula que é controlada pelo controlador, bem como o modelo do tanque. As variáveis do processo são: altura do tanque (m), área da base do tanque (m^2), área da circunferência do cano de saída da água (m^2), vazão máxima de entrada da válvula controlada (m^3/s) e nível inicial de água no tanque (m).

Figura 3. 5- Diagrama de blocos do processo de nível de líquido



É possível verificar que existe um atraso de transporte de meio segundo associado à válvula proporcional. Isto faz com que a dinâmica da válvula seja próxima da dinâmica de uma válvula real, em que existe um atraso até que a válvula responda ao sinal do controlador. O fluxo máximo da válvula é definido através de um valor constante durante as simulações. Assim, a tabela 3.1 mostra os valores utilizados para

o processo de controle de nível, definidos de forma que o tanque tivesse um volume de 10.000 litros.

Tabela 3. 1- Valores dos parâmetros utilizados para o processo de controle de nível

Parâmetro	Valor
Altura do tanque	5m
Área da base do tanque	2m ²
Área da circunferência de saída	0,1m ²
Vazão máxima de entrada	1m ³ /s
Nível inicial do tanque	0,5m


3.2. Controlador PID

O controlador PID paralelo foi sintonizado utilizando o ajuste manual, de forma que os parâmetros foram variados conforme o efeito desejado no controle do processo. Inicialmente, o parâmetro proporcional foi aumentado até que a saída fosse oscilatória. Feito isso, o ganho integral foi aumentado de forma que o erro estacionário fosse eliminado, o que elevou o sobressinal da saída. Por fim, o parâmetro derivativo foi aumentado de forma a reduzir o sobressinal. A figura 3.6 mostra a resposta do controlador a uma entrada degrau unitário, quando o estado inicial do nível é 0,5m. A tabela 3.2 mostra os valores adotados para o PID.

Tabela 3. 2- Valores dos parâmetros do controlador PID paralelo

Parâmetro	Valor
Proporcional	3
Integral	2
Derivativo	4


Figura 3. 6- Curva de resposta da planta utilizando o controlador PID a uma entrada degrau unitário, com estado inicial em 0,5m



Deve-se ressaltar que o ajuste do controlador PID foi realizado de forma que ele tivesse um comportamento afastado dos extremos de calibragem (excessivamente amortecido ou excessivamente oscilatório), o que iria gerar um desempenho insatisfatório para o controlador PID, visto que os critérios de avaliação consideram o tempo de acomodação e o erro estacionário do processo controlado.

A figura 3.7 mostra o modelo utilizado para a malha de controle utilizando o PID.

Figura 3. 7- Simulação da malha de controle do controlador PID



3.3. Controlador Fuzzy

O controlador fuzzy foi criado de duas maneiras distintas, apresentando uma ou duas entradas. Isso foi feito devido ao fato de o controlador fuzzy de uma entrada poder apresentar uma resposta muito oscilatória, uma vez que ele se baseia apenas no valor do erro do sistema como variável de entrada. Assim, um segundo controlador fuzzy foi criado, utilizando a taxa de variação da primeira variável como segunda entrada, fazendo com que o controlador conseguisse realizar um ajuste fino no controle. No entanto, uma vez que todos os outros controladores utilizaram apenas uma entrada, o controlador fuzzy de uma entrada foi mantido na avaliação comparativa.

O controlador fuzzy do tipo Mamdani de uma entrada utiliza o erro entre o sinal de referência e o sinal de saída da planta como entrada. Assim, quando o erro é positivo, sabe-se que o nível de água no tanque está abaixo do desejado. Quando o erro é negativo, o nível de água está acima da referência. As figuras 3.8 e 3.9 mostram as funções de pertinência da entrada Nível e da saída Válvula, respectivamente:

Figura 3. 8- Funções de pertinência da variável de entrada Nível





Figura 3. 9- Funções de pertinência da variável de saída Válvula

Utilizou-se a tabela de regras de forma a relacionar entradas e saídas, conforme a tabela 3.3. Essas regras expressam o conhecimento acerca do funcionamento do processo de controle de nível, relacionando o erro do nível com a abertura ou fechamento da válvula proporcional.


Tabela 3. 3- Regras que relacionam entrada e saída do controlador fuzzy de uma entrada

Nº da Regra	Variável de Entrada	
	Nível	Válvula
1	bom	zero_var
2	alto	fechar_r
3	m_alto	fechar_d
4	p_alto	fechar_md
5	baixo	abrir_r
6	m_baixo	abrir_d
7	p_baixo	abrir_md

Utilizou-se o método de inferência de Mamdani (detalhado no Apêndice B), uma vez que tal método se mostrou eficaz quando aplicado no controle de processos

(ARAS, 2011), além de ser o método mais utilizado (SIVANANDAM; SUMATHI; DEEPA, 2007). O método de defuzzificação escolhido foi o do centroide ou centro de massa, uma vez que ele representa melhor a função de pertinência de saída do controlador, conforme observado anteriormente. Assim, considerando o método de inferência fuzzy, foi possível obter a região de controle apresentada pela figura 3.10:


Figura 3. 10- Gráfico de controle do controlador fuzzy de uma entrada



O gráfico de controle mostra que o acionamento da válvula é pequeno quando o erro entre a referência e o nível atual é próximo de zero. Porém, a medida que o erro aumenta (o que acontece com a mudança do setpoint), a válvula pode ser aberta ou fechada de acordo com o fluxo desejado. Além disso, verifica-se que a saída assume também valores negativos, apesar de o número 0 já significar a válvula fechada. Isto acontece para que a defuzzificação pelo centro de massa seja capaz de produzir uma saída de valor zero, que não aconteceria se o intervalo da variável de saída fosse apenas positivo. Ainda, o uso de valores negativos permite que a válvula seja fechada mais rapidamente, no caso de o nível estar muito acima da referência.

A figura 3.11 mostra o modelo utilizado para a malha de controle utilizando o controlador fuzzy de uma entrada.

Figura 3. 11- Simulação da malha de controle do controlador fuzzy de uma entrada



O segundo controlador fuzzy também utiliza o erro entre a referência e a saída da planta como entrada, no entanto, ele utiliza derivada deste erro como segunda entrada, de forma a considerar a variação do erro para controlar a válvula. Esta modificação permite que o controlador responda de maneira mais eficiente, uma vez que a taxa de variação do erro dá a ele uma leitura de para onde o erro deverá caminhar nos instantes futuros. As figuras 3.12, 3.13 e 3.14 mostram as funções de pertinência das entradas e da saída, respectivamente:

Figura 3. 12- Funções de pertinência da variável de entrada Nível




Figura 3. 13- Funções de pertinência da variável de entrada Variação





Figura 3. 14- Funções de pertinência da variável de saída Válvula




A tabela 3.4 relaciona as entradas com uma saída. É possível verificar que quando o nível é alto ou baixo e, portanto, o erro é grande, a abertura ou fechamento da válvula são máximos, independentemente do valor da variação do erro. Em todos os outros casos, o controlador leva em consideração a variação do erro para enviar o sinal de controle.

Tabela 3. 4- Regras que relacionam entradas e saída do controlador fuzzy de duas entradas

Nº da Regra	Variáveis de Entrada		Variável de Saída
	Nível	Variação	Válvula
1	bom	nula	zero_var
2	bom	negativa	abrir_d
3	bom	positiva	fechar_d
4	m_alto	positiva	fechar_r
5	m_alto	negativa	fechar_m
6	m_baixo	negativa	abrir_r
7	m_baixo	positiva	abrir_m
8	baixo	-	abrir_r
9	alto	-	fechar_r


A figura 3.15 mostra a superfície de controle deste controlador. Conforme esperado, quando o erro é grande, a atuação na válvula é máxima. Ainda, é possível observar que esta superfície é muito mais completa em relação à curva de controle do controlador fuzzy com apenas uma entrada, de forma que as variações no sinal de controle são menos lineares.

Figura 3. 15- Superfície de controle do controlador fuzzy de duas entradas



A figura 3.16 apresenta o modelo utilizado para as simulações com a malha de controle do controlador fuzzy de duas entradas.

Figura 3. 16- Simulação da malha de controle do controlador fuzzy de duas entradas



3.4. Controlador Preditivo Baseado em Modelo

O modelo da planta utilizado no controlador preditivo baseado em modelo foi obtido utilizando a ferramenta de identificação de sistemas do software Matlab, aproximando-o através de uma função no espaço de estados. Além disso, o MPC foi configurado para utilizar um horizonte de predição de 10 intervalos e o horizonte de controle de 2 intervalos. Estes parâmetros foram escolhidos com base nos testes realizados com o controlador no processo modelado, de forma que a melhor resposta

obtida se deu com os parâmetros descritos. As equações 3.7 e 3.8 mostram a aproximação, em tempo contínuo, da planta feita pelo software MATLAB.

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 1 & -0,1565 \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0,5 \\ 0 \end{bmatrix} \cdot u \quad (3.7)$$

$$y = [0 \ 0,5] \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (3.8)$$

Uma vez feita a linearização do modelo, foi possível configurar as restrições para o controlador MPC, de forma que ele possa operar obedecendo os limites das variáveis manipulada e controlada. Assim, o fluxo máximo de entrada no tanque foi limitado a 1m³/s e o nível máximo do tanque foi definido em 3,5m. Feito isso, realizou-se uma simulação de cenário para avaliar a eficiência do controlador. Na figura 3.17, pode-se verificar a resposta do MPC a uma entrada degrau unitário. Deve-se observar que a entrada degrau utilizada se assemelha a um sinal degrau real, o que significa que a mudança de patamar leva algum tempo para ocorrer. A figura 3.18 mostra o sinal de controle utilizado pelo controlador quando o tanque apresentava um nível inicial de 0,5m:

Figura 3. 17- Gráfico de resposta do controlador MPC mediante uma entrada degrau unitário real






Figura 3. 18- Gráfico do sinal de controle do controlador MPC quando submetido a uma entrada degrau unitário real



É possível verificar que as restrições foram atendidas. Neste caso, o fluxo máximo foi de $1\text{ m}^3/\text{s}$ logo após o degrau ter sido aplicado em 1s. A medida que a saída se aproximou da referência, o fluxo foi sendo diminuído, até que a válvula se fechou, em 3s. Após este tempo, o controle realizou o ajuste fino, de forma a reduzir o erro estacionário. Em 10s, o erro já era menor do que 2% do valor de referência. Percebe-se ainda que o sinal de controle pode assumir valores negativos, porém, a válvula já está fechada quando o fluxo é zero. Além disso, observa-se que a entrada degrau não é ideal, apresentando uma característica de rampa, como acontece na realidade.

Na figura 3.19, tem-se a saída da planta quando aplicada uma entrada degrau de valor 4, para a mesma situação. É possível verificar que a restrição de nível máximo foi atendida, de forma que a referência de 5,5m não pode ser alcançada, uma vez que o nível máximo foi definido para 5m.


Figura 3. 19- Gráfico de resposta do controlador MPC quando submetido a uma entrada degrau de amplitude cinco



A fim de tentar melhorar a resposta do controlador MPC, realizou-se alterações nos parâmetros de ajuste de peso (*Weight Tuning*) e no ganho geral do estimador (*Overall estimator gain*). No entanto, as alterações destes parâmetros não tiveram influência significativa na resposta da planta mediante a entrada degrau.

A figura 3.20 apresenta a simulação utilizada para a malha de controle do controlador MPC.

Figura 3. 20- Simulação da malha de controle do controlador MPC



3.5. Controlador Preditivo Neural

O controlador neural preditivo foi criado através da ferramenta *Neural Network Predictive Controller* do Simulink. Ele foi configurado com um horizonte de predição de 10 intervalos e horizonte de controle de 2 intervalos, assim como no MPC.

Após a configuração inicial do controlador, realizou-se vários ensaios variando os parâmetros da rede neural e avaliando o Erro Quadrático Médio, Regressão Linear e *Overfitting* (mais detalhes sobre essas métricas podem ser encontrados no Apêndice A), a fim de encontrar a melhor configuração dentre todos os ensaios realizados. Feito isso, optou-se por utilizar 20 neurônios na camada escondida e um atraso de 2 amostras para a entrada e a saída da rede, a uma taxa de amostragem de 0,5 segundo. Assim como no MPC, definiu-se as restrições do treinamento da rede neural para um fluxo máximo de entrada de $1\text{m}^3/\text{s}$ e o nível máximo do tanque para 5m. A tabela 3.5 mostra os parâmetros de configuração do treinamento da rede neural:

Tabela 3. 5- Parâmetros de configuração utilizados para o treinamento da rede neural


Parâmetro	Valor
Neurônios da camada escondida	20
Número de entradas e saídas atrasadas	2
Intervalo de amostragem (s)	0,5
Número de amostras para o treinamento	5.000
Máxima entrada da planta (m^3/s)	1
Mínima entrada da planta (m^3/s)	-1
Máxima saída da planta (m)	5
Mínima saída da planta (m)	0
Épocas de treinamento	40

Após o treinamento, foi possível verificar que as restrições foram atendidas. Então, a rede neural foi treinada com os dados obtidos da planta. Para o treinamento, utilizou-se o algoritmo de Levenberg-Marquardt e um máximo de 40 épocas de

treinamento (mais detalhes sobre o treinamento de uma rede neural e sobre o método de treinamento podem ser encontrados no Apêndice A). Foi possível observar que o erro entre a resposta da rede neural e da planta gira em torno de 1%, o que é considerado suficiente para a realização do controle.

A figura 3.21 apresenta a simulação utilizada para a malha de controle do controlador preditivo neural.

Figura 3. 21- Simulação da malha de controle do controlador preditivo neural



3.6. Critérios de Avaliação

Com o intuito de comparar os diferentes métodos de controle, foram estipulados cinco critérios de avaliação. Eles foram escolhidos de forma que possam avaliar os diferentes aspectos de cada controlador e poder quantificar as respostas de cada controlador mediante um sinal de referência único. Os critérios utilizados foram:

ISE (Integral Square Error): Este método calcula a integral do quadrado do erro medido entre a saída e o setpoint, durante todo o intervalo T considerado. Este método discrimina sistemas excessivamente amortecidos dos subamortecidos, dando um grande peso aos erros grandes e pequeno peso aos erros pequenos. A expressão do ISE é mostrada pela equação 3.9:

$$ISE = \int_0^T e^2(t)dt \quad (3.9)$$


ITSE (Integral of Time multiplied by Square Error): Da mesma forma que o ISE, este método utiliza o erro quadrático. No entanto, a integral é calculada com o tempo multiplicando o quadrado do erro, de forma que se dá grande importância aos erros

que acontecem tarde na resposta do controlador. A equação 3.10 mostra a expressão do ITSE:

$$ITSE = \int_0^T t \cdot e^2(t) dt \quad (3.10)$$

A figura 3.22 mostra a implementação dos critérios ISE e ITSE utilizados para realizar as comparações entre os controladores. No caso da figura, a malha é do controlador PID, no entanto, a mesma implementação foi utilizada para todos os controladores.

Figura 3. 22- Implementação dos critérios de avaliação ISE e ITSE para a malha de controle do controlador PID



Erro estacionário: O erro estacionário é a diferença entre a resposta estacionária do controlador e o *setpoint* desejado. Idealmente, o controlador deveria ser capaz de tornar o erro estacionário zero. No entanto, projetos reais de controle especificam um valor máximo para o valor do erro estacionário, de forma que atenda adequadamente as necessidades de cada projeto.


Sobressinal: O sobressinal da resposta de cada controlador será medido como uma porcentagem do valor estacionário. Ele é medido a partir do valor de pico ou vale mais distante do valor estacionário final (OGATA, 2011). Como a maioria dos problemas reais de controle especificam um sobressinal máximo, avaliar esse parâmetro é muito importante para comparar os controladores. O sobressinal é expresso de acordo com a equação 3.11, em que $y_{máx}$ é o valor mais distante da resposta ao valor estacionário y_e :

$$M_p = \frac{(y_{m\acute{a}x} - y_e)}{y_e} \cdot 100\% \quad (3.11)$$

A figura 3.23 mostra um gráfico típico da resposta de um sistema subamortecido quando submetido a uma entrada degrau unitário e apresenta graficamente o conceito de sobressinal.

Tempo de acomodação: O tempo de acomodação é definido como o tempo necessário para que o sinal de resposta atinja e permaneça dentro de uma faixa de 5% do valor estacionário (OGATA, 2011). A figura 3.23 apresenta graficamente o tempo de acomodação (t_s) da resposta de um sistema subamortecido submetido a uma entrada degrau unitário.

Figura 3. 23- Gráfico de resposta de um sistema subamortecido quando submetido a uma entrada do tipo degrau unitário



Considerando todos os critérios apresentados, deve-se ressaltar que o mais importante em um projeto de controle é que os controladores atendam às especificações de sobressinal, tempo de acomodação e erro estacionário. Uma vez que esses parâmetros são atingidos, outros critérios de avaliação são considerados, como os índices de desempenho. Desta forma, os três parâmetros apresentados são mais relevantes na escolha do controlador do que os índices de desempenho.

CAPÍTULO 4- RESULTADOS E DISCUSSÃO


Neste capítulo são apresentados os resultados obtidos utilizando os quatro métodos de controle abordados neste trabalho, com o intuito de conduzir uma avaliação comparativa dos métodos avançados com o controlador PID, além de comparar os métodos entre si. Para isso, foram utilizados diferentes tipos de entradas e cenários em cada um dos experimentos. Sinais ruidosos também foram utilizados a fim de avaliar a robustez de cada controlador. Ao final, será apresentada uma discussão em que se avalia os pontos fortes e fracos de cada método aplicado no controle do processo considerado.

4.1. Resposta do sistema mediante uma entrada degrau ideal

Inicialmente, foi utilizado um sinal composto de três patamares distintos, sendo que a transição entre eles é realizada através de uma função degrau ideal, ou seja, que não considera nenhum atraso na mudança de patamar ou ruídos durante a aplicação do sinal.


A figura 4.1 mostra o sinal utilizado para a simulação do primeiro cenário. Considerando um nível inicial de 0,5m, o nível desejado é definido para 2m, 3,2m e 1m. Cada nível é alterado após 120s, de forma que todos os controladores possam atingir um estado de equilíbrio para a saída.

Figura 4. 1- Sinal de referência degrau ideal para o nível de líquido no tanque




A figura 4.2 mostra o resultado do controle utilizando o sinal do primeiro cenário no controlador PID com os parâmetros apresentados na tabela 3.2. Pode-se observar que o controlador é capaz de realizar o controle para os três patamares, apresentando sempre um sobressinal elevado, da ordem de 39%, e um erro estacionário baixo, da ordem de 3%.

Figura 4. 2- Controle de nível do controlador PID para a referência degrau ideal




A figura 4.3 apresenta o resultado de controle para o primeiro cenário utilizando o controlador MPC parametrizado conforme apresentado no capítulo 3, item 4. Da mesma forma, o controlador foi capaz de realizar o controle, atingindo um erro estacionário nulo para todos os patamares. O controlador apresentou um sobressinal máximo de 21,5% e erro estacionário nulo para todos os patamares.

Figura 4. 3- Controle de nível do controlador MPC para a referência degrau ideal




A figura 4.4 apresenta a resposta do controlador neural preditivo mediante o mesmo sinal de entrada. Pode-se observar que em determinado patamar de referência, o controlador não foi capaz de realizar o controle, de forma que o sistema se tornou instável. O sobressinal máximo foi de 80% e o erro estacionário médio foi próximo de 9%, nos casos em que o controlador conseguiu estabilizar o sistema. Além de não ser capaz de controlar o sistema em todos os patamares, o controlador preditivo neural apresentou uma resposta excessivamente oscilatória.

Figura 4. 4- Controle de nível do controlador Preditivo Neural para a referência degrau ideal




A figura 4.5 apresenta os resultados obtidos para o controlador Fuzzy de uma entrada. Foi observado que o controlador foi incapaz de realizar o controle, tornando o sistema indefinidamente oscilatório. O sobressinal observado foi da ordem de 20% para este primeiro cenário. O erro estacionário observado tem a mesma amplitude do sobressinal, uma vez que a resposta é oscilatória.

Figura 4. 5- Controle de nível do controlador Fuzzy de uma entrada para a referência degrau ideal




A figura 4.6 apresenta os resultados obtidos para o controlador Fuzzy de duas entradas. O resultado observado foi que este controlador foi capaz de realizar o controle, sendo que a resposta obtida teve o caráter oscilatório eliminado, devido ao uso da variação do erro como segunda entrada para o controlador. Assim, o sobressinal máximo foi de 15,5% e o erro estacionário médio foi próximo de 2%.

Figura 4. 6- Controle de nível do controlador Fuzzy de duas entradas para a referência degrau ideal



A figura 4.7 apresenta as curvas de resposta de todos os controladores juntos, para que seja possível realizar uma comparação a respeito da forma das respostas obtidas. Pode-se observar que apesar de todos os controladores terem sido capazes de realizar o controle do processo para o cenário proposto, as formas das respostas obtidas são bastante distintas.

Figura 4. 7- Controle de nível de todos os controladores para a referência degrau ideal




A Tabela 4.1 apresenta os valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores. Os controladores que não foram capazes de controlar o processo em algum patamar de referência apresentam um tempo de acomodação indefinido.

Tabela 4. 1- Comparação dos valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores para a entrada degrau ideal

Controlador	Sobressinal máximo	Tempo de acomodação máximo (s)	Erro estacionário máximo
PID	39,3%	83	3,5%
MPC	21,5%	48	0%
RNA	80,0%	-	17,3%
Fuzzy 1	20,6%	-	20,6%
Fuzzy 2	15,5%	62	2,0%

O fato de as formas das respostas dos controladores serem bastante distintas entre si é relevante quando se considera a atuação da válvula proporcional utilizada, de forma que uma resposta mais oscilatória exige atuações rápidas na válvula, demandando um esforço mecânico maior. A figura 4.8 apresenta o gráfico da ação de controle de todos os controladores na válvula proporcional.

Figura 4. 8- Ação de controle de todos os controladores para a referência degrau ideal



As figuras 4.9, 4.10 e 4.11 apresentam ampliações do gráfico de ação de controle intervaladas de 120 segundos, de forma que é possível comparar as ações de controle de todos os controladores para cada patamar de referência do sinal degrau ideal.

Figura 4. 9- Ação de controle de todos os controladores para a referência degrau ideal entre 0 e 120 segundos




Figura 4. 10- Ação de controle de todos os controladores para a referência degrau ideal entre 120 e 240 segundos





Figura 4. 11- Ação de controle de todos os controladores para a referência degrau ideal entre 240 e 360 segundos




Pode-se concluir da figura 4.8 que os controladores Fuzzy de uma entrada e neural preditivo foram os que produziram as maiores e mais bruscas variações (acima de $0,2\text{m}^3/\text{s}^2$) na válvula proporcional, de forma que o fluxo de líquido através da válvula foi oscilatório mesmo após os primeiros 20 segundos após a mudança de patamar, que é um intervalo de tempo em que grandes variações de fluxo são esperadas devido ao degrau. O controlador PID apresentou uma variação elevada no fluxo de líquido mesmo após 20 segundos da mudança de patamar de referência, sendo que após este primeiro instante as oscilações no fluxo foram realizadas de maneira mais suave, sem apresentar oscilações bruscas acima de $0,2\text{m}^3/\text{s}^2$. Os controladores MPC e Fuzzy de duas entradas foram os que exigiram menos mecanicamente da válvula, apresentando uma variação de fluxo suave durante todo o cenário considerado.

A figura 4.12 apresenta o gráfico do ISE durante todo o tempo do sinal de aplicação do sinal de referência do primeiro cenário. Pode-se observar que os controladores Fuzzy de uma entrada e Preditivo Neural apresentaram os maiores índices ISE, seguidos pelos controladores PID, MPC e Fuzzy de duas entradas. Desta forma, fica evidente que os controladores Fuzzy de uma entrada e Preditivo Neural


foram penalizados nos patamares em que não foram capazes de estabilizar o processo.

Figura 4. 12- Índice de desempenho ISE de todos os controladores para a referência degrau ideal



A figura 4.13 apresenta o gráfico do ITSE para cada controlador ao longo da aplicação do sinal de referência. De maneira análoga ao gráfico do ISE, os controladores Fuzzy de uma entrada e Preditivo Neural foram os mais penalizados devido às mesmas razões descritas anteriormente para a análise do ISE.

Figura 4. 13- Índice de desempenho ITSE de todos os controladores para a referência degrau ideal




Com base nos dados da Tabela 4.1 e os gráficos dos índices de desempenho, pode-se observar que o controlador Fuzzy de duas entradas apresentou os melhores resultados, quando comparado com os demais controladores. Os resultados de sobressinal, tempo de acomodação e erro estacionário apresentados foram muito satisfatórios quando comparados com os demais controladores. Em seguida, o controlador MPC se destacou pelo erro estacionário nulo em todos os patamares de controle, além dos bons índices de desempenhos, quando comparados com os outros controladores. O controlador PID foi capaz de realizar o controle em todos os patamares, porém, apresentou um elevado tempo de acomodação, bem como sobressinal elevado e oscilações excessivas. Por fim, os controladores Fuzzy de uma entrada e Preditivo Neural não foram capazes de realizar adequadamente o controle em todos os patamares estabelecidos.

A fim de avaliar o comportamento dos controladores nos extremos da faixa de operação do processo, utilizou-se o sinal de referência mostrado pela figura 4.14. Neste segundo cenário, o nível inicial ainda é 0,5m, mas ele é alterado para 5m logo no primeiro instante de simulação. Após 120s, o tanque é totalmente esvaziado. Passados mais 120s, o nível é colocado em 2,5m. Desta forma, foi possível avaliar a


capacidade de cada controlador de atuar nos extremos do nível do tanque e voltar para uma posição intermediária.

Figura 4. 14- Sinal de referência degrau ideal do nível de líquido no tanque nos limites de operação do processo



Uma vez que nesse segundo cenário os níveis extremos são considerados, pode-se observar que as respostas dos controladores não apresentam nenhum sobressinal após atingirem os patamares de 5m e 0m. No nível intermediário de 2,5m, as características de resposta de cada controlador se mantém as mesmas observadas para o cenário apresentado anteriormente. A figura 4.15 apresenta a resposta de todos os controladores para este segundo cenário.


Figura 4. 15- Controle de nível de todos os controladores para a referência degrau ideal nos limites de operação do processo



Pode-se observar que as curvas de resposta dos controladores são similares entre si quando o nível é posto em um dos extremos, com exceção do controlador PID, que apresentou erro estacionário após 150s de simulação. Ainda, pode-se observar que o controlador Preditivo Neural apresentou o maior tempo de resposta para atingir os patamares extremos, apresentando um atraso próximo de 4 segundos em relação aos demais controladores.

A figura 4.16 ilustra o sinal de controle dos controladores para o segundo cenário considerado. Pode-se observar que as características do acionamento da válvula se mantêm similares aos apresentados anteriormente.

Figura 4. 16- Ação de controle de todos os controladores para a referência degrau ideal nos limites de operação do processo



A figura 4.17 e 4.18 apresentam os gráficos do ISE e do ITSE ao longo de todo o tempo de aplicação da referência do cenário de utilização dos limites do tanque. Pelas mesmas razões apresentadas no primeiro cenário de utilização normal, o controlador Fuzzy de uma entrada e Preditivo Neural foram os mais penalizados pelos índices de desempenho. Assim, fica evidente o atraso do controlador Preditivo Neural em relação aos demais. Além disso, o controlador MPC se destacou, apresentando os melhores índices de desempenho em todos os patamares de referência.

Figura 4. 17- Índice de desempenho ISE de todos os controladores para a referência degrau ideal nos limites de operação do processo






Figura 4. 18- Índice de desempenho ITSE de todos os controladores para a referência degrau ideal nos limites de operação do processo



4.2. Resposta do sistema mediante uma entrada degrau ruidosa


Tendo em vista que as aplicações reais estão sujeitas a ruídos decorrentes de interferências na rede elétrica ou de transmissão de dados pelas redes de comunicação, é necessário que se avalie o comportamento dos controladores diante de um sinal de referência ruidoso. Desta forma, utilizou-se a mesma forma para o sinal degrau, acrescido de um ruído branco. Isto fez com que o patamar de referência não mais fosse constante, mas sim ficasse oscilando em torno de determinado valor. A figura 4.19 apresenta o sinal utilizado.

Figura 4. 19- Sinal de referência degrau ruidoso do nível de líquido no tanque




O controlador PID, quando submetido à entrada degrau ruidoso apresentada, se comportou apresentando um elevado sobressinal de até 37,5% e um tempo de acomodação máximo de 97 segundos, conforme se observa na Figura 4.20. Apesar da entrada ruidosa, o controlador foi capaz de realizar o controle em todos os patamares considerados, apresentando erro estacionário máximo de 3,5%.

Figura 4. 20- Controle de nível do controlador PID para a referência degrau ruidoso




Conforme pode ser observado na Figura 4.21, o controlador MPC foi capaz de realizar o controle quando submetido à entrada degrau ruidoso. Foi constatado um sobressinal máximo de 22,5% e um tempo de acomodação máximo de 53 segundos. O erro estacionário máximo foi de 2%, diferentemente do erro estacionário do primeiro cenário, que foi nulo. Isso se deve ao fato de o sinal de referência estar constantemente oscilando, o que faz com que o controlador tente corrigir o sinal de controle a todo instante.

Figura 4. 21- Controle de nível do controlador MPC para a referência degrau ruidoso




A Figura 4.22 apresenta a resposta do controlador neural para a entrada degrau ruidoso. Da mesma forma que foi observado com o sinal degrau ideal, o controlador neural não foi capaz de estabilizar o sistema em todos os patamares considerados, de forma que durante 120 e 240 segundos, o sistema foi instável. O sobressinal máximo observado foi de 32,5% e o erro estacionário máximo, no caso em que o sistema foi estabilizado, foi de 8%.

Figura 4. 22- Controle de nível do controlador RNA para a referência degrau ruidoso




O controlador Fuzzy de uma entrada não foi capaz de estabilizar o sistema de maneira a eliminar o erro estacionário. Assim, o sistema permaneceu oscilando indefinidamente, conforme se observa na Figura 4.23. O sobressinal máximo foi de 35% e o erro estacionário foi da mesma magnitude, uma vez que as oscilações nunca diminuíram.

Figura 4. 23- Controle de nível do controlador Fuzzy de uma entrada para a referência degrau ruidoso




A resposta do controlador Fuzzy de duas entradas pode ser observado na Figura 4.24. Foi possível observar que o controlador foi capaz de realizar o controle do processo, apresentando um sobressinal máximo de 15%, um tempo de acomodação máximo de 39 segundos e erro estacionário máximo de 4,5%.

Figura 4. 24- Controle de nível do controlador Fuzzy de duas entradas para a referência degrau ruidoso



A figura 4.25 apresenta a resposta de todos os controladores para o cenário de referência degrau ruidoso. É possível observar a instabilidade do controlador Fuzzy de uma entrada em todos os patamares, enquanto os demais controladores realizam o controle adequadamente, com exceção do segundo patamar de controle para o controlador neural.

Figura 4. 25- Controle de nível de todos os controladores para a referência degrau ruidoso



A Tabela 4.2 apresenta os valores máximos do sobressinal, tempo de acomodação e erro estacionário para cada um dos controladores. Quando não indicado, o valor do erro estacionário máximo indica que o controlador não foi capaz de atingir o nível considerado de 5% do sinal de referência em todos os patamares de referência. Considerando os valores obtidos, foi possível observar que os controladores Fuzzy de duas entradas e MPC se sobressaíram em relação aos demais nos quesitos sobressinal máximo e tempo de acomodação máximo. Ainda, eles apresentaram um erro estacionário consideravelmente baixo, assim como o controlador PID.

Tabela 4. 2- Comparação dos valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores para a entrada degrau ruidoso

Controlador	Sobressinal máximo	Tempo de acomodação máximo (s)	Erro estacionário máximo
PID	37,5%	97	3,5%
MPC	22,5%	53	2%
RNA	32,5%	-	8%
Fuzzy 1	35%	-	35%
Fuzzy 2	15%	39	4,5%

As figuras 4.26, 4.27, 4.28 e 4.29 apresentam as curvas de acionamento da válvula dos controladores

Figura 4. 26- Ação de controle de todos os controladores para a referência degrau ruidoso de 0 a 360 segundos




Figura 4. 27- Ação de controle de todos os controladores para a referência degrau ruidoso entre 0 e 120 segundos




Figura 4. 28- Ação de controle de todos os controladores para a referência degrau ruidoso de 120 a 240 segundos





Figura 4. 29- Ação de controle de todos os controladores para a referência degrau ruidoso de 240 a 360 segundos



Analogamente ao que foi observado para o caso da referência degrau ideal, os controladores Fuzzy de uma entrada e Preditivo Neural apresentaram as maiores oscilações após os primeiros 20 segundos após a mudança do patamar de controle, o que indica maior esforço sobre a válvula por um tempo maior, quando comparado com os controladores MPC e PID, que apresentaram menores esforços na válvula. O controlador PID obteve um desempenho intermediário, realizando oscilações maiores sobre a válvula, mas de maneira mais branda, inferiores a $0,2\text{m}^3/\text{s}^2$. O controlador Fuzzy de duas entradas apresentou o mínimo esforço sobre a válvula, uma vez que sua principal variação ocorre antes dos 20 segundos após a mudança de patamar de referência, permanecendo com poucas variações após esse tempo.

As figuras 4.30 e 4.31 apresentam os índices de desempenho ISE e ITSE, respectivamente. Assim como no caso de referência degrau ideal, os controladores mais punidos foram aqueles que não foram capazes de realizar o controle em todos os patamares considerados: controlador Fuzzy de uma entrada e controlador neural. Os demais controladores apresentaram índices relativamente próximos, com destaque para o controlador Fuzzy de duas entradas, que apresentou os melhores índices de desempenho.

Figura 4. 30- Índice de desempenho ISE de todos os controladores para a referência degrau ruidoso






Figura 4. 31- Índice de desempenho ITSE de todos os controladores para a referência degrau ruidoso



4.3. Resposta do sistema mediante uma entrada rampa ideal

Em muitos processos é utilizada a uma entrada do tipo rampa como sinal de referência para o controlador. Além disso, na prática, um sinal de referência do tipo degrau se aproxima de um sinal do tipo rampa, uma vez que existe um tempo necessário para fazer o sinal sair de um patamar até outro, o que o sinal do tipo degrau ideal não leva em consideração. Assim, faz-se necessário avaliar os controladores mediante entradas do tipo rampa para que se possa tirar conclusões a respeito da utilização deles em uma aplicação real. Para isso, utilizou-se a referência mostrada na Figura 4.32.


Figura 4. 32- Sinal de referência rampa ideal do nível de líquido no tanque



Tendo em vista que o sistema apenas irá estabilizar após o sinal de referência se tornar constante, a avaliação de desempenho dos controladores foi realizada sempre após 50 segundos a partir do início da variação do sinal de referência. Após esse tempo, o sinal é constante.


A figura 4.33 apresenta a resposta do controlador PID mediante a entrada rampa. Pode-se observar que o controle foi realizado, de forma que o sistema é estabilizado em todos os patamares considerados. O sobressinal máximo medido foi de 5% em relação à referência já estabilizada. O tempo de acomodação máximo foi de 33 segundos e o erro estacionário para todos os casos foi nulo.

Figura 4. 33- Controle de nível do controlador PID para a referência rampa ideal




A figura 4.34 apresenta a curva de resposta do controlador MPC. Observa-se que o sobressinal máximo foi de 4%, o tempo de estabilização máximo foi de 23 segundos e o erro estacionário foi nulo para todos os patamares de referência. Assim, foi possível perceber que o controle foi realizado sempre muito próximo ao sinal de referência, tanto nos patamares variáveis quanto nos patamares constantes.

Figura 4. 34- Controle de nível do controlador MPC para a referência rampa ideal




A resposta do controlador preditivo neural é apresentada na figura 4.35. É possível observar que o sistema se tornou oscilatório após o segundo patamar de referência ser atingido. O sobressinal atingiu 17%, assim como o erro estacionário máximo no estado oscilatório da resposta. O tempo de acomodação máximo não foi medido, uma vez que o controlador não foi capaz de atingir os requisitos considerados para o estado de acomodação em todos os patamares.

Figura 4. 35- Controle de nível do controlador preditivo neural para a referência rampa ideal




A figura 4.36 apresenta a resposta do controlador Fuzzy de uma entrada para a referência rampa ideal. Assim como observado com as outras entradas, este controlador não foi capaz de tornar o sistema estável e minimizar o erro. Assim, a resposta oscilatória apresentou 35% de sobressinal, mesma magnitude do erro estacionário máximo.

Figura 4. 36- Controle de nível do controlador Fuzzy de uma entrada para a referência rampa ideal




O controlador Fuzzy de duas entradas foi capaz de estabilizar o processo para todos os patamares, conforme apresentado na Figura 4.37. O sobressinal máximo foi de 8% e o tempo de estabilização máximo foi de 41 segundos. O erro estacionário foi muito próximo de zero, alcançando 1,5% no pior caso.

Figura 4. 37- Controle de nível do controlador Fuzzy de duas entradas para a referência rampa ideal



A figura 4.38 apresenta a curva de resposta de todos os controladores para a referência rampa ideal.

Figura 4. 38- Controle de nível de todos os controladores para a referência rampa ideal



A tabela 4.3 apresenta os dados medidos de sobressinal, tempo de acomodação e erro estacionário máximos para cada controlador.

Tabela 4. 3- Comparação dos valores máximos do sobressinal, tempo de acomodação e erro estacionário de todos os controladores para a entrada rampa ideal

Controlador	Sobressinal máximo	Tempo de acomodação máximo (s)	Erro estacionário máximo
PID	5%	33	0%
MPC	4%	23	0%
RNA	17%	-	17%
Fuzzy 1	35%	-	35%
Fuzzy 2	8%	41	1,5%

As Figuras 4.39, 4.40, 4.41 e 4.42 apresentam os sinais de controle para a referência rampa ideal. Pode-se observar que os controladores Fuzzy de duas entradas e MPC foram os que demonstraram menor esforço na válvula de controle de fluxo, o que se reflete em um controle mais suave menos oscilatório. Os maiores esforços foram gerados pelos controladores que não foram capazes de realizar o controle e todos os patamares de referência: Fuzzy de uma entrada e RNA.

Figura 4. 39- Ação de controle de todos os controladores para a referência rampa ideal




Figura 4. 40- Ação de controle de todos os controladores para a referência rampa ideal




Figura 4. 41- Ação de controle de todos os controladores para a referência rampa ideal





Figura 4. 42- Ação de controle de todos os controladores para a referência rampa ideal



As Figuras 4.43 e 4.44 apresentam os índices de desempenho ISE e ITSE, respectivamente. Da mesma forma que nas outras referências, o controlador Fuzzy de uma entrada teve os piores índices de desempenho, devido ao elevado erro estacionário. O controlador preditivo neural também foi penalizado nos patamares em que não conseguiu minimizar o erro. O controlador de melhor desempenho foi o MPC, seguido do controlador PID. O controlador Fuzzy de duas entradas teve um desempenho intermediário, uma vez que o controle realizado por ele não foi tão próximo do sinal de referência nos instantes em que a rampa era aplicada.

Figura 4. 43- Índice de desempenho ISE de todos os controladores para a referência rampa ideal





Figura 4. 44- Índice de desempenho ITSE de todos os controladores para a referência rampa ideal



A fim de se avaliar a influência dos ruídos no desempenho dos controladores mediante a entrada do tipo rampa, realizou-se as simulações com o sinal rampa ruidosa. No entanto, assim como observado para a adição de ruídos no sinal degrau, os resultados de desempenho dos controladores para a rampa ruidosa não foram significativamente diferentes dos obtidos para as simulações com o sinal rampa ideal. Os gráficos desta simulação são apresentados no Apêndice C.

CAPÍTULO 5- CONCLUSÕES

Este trabalho apresentou um estudo comparativo entre os métodos de controle preditivos e/ou inteligentes mais utilizados atualmente: o Controle Preditivo Baseado em Modelo, Controle Preditivo Neural e Controle Fuzzy. A fim de comparar os resultados com um método de controle clássico amplamente utilizado, utilizou-se o Controle PID. As configurações de todos os controladores foram feitas de forma que os controladores preditivos utilizassem os mesmos horizontes de controle e predição. Ainda, o controlador neural escolhido foi selecionado com base em diversos ensaios realizados, de forma que o melhor deles foi utilizado na análise comparativa entre os controladores. A comparação entre os diferentes métodos de controle foi realizada considerando diversos cenários e entradas distintas, ideais e reais. Além disso, as características de sobressinal, tempo de acomodação e erro estacionário foram considerados na avaliação, além dos índices de desempenho ISE e ITSE. Por fim, ainda foi considerado o perfil de exigência de cada controlador na válvula proporcional de entrada de líquido no tanque, de forma que foi possível verificar qual dos controladores poderia causar mais desgastes na válvula em cada um dos cenários considerados.

Com base nos resultados obtidos, observou-se que o controlador Fuzzy de uma entrada foi incapaz de estabilizar o processo, de forma que não foi capaz de realizar o controle. De forma similar, o controlador preditivo neural apresentou respostas oscilatórias em alguns dos patamares de controle, de forma que em alguns casos não foi capaz de estabilizar o sistema. Considerando todos os cenários, os controladores MPC e Fuzzy de duas entradas apresentaram os melhores resultados em termos de estabilidade, sobressinal, tempo de acomodação e erro estacionário. Ainda, ambos apresentaram os melhores índices de desempenho nos cenários considerados. No entanto, apesar dos resultados similares, observou-se que o controlador Fuzzy de duas entradas apresentou melhor desempenho quando aplicada uma entrada degrau ruidoso, o que indica maior robustez em aplicações reais. No entanto, seu desempenho se mostrou abaixo do apresentado pelo controlador MPC no caso de uma entrada do tipo rampa com vários patamares de controle. Neste caso, observou-se que o controlador MPC obteve os melhores resultados para as variáveis de projeto e índices de desempenho. O controlador PID foi capaz de controlar o sistema em

todos os cenários, porém, sempre apresentou uma resposta muito oscilatória devido à natureza não linear do processo e da válvula de controle, o que resultou em índices de desempenho abaixo dos apresentados pelos controladores MPC e Fuzzy de duas entradas.

REFERÊNCIAS

ADÃO, A. A.; **Controle Preditivo – Aspectos Teóricos e de Implementação Prática**. 2011 97 f. Dissertação (Mestrado em Engenharia Elétrica) Universidade Federal do Ceará, Fortaleza, 2011.

ARAS, M. S. M.; AZIS, F. A.; ALI, F. A.; HAMID, S. M. S. S. A.; BASAR, M. F. H. M. Performances Evaluation and Comparison of Two Algorithms for Fuzzy Logic Rice Cooking System. IEEE CONFERENCE ON OPEN SYSTEMS. 2011. Langkawi. **Anais...** Langkawi: IEEE, 2011, p. 400 - 405.

BARROS, R. L. D. **Avaliação de Critérios de Desempenho de Controladores Preditivos**. 2013. 165 f. Dissertação (Mestrado em ciências) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2013.

BEDE, B. **Mathematics of Fuzzy Sets and Fuzzy Logic**. Londres: Springer, 2013.

BHANDARE, D. S.; KULKARNI, N. R. Performance Evaluation and Comparison of PID Controller and Fuzzy Logic Controller for Process Liquid Level Control. 15th International Conference on Control, Automation and Systems, p. 1347-1352. **Anais**. 2015, Busan, Korea.

CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. 2. ed. London, United Kingdom: Springer, 2007.

CARMO, P. F. **Proposta de Modelo para Descrição da Vazão em Válvulas Direcionais Proporcionais, com Efeito de Vazamento**. 2003. 134 f. Dissertação (Mestrado em engenharia mecânica) Universidade Federal de Santa Catarina, Florianópolis.

CARULO, M. F. **Desenvolvimento e Implementação de Controlador Fuzzy Aplicado à Produção de Biodiesel**. 2008. 196 f. Tese (Doutorado em Engenharia Química) – Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas, 2008.

CHENG-ZE, L.; ZHI, Y.; SHAN, D. J. Application of Fuzzy PID control in Level control for Nuclear Power Plant Primary Bolt Inspection. IEEE International Conference on Computer Science and Automation Engineering. **Anais**. 2012, Shanghai, China.

COELHO, L. S.; SANTOS, A. A. P.; COSTA JR., N. C. A. Podemos Prever a Taxa de Cambio Brasileira? Evidência Empírica utilizando Inteligência Computacional e Modelos Econométricos. **Gestão & Produção**. São Carlos, v. 15, n. 3, dez., 2008.

CONDORENA, E. G. B.; **Identificação de Processos e Controle Preditivo com Modelo utilizando técnicas de Inteligência Artificial aplicadas à Produção de Bioetanol**. 2012 493f. Tese (Doutorado em Engenharia Química) Universidade Estadual de Campinas.

CORREIA, W. B. **Controlador Preditivo GPC com Restrições Implementado em um Compressor de Ar**. 2010 123 f. Dissertação (Mestrado em Engenharia Elétrica) Universidade Federal do Ceará.

COSTA, A. **Previsão de Séries Temporais Financeiras por meio de Redes Neurais Dinâmicas e Processos de Transformação de Dados: Uma Abordagem Empírico-Comparativa**. 2012. 94 f. Dissertação (Mestrado em Engenharia de Produção) – Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2012.

DHAR, S.; MUKHERJEE, T.; GHOSHAL, A. K. Performance Evaluation of Neural Network Approach in Financial Prediction: Evidence from Indian Market. International Conference on Communication and Computational Intelligence. **Anais**. Perundurai, Erode, T.N., India.27, 2010. p. 597-602.

DUARTE, E. R. **Avaliação e Desenvolvimento de Algoritmos de Controle aplicado a um processo Extrativo de Fermentação Alcolólica Contínua**. 2006. 163 f. Tese (Doutorado em engenharia química) – Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas, 2007.

ELECTROLUX. **Máquina de Lavar Loixa**. Disponível em: <<http://www.electrolux.com.br/Support/Usage-advice/Maquinas-de-lavar-loixa/>>. Acesso em: 15 jun. 2016.

ESTURILIO, G. G. **Modelagem e Controle preditivo Econômico de um Reator de Amônia**. 2011. 90 f. Dissertação (Mestrado em engenharia química) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2011.

FAVARO, J. **Controle preditivo aplicado à planta piloto de neutralização de pH**. 2012. 149 f. Dissertação (Mestrado em engenharia de sistemas) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2012.

FELIZARDO, K. R. **Modelagem e Controle Preditivos de um Sistemas de Pulverização com Injeção Direta**. 2013. 143 f. Tese (Doutorado em engenharia elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo. São Paulo, 2013.

FERIMNO, F.; **Estudo Comparativo de Métodos de Sintonia de Controladores PID**. 2014. 90f. Dissertação (Mestrado em Sistemas de Energia e Automação) Universidade de São Paulo, São Carlos.

FILETI, A.M.F.; ANTUNES, A.J.B.; SILVA, F.V.; SILVEIRA Jr., V.; PEREIRA, J.A.F.R. Experimental Investigations on Fuzzy Logic for Process Control. In: Control Engineering Practice, v. 15, **Anais...** 2007, p. 1149-1160.

GARRIDO, A. A Brief History of Fuzzy Logic. In: BROAD RESEARCH IN ARTIFICIAL INTELLIGENCE AND NEUROSCIENCE – BRAIN. v. 3, 2012. **Anais...** ISSN, 2012, p. 71 - 77.

GONÇALVES, G. J. C.; **Controle e Modelo de Máquina de Papel Automática**. 2014. 82f. Trabalho de Graduação (Graduação em Engenharia de Controle e Automação) – Universidade Estadual Paulista – UNESP – Sorocaba, 2014.

HABER, R. E.; ALIQUE, J. R.; ALIQUE, A.; GIMÉNEZ, J. E. **Embedded Fuzzy Control System - Application to an Electromechanical System**. Berlin: Springer, 2003.

HAYKIM, S. O. **Neural Networks and Learning Machines**. 3rd ed. 2008. Pearson Education.

IKHLEF, A.; KIHIL, M.; BOUKHEZZAR, B.; MANSOURI, N.; HOBAR, F. Online PID Control of a Tank Level System. IEEE Global Engineering Education Conference. **Anais**. p. 281-284, 2016, Abu Dhabi, Emirados Árabes Unidos.

JANG, J.-S. R.; SUN, C.-T. e MIZUTANI, E. **Neuro-Fuzzy and Soft Computing: a computational approach to learning and machine intelligence**. Prentice Hall, 2007.

KATAL, N.; KUMAR, P.; NARAYAN, S. Optimal PID Controller for Coupled-Tank Liquid-Level Control System using Bat Algorithm. IEEE International Conference on Power, Control and Embedded Systems, 2014. **Anais**.

KIM, H.; SHIN, K. A hybrid approach based on neural networks and genetic algorithms for detecting temporal patterns in stock markets. **Applied Soft Computing**, v. 7, n. 2, p.569-576, 2007

KONSEY, M. K.; CUTRIGHT, R.; BEQUETTE, B. W. Computational Efficient Neural Predictive Control based on a Feedforward Architecture. In: American Control Conference, 2006, Minneapolis. **Proceedings**. Minneapolis, 2006, p. 2957-2962.

KOSKO, B. **Fuzzy Thinking: The New Science of Fuzzy Logic**. Hyperion, 1993.

LI, F. Research on the Estimating Model of the Stock Market Price Based on the LM-BP Neural Network. In: International Conference on Genetic and Evolutionary Computing, 4th, 2010, Shenzhen. **Anais**. Shenzhen, 2010. p. 562-565.

MARTIN, P. A. **Aplicação de Técnicas de Controle Preditivo em uma Coluna de Destilação**. 2011. 175 f. Tese (Doutorado em engenharia de sistemas) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2011.

MATHWORKS. **Fuzzy Logic Toolbox R2015a – User's Guide**. Disponível em: <http://www.mathworks.com/help/pdf_doc/fuzzy/fuzzy.pdf>. Acesso em: 15 dez. 2015.

MATHWORKS. **Model Predictive Control Toolbox R2016a – User's Guide**. Disponível em: <http://www.mathworks.com/help/pdf_doc/mpc/mpc_ug.pdf>. Acesso em: 15 mai. 2016.

MOZELLI, L. A. **Controle Fuzzy para Sistemas Takagi-Sugeno: Condições Aprimoradas e Aplicações**. 2008. 87 f. Dissertação. (Mestrado em Engenharia Elétrica) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

OGATA, K. **Engenharia de Controle Moderno**. 2011. 5º ed. Editora Pearson.

OLIVI, L. R.; **Aplicação de Herbicidas a Taxas Variáveis utilizando Controle Preditivo**. 2009. 133f. Dissertação (Mestrado em Engenharia Elétrica) Universidade de São Paulo.

PATAN, K.; KORBICZ, J. Stable neural network based model predictive control. In: Conference on Control and Fault-Tolerant Systems, Nice, 2013. **Anais**. Nice, 2013. p. 419-424.

POTTER, M. C.; WIGGERT, D. C. **Mecânica dos Fluidos**. 3rd ed. 2004. Thompson.

QINGLI, O.; PINGRONG, Z.; YANGXI, W. Control System of the Boiler Water Level Based on Normalized PID. 3rd International Conference on Computer Science and Network Technology. **Anais**. p. 1251-1254, 2013, Dalian, China.

RATHER, A. Optimization of Predicted Portfolio using various Autoregressive Neural Networks. In: International Conference on Communication Systems and Network Technologies, 2012, Rajkot. **Anais**. Rajkot, 2012. p. 265-269.

RAZAVI, S.; TOLOSAN, B. A. A New Formulation for Feedforward Neural Nets. **Anais**. IEEE Trans. on Neural Networks. 2011 v. 22 n. 10. p. 1588-1598.

RAZAVI, S.; TOLOSAN, B. A. and Burn, D. H. **Numerical assessment of metamodelling strategies in computationally intensive optimization**. 2011.

REN, H.; ZHANG, Y. Nonlinear Control Based on an Improved Neural Predictive Control Scheme. In: International Conference on Computer Science and Network Technology, 3rd, 2013, Dalian. **Anais**. Dalian, 2013. p. 1222-1225.

ROMANINI, C. E. B. **Desenvolvimento de um Sistema de Controle Fuzzy para Incubadora de Ovos**. 2009. 100 f. Dissertação (Mestrado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2009.

ROSS, T. J. **Fuzzy Logic with Engineering Applications**. 3. ed. Wiley, 2009.

SARDARMEHNI, T.; MENHAJ, M. B.; NAYER, S. HOSSEIN, R. In: Iranian Conference on Fuzzy Systems. 13th, 2013. **Anais**.

SHARMA, M.; PALLAVI, V.; MATHEW, L. Design an Intelligent for a Process Control System. IEEE International Conference on Innovation and Challenges in Cyber Security. p.217-223 **Anais**. 2016.

SHAW, I.; SIMÕES, M. G. **Controle e Modelagem Fuzzy**. 2. ed. Editora Blucher, 2007.

SILVA, R. S. **Previsão de venda de produtos em uma indústria de telecomunicação utilizando redes neurais artificiais**. 2010. 78 f. Dissertação

(Mestrado em Computação Aplicada) Universidade do Vale do Rio Dos Sinos, São Leopoldo.

SIVANANDAM, S. N.; SUMATHI, S; DEEPA, S. N. **Introduction to Fuzzy Logic using MATLAB**. Berlin: Springer, 2007.

VARGHESE, H. K.; ROSE, L. Comparative Study of Various Level Control Techniques for a Two Tank System. IEEE International Conference in Information Embedded and Communication Systems. **Anais**. 2015.

VIEIRA, C. **Forecasting Financial Markets with Artificial Neural Networks**. 2013. 37 f. Dissertação (Mestrado em Matemática Financeira) – School of Economics & Management, Instituto Superior de Economia e Gestão, Lisboa, 2013.

VIEIRA, W. G. **FCC: Controle Preditivo e Identificação via Redes Neurais**. 2002. 193 f. Tese (Doutorado em engenharia química) – Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas, 2002.

WUERGES, A.; BORBA, J. Redes Neurais, Lógica Nebulosa e Algoritmos Genéticos: Aplicações e Possibilidades em Finanças e Contabilidade. **Revista de Gestão da Tecnologia e Sistemas de Informação**, Florianópolis, 2010. v.7, n.1, p. 163-182.

YIXIN, Z.; ZHANG, J.; Stock Data Analysis Based on BP Neural Network. In: International Conference on Communication Software and Networks, 4th, 2010. **Anais**. IEEE Computer Society, 2010. p. 396-399.

YOO, A.; LEE, T. C.; YANG, D. R. Experimental simultaneous state and parameter identification of a pH neutralization process based on an extended kalman filter. **Korean Journal Chemical Engineering**, vol. 21, n. 4, p. 753–760, 2004.

ZADEH, L.A. **Fuzzy Sets**. In: INFORMATION AND CONTROL. 8, 1965. Disponível em: <<http://www-bisc.cs.berkeley.edu/Zadeh-1965.pdf>>. Acesso em: 10 mai. 2014.


APÊNDICE

A. Conceitos de Redes Neurais Artificiais

As Redes Neurais Artificiais são redes com múltiplas camadas de neurônios (YIXIN et al., 2010) que assemelham sua maneira construtiva, visando o processamento paralelo que o cérebro humano é capaz de fazer (DHAR; MUKHERJEE; GHOSHAL, 2010). Os neurônios da RNA são a base para toda a rede e são responsáveis pelo processamento mais básico do conhecimento (COELHO; SANTOS; COSTA JR., 2008).

A figura 1 apresenta uma representação do neurônio biológico. Com cerca de 10.000 contatos sinápticos, os neurônios recebem estímulos elétricos através dos dendritos (HAYKIN, 2008). No interior do neurônio, sinais químicos e elétricos percorrem o corpo celular e vão em direção ao axônio, desde que determinado limiar de excitação seja superado. No final, o axônio é dividido em várias ramificações, que irão se ligar quimicamente aos dendritos de outros neurônios, transmitindo a informação através da chamada sinapse (VIEIRA, 2013).

Figura 1: Representação do neurônio biológico




(Fonte: ESTEVAM, 2013)

A figura 2 apresenta um modelo artificial de neurônio, de forma que os dendritos são representados pelos sinais de entrada $X_1, X_2, \dots, X_m$. A relação entre o dendrito de um neurônio com o axônio de outro neurônio é medida pelo chamado peso sináptico, representado genericamente por W_{km} . Quanto maior esta relação, maior relevância

terá determinado sinal de entrada para o neurônio. Os dados de entrada são processados todos juntos pelo neurônio através do somador (Σ). O valor b_k representa o limiar de excitação do neurônio biológico, de forma que o sinal elétrico apenas será propagado para a saída caso este valor seja atingido ou superado. Por fim, a função de ativação $\varphi(.)$ irá modificar o sinal antes de o enviar à saída do neurônio artificial, que representa um terminal do axônio do neurônio biológico (SILVA, 2010).

Figura 2: Modelo de neurônio artificial



(Fonte: MECATRÔNICA ATUAL, 2006)

Desta forma, o neurônio artificial pode ser modelado matematicamente, como se segue nas equações 1 e 2 (HAYKIN, 2008), em que V_k é a entrada ponderada do neurônio e Y_k é a saída do neurônio:

$$V_k = \sum_{j=1}^m (W_{kj} X_j) \quad (1)$$

$$Y_k = \varphi (V_k + b_k) \quad (2)$$


A seguir, são apresentadas as estruturas mais utilizadas de redes neurais artificiais.

1. Redes Feedforward

As redes neurais do tipo *feedforward* são as mais utilizadas, uma vez que podem ser aplicadas a diversos tipos de problemas como aproximação de funções, previsões e simulações (RAZAVI; TOLOSN, 2011). Sua característica construtiva é feita de forma que as informações sempre são propagadas para frente, assim, dados de saída não são levados em consideração em outros pontos da rede (HAYKIN, 2008).

A figura 30 mostra uma estrutura de rede neural do tipo *feedforward* apenas com a camada de saída:


Figura 3: Rede *Feedforward* com uma única camada de neurônios



Apesar de a configuração da rede *feedforward* sem a camada escondida ser aplicável nos tipos de problemas citados, é comprovado que a mesma rede com uma camada escondida é mais eficiente na resolução de problemas complexos (RAZAVI; TOLOSN, 2011). Além disso, quando mantido o número de neurônios, o uso de uma camada escondida além da primeira torna a rede menos eficaz (RAZAVI; TOLOSN; BURN, 2011), ao contrário do que a princípio pareceria lógico.

A figura 4, abaixo, apresenta a estrutura de uma rede *feedforward* com uma camada escondida:

Figura 4: Rede *Feedforward*, totalmente conectada, com uma camada de neurônios escondidos



(Fonte: HAYKIN, 2008)

2. Redes Preditivas


As redes neurais preditivas podem ser divididas em dois tipos principais: as redes não recorrentes e as redes recorrentes.

A recorrência de uma rede diz respeito a haver ou não uma realimentação da saída de algum neurônio da rede para suas próprias entradas. Esta realimentação pode vir tanto da camada de saída quanto de alguma camada escondida.

2.1 Rede Preditiva não Recorrente

Apesar de as redes *feedforward* previamente apresentadas serem eficazes para uma série de problemas distintos, quando a aplicação é a predição de séries temporais, redes específicas se fazem necessárias. A figura 5 apresenta uma modificação na estrutura da rede *feedforward*:

Figura 5: Rede *feedforward* focada atrasada no tempo



(Fonte: HAYKIN, 2008)

Esta modificação, que adiciona atrasos no tempo para as entradas, visa fazer com que a rede seja treinada utilizando p valores passados. Assim, o valor de saída previsto para o tempo t , y_t , está baseado em entradas de tempos anteriores, conforme a equação 3:

$$y_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-p}) \quad (3)$$


Os atrasos unitários no tempo, representados por z^{-1} , fazem com que esta rede, também conhecida por FTDNN (*Focused Time Delay Neural Network*), consiga ser mais eficiente na resolução de problemas variantes no tempo (KIM; SHIN, 2007).

2.2 Redes Preditivas Recorrentes

As redes preditivas recorrentes se valem de valores preditos pela própria rede para realimentar os neurônios da camada de entrada. A presença da realimentação tem grande influência na capacidade de aprendizado da rede e em seu desempenho (HAYKIN, 2008).

A figura 6 apresenta uma rede recorrente não autorregressiva, ou seja, um neurônio nunca é realimentado por sua própria saída:


Figura 6: Rede recorrente não autorregressiva e sem camada escondida



(Fonte: HAYKIN, 2008)

A figura 7 apresenta uma rede recorrente autorregressiva, ou seja, cada neurônio é realimentado por sua própria saída e pela saída de todos os outros neurônios:

Figura 7: Rede recorrente autorregressiva com entradas exógenas



(Fonte: HAYKIN, 2008)

Ainda, esta rede apresenta entradas que estão fora do ciclo de realimentação da rede. Estas entradas são chamadas de exógenas. Assim, esta rede recebe o nome de NARX (*Nonlinear Autoregressive with Exogenous Inputs*).

As entradas exógenas da rede NARX são variáveis que, de alguma forma, influenciam ou refletem o comportamento da variável a ser predita. Assim, elas servem como um parâmetro a mais para a rede realizar as predições, aumentando sua capacidade preditiva (HAYKIN, 2008).

3. Treinamento da Rede Neural

Em relação aos métodos de treinamento possíveis, o mais usado é o método da Retropropagação do Erro (RE) (YIXIN et al., 2010), que apresenta excelentes resultados no treinamento de diversos tipos de redes (LI, 2010).

O algoritmo da RE busca o ponto de mínimo na função gradiente do erro em função dos pesos sinápticos. Assim, para um dado neurônio k da camada j de uma rede neural, sabe-se que o erro da saída da rede, $e_k(n)$, em uma dada época n , é a diferença entre o valor desejado da saída, $d_k(n)$, e o valor real emitido pela rede, $y_k(n)$, conforme a equação 4:

$$e_k(n) = d_k(n) - y_k(n) \quad (4)$$

A fim de se medir este erro a cada época de treinamento, define-se o Erro Quadrático Médio (EQM), $\mathcal{E}(n)$, como mostrado pela equação 5:

$$\mathcal{E}(n) = \frac{1}{2} e_k^2(n) \quad (5)$$

Conforme as épocas de treinamento avançam, os pesos sinápticos, w_{kj} , são atualizados seguindo para o ponto de mínimo do gradiente da função do EQM, em que η é a taxa de aprendizagem da rede, conforme as equações 6 e 7:

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (6)$$

$$\Delta w_{kj}(n) = -\eta \frac{\partial \mathcal{E}}{\partial w} \quad (7)$$

Uma vez que não é possível relacionar diretamente o EQM com o peso sináptico, faz-se esta relação indiretamente, uma vez que o EQM é função do erro da rede, que é função da saída da rede, que por sua vez depende da saída do neurônio

k , u_k , que varia de acordo com os pesos sinápticos deste neurônio. As equações 8 e 9 apresentam essas relações:

$$\mathcal{E} = f(e(y(u(w)))) \quad (8)$$

$$\nabla \mathcal{E}(w) = \frac{\partial \mathcal{E}}{\partial w} = \frac{\partial \mathcal{E}}{\partial e} \frac{\partial e}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial w} \quad (9)$$

Apesar de ser um método muito eficiente, o algoritmo da RE pode apresentar desvantagens, como treinar a rede de uma maneira que o treinamento convirja para um ponto de mínimo local do gradiente da função do EQM (LI, 2010). Assim, o algoritmo de treinamento de Levenberg-Marquardt, que também se baseia no método do gradiente descendente, se mostra como uma ótima opção para treinar uma RNA, de forma a evitar erros de treinamento cometidos pelo algoritmo de treinamento da retropropagação do erro (COSTA, 2012).

A taxa de aprendizado da rede, η , influencia o quão rápido a rede irá atualizar seus pesos sinápticos, conforme a equação 9, percorrendo a superfície do EQM. Assim, um valor pequeno para η faz com que a aprendizagem seja mais lenta e, em alguns casos, mais eficiente. Um valor elevado para η torna a aprendizagem mais rápida, mas poderá gerar instabilidade e evitar que o ponto de mínimo seja alcançado (HAYKIN, 2008).

B. Conceitos de Lógica Fuzzy

Desde épocas remotas o homem tenta modelar os fenômenos que vê ocorrerem na natureza com o objetivo de os entender e até mesmo os reproduzir. Assim, para que seja possível construir modelos confiáveis e que possam de fato estar de acordo com a realidade, existe a necessidade de que sejam utilizados conceitos e expressões precisas, de forma que se possa obter resultados iguais, ainda que os modelos sejam aplicados em diferentes processos e por diferentes pessoas. Desta forma, a primazia pela precisão sempre esteve presente nas chamadas ciências exatas (GONÇALVES, 2014).

Apesar disso, o homem utiliza diversos conceitos imprecisos em seu cotidiano, uma vez que a precisão das informações nem sempre é conhecida. Assim, expressões como *muito*, *bastante*, *pouco*, *suficiente*, entre outras, são usadas corriqueiramente quando há a necessidade se precisar alguma informação.

Uma vez que tais expressões não são suficientes para dar a precisão requerida por modelos utilizados nas ciências exatas, estudos foram feitos no sentido de se criar uma relação entre o vago e o preciso, de forma a utilizar o conhecimento que é passado de forma imprecisa para que fosse possível criar modelos exatos.

Com base nisso, o filósofo e físico quântico Max Black iniciou trabalhos com o intuito de modelar aquilo que fosse considerado vago (GARRIDO, 2012). Através do uso de casos difíceis de serem definidos precisamente, Max Black chegou à conclusão, por volta do ano de 1965, de que a incerteza, característica daquilo que é considerado vago, está presente em todas as medições realizadas.

Os trabalhos de Max Black foram de grande influência para Lofti Zadeh, que reconheceu a importância dos conceitos vagos nas vidas das pessoas, além de serem essenciais em tópicos como reconhecimento de padrões, comunicação, entre outros (ZADEH, 1965). Assim, Zadeh desenvolveu o conceito de conjunto vago, também conhecido como conjunto nebuloso ou conjunto *fuzzy*.

De acordo com Zadeh, um conjunto fuzzy pode conter, ao mesmo tempo, elementos que pertencem e não pertencem a este conjunto, simultaneamente (GARRIDO, 2012). Esta aplicação do conceito de conjuntos foi fundamental para que fosse possível aproximar conceitos vagos da precisão matemática. Assim, os conceitos da lógica fuzzy foram utilizados para transformar os conhecimentos de uma pessoa especialista em um modelo matemático, tornando possível a criação de controladores de processos industriais baseados na lógica fuzzy (BEDE, 2013).

Anos depois, em 1980, Ebrahim Mamdani desenvolveu o primeiro controlador a usar a lógica fuzzy como base, conhecidos como controladores fuzzy (KOSKO, 1993). Através dele foi possível realizar o controle de uma máquina a vapor com sucesso. Atualmente, grandes empresas como a Electrolux utilizam os controladores fuzzy em máquinas de lavar louças (ELECTROLUX, 2014), além de eles também estarem amplamente presentes nos sistemas de freios do tipo ABS (*anti-lock braking system*) em veículos automotores (GARRIDO, 2012).

Conforme observado, as pessoas se valem de conceitos incertos em seu cotidiano para descrever e classificar os mais variados eventos. Assim, a lógica fuzzy precisou expandir o conceito clássico de conjuntos de forma que fosse possível que um dado elemento pertencesse e não pertencesse a um dado conjunto ao mesmo tempo.


Classicamente, um conjunto de elementos é formado apenas por elementos que se enquadrem naquele conjunto. Isto faz com que existam apenas duas possibilidades de classificação de um dado elemento em um dado conjunto: como pertencente ou não pertencente àquele conjunto. Esta classificação clássica de elementos é usualmente chamada de *crisp*. Assim, um conjunto com as características citadas é chamado de conjunto *crisp* (SHAW; SIMÕES, 2007).

Por outro lado, uma vez que a lógica fuzzy trabalha com conceitos vagos, criou-se os chamados conjuntos fuzzy para que fosse possível tratar de forma matemática conceitos pouco claros. Assim, estabeleceu-se o conceito de pertinência, que estabelece com que grau uma relação de pertinência entre um dado elemento e um dado conjunto é verdadeira (MATHWORKS, 2013). Por definição, a pertinência é expressa por um número entre zero e um.

De acordo com estas definições, um dado elemento x , pertencente a um conjunto crisp A, possui uma função de pertinência $\mu_A(x)$ que apenas pode assumir os valores zero, para o caso em que o elemento não pertence ao conjunto A, e um, para quando o elemento pertence ao conjunto A. No entanto, em se tratando de um conjunto fuzzy, $\mu_A(x)$ pode assumir qualquer valor entre zero e um, de forma que é possível que x pertença apenas parcialmente a A (ZADEH, 1965).

Uma vez que o uso da lógica fuzzy requer uma expansão no conceito clássico de conjuntos, é necessário que se defina as operações básicas com os conjuntos fuzzy. Desta forma, definem-se os conjuntos fuzzy $A = \{\frac{0}{1}, \frac{0}{2}, \frac{0}{3}, \frac{0,5}{4}, \frac{1}{5}, \frac{1}{6}, \frac{1}{7}\}$ e $B = \{\frac{0}{1}, \frac{0,5}{2}, \frac{1}{3}, \frac{0,5}{4}, \frac{0}{5}, \frac{0}{6}, \frac{0}{7}\}$, em que o denominador representa o número do elemento dentro do conjunto e o numerador indica o grau de pertinência deste elemento no conjunto. Os conjuntos A e B são mostrados na figura 1 abaixo:

Figura 1: Funções de pertinência dos conjuntos A e B




Quando se trabalha com conjuntos fuzzy, a operação de união entre eles implica em um novo conjunto que é composto pelo valor máximo das pertinências de cada um dos conjuntos (SHAW; SIMÕES, 2007). Portanto, a pertinência de cada

elemento do novo conjunto U (formado pela união dos conjuntos A e B), $u_U(x)$, é definida pela equação 1:

$$u_{A \cup B}(x) = u_U(x) = \max(u_A(x), u_B(x)) \quad (1)$$

Desta forma, a função de pertinência do conjunto U é mostrada pela figura 2:


Figura 2: Função de pertinência resultante da união dos conjuntos A e B



Em relação à propriedade de intersecção de conjuntos fuzzy, a pertinência $u_I(x)$ de cada elemento do conjunto resultante da intersecção dos conjuntos A e B, I, será a menor pertinência dentre os elementos dos conjuntos A e B (SHAW; SIMÕES, 2007). Desta forma, define-se a equação 2 e é mostrado pela figura 3:

$$u_{A \cap B}(x) = u_I(x) = \min(u_A(x), u_B(x)) \quad (2)$$

Figura 8: Função de pertinência resultante da intersecção dos conjuntos A e B



O complemento de um conjunto fuzzy A ($\bar{A}$) é definido como sendo a diferença entre a máxima pertinência possível e a pertinência do elemento do conjunto considerado (SHAW; SIMÕES, 2007). Assim, a pertinência $u_{\bar{A}}(x)$ do elemento x de um conjunto $\bar{A}$ que é o complemento do conjunto A , é definido como mostrado pela equação 3

$$u_{\bar{A}}(x) = 1 - u_A(x) \quad (3)$$

Abaixo são apresentadas as funções de pertinência dos conjuntos A e $\bar{A}$ e dos conjuntos B e $\bar{B}$, conforme as figuras 4 e 5:

Figura 4: Funções de pertinência do conjunto A e de seu complemento





Figura 5: Funções de pertinência do conjunto B e de seu complemento



Por fim, os conjuntos fuzzy obedecem à maioria das relações existentes para conjuntos crisp, como a propriedade comutativa, associativa e de involução. Porém, os conjuntos fuzzy diferem no que diz respeito às propriedades que envolvem conjuntos e seus complementos. Com o intuito de conceituar as principais propriedades de conjuntos fuzzy, tais propriedades são apresentadas abaixo, em que A, B e C são conjuntos fuzzy e E é o universo de discurso tal que A, B e C estão contidos em E (SHAW; SIMÕES, 2007).

Propriedade cumulativa:

$$A \cup B = B \cup A$$

$$A \cap B = B \cap A$$

Propriedade associativa:

$$(A \cup B) \cup C = A \cup (B \cup C)$$

$$(A \cap B) \cap C = A \cap (B \cap C)$$

Conjuntos complementares:

$$A \cup \bar{A} = E$$

$$A \cap \bar{A} = \emptyset$$

Conjunto nulo:

$$A \cup \emptyset = A$$

$$A \cap \emptyset = \emptyset$$

Conjunto universo:

$$A \cup E = E$$

$$A \cap E = A$$

Involução:

$$\overline{(\bar{A})} = A$$

Teorema de De Morgan:

$$(\overline{A \cup B}) = \overline{A} \cap \overline{B}$$

$$(\overline{A \cap B}) = \overline{A} \cup \overline{B}$$

Variáveis linguísticas são variáveis que, ao invés de estarem relacionadas a um valor numérico, estão atreladas a uma palavra ou sentença. Desta forma, a variável temperatura é uma variável linguística desde que não seja representada por um valor numérico, mas sim por um conceito, por exemplo: quente, frio, morno, agradável, muito quente, entre outros. Os modificadores das variáveis (muito, pouco, quase, extremamente, entre outros) são tratados como operadores não lineares que alteram o significado das variáveis linguísticas (ZADEH, 1975).

Conforme apresentado, cada elemento de um conjunto fuzzy está atrelado a um grau de pertinência àquele conjunto. Assim, uma vez que uma variável linguística é representada por uma função de pertinência dentro de um conjunto fuzzy (por exemplo, a variável linguística frio é representada por uma função de pertinência dentro do conjunto temperatura), os elementos contidos nesta variável linguística estão atrelados a um valor de pertinência. Desta forma, supondo que a temperatura ambiente de 25°C seja considerada agradável, um valor de 9°C (um elemento do conjunto temperatura) poderia apresentar uma pertinência de 0,9 para a função de pertinência da variável linguística frio e uma pertinência de 0 para a função de pertinência da variável linguística quente.

Uma vez que as entradas de um sistema fuzzy são representadas por números exatos, pertencentes a conjuntos crisp portanto, existe a necessidade de adequar estes números às diversas funções de pertinência existentes na base de dados do controlador. Desta forma, tomando-se como exemplo a função de pertinência representando a sensação térmica, apresentada na figura 12, uma entrada com valor de 10°C irá pertencer ao conjunto Frio com pertinência 1 e ao conjunto Quente com pertinência 0. Porém, uma entrada no valor de 25°C irá apresentar uma pertinência de 0,5 em ambos os conjuntos. Assim, uma entrada pertencente a um conjunto crisp é transformada de forma que ela passa a poder ser representada através de conjuntos fuzzy. Tal transformação é chamada fuzzificação.


Ao fim do processo de inferência, o controlador fuzzy terá como saída uma função de pertinência que será formada por uma ou mais funções de pertinência intermediárias, dependendo de como a entrada crisp se encaixa na base de dados fuzzy e também do método de inferência utilizado (conforme será abordado com mais detalhes, adiante). Assim, uma vez que a saída do controlador fuzzy irá, usualmente, se comunicar com sensores e atuadores, esta saída não poderá estar no formato de uma função de pertinência. Desta forma, ocorre o chamado processo de defuzzificação, no qual uma saída fuzzy é transformada em um valor crisp, que poderá ser adequadamente interpretado pelos elementos atuadores. Existem sete métodos mais usados para realizar a defuzzificação (SIVANANDAM; SUMATHI; DEEPA, 2007). Eles são apresentados abaixo, considerando que S é o conjunto fuzzy de saída a ser defuzzificado, z^* é o elemento crisp que representará o conjunto S após a defuzzificação e z é qualquer outro elemento do conjunto S :

(I) Método da máxima pertinência

O método da máxima pertinência consiste em tomar como saída crisp o valor referente à máxima pertinência existente na função de pertinência. Desta forma, tem-se a equação 4 abaixo e a figura 6:

$$\mu_S(z^*) \geq \mu_S(z) \quad (4)$$

Figura 6: Defuzzificação através do método da máxima pertinência




No caso de existirem um ou mais elementos com a pertinência máxima da função de pertinência, pode-se utilizar o método II.

(II) Método da média dos máximos

O método da média dos máximos pode ser aplicado em casos em que existem vários elementos que possuem a máxima pertinência da função. Desta forma, a saída z^* é dada pela média aritmética simples entre o primeiro e último elemento com o maior valor de pertinência. No exemplo da figura abaixo, tem-se o gráfico da equação 5 e pela figura 7:

$$z^* = \frac{a+b}{2} \quad (5)$$

Figura 7: Defuzzificação através do método da média dos máximos. Autoria própria



(III) Método da centróide ou centro de gravidade

O método da centróide, também conhecido como método do centro de gravidade, é o mais utilizado (SIVANANDAM; SUMATHI; DEEPA, 2007). Ele é indicado para processos de controle, em que existe a necessidade da continuidade nos valores de saída do controlador fuzzy, uma vez que saltos na saída do controlador podem não ser aceitáveis (SHAW; SIMÕES, 2007). Ainda, o método do centro de gravidade pode ser aplicado para funções de pertinência assimétricas, tal como mostrado na figura 13. Matematicamente, a relação é mostrada pela equação 6:


$$z^* = \int \frac{\mu_S(z) \cdot z \cdot dz}{\mu_S(z) \cdot dz} \quad (6)$$

(IV) Método da média aritmética ponderada

Este método, como o próprio nome sugere, consiste em realizar o cálculo da média aritmética ponderada entre todos os elementos que possuam o maior valor de pertinência da função ao qual está inserido. Desta forma, este método é útil para o caso em que existam várias funções de pertinência bem definidas dentro do conjunto fuzzy de saída. Por fim, este método apenas pode ser aplicado para funções de pertinência simétricas (SIVANANDAM; SUMATHI; DEEPA, 2007). Assim, essa relação é mostrada pela equação 7 e pela figura 8:

$$z^* = \frac{\sum \mu_S(z) \cdot z}{\sum \mu_S(z)} \quad (7)$$

Figura 8: Defuzzificação através do método da média aritmética ponderada




(V) Método do centro das somas

Este método utiliza a intersecção das áreas dos conjuntos fuzzy de saída. Assim, ao invés de realizar a operação de união entre conjuntos para obter um único conjunto fuzzy de saída, toma-se a intersecção dos mesmos, o que será representado através de uma área Z na função de pertinência. Utiliza-se como saída crisp o ponto central desta área resultante da intersecção dos conjuntos fuzzy (ROSS, 2009). Este método é representado como se segue, em que $\bar{z}$ é a distância da base até a centróide de cada conjunto fuzzy e n é o número de conjuntos fuzzy que compõem a intersecção, conforme mostra a equação 8 e a figura 9:

$$z^* = \frac{\sum_{k=1}^n \mu_S(z) \cdot \int_Z \bar{z} dz}{\sum_{k=1}^n \mu_S(z) \cdot \int_Z dz} \quad (8)$$


Figura 9: Defuzzificação através do método do centro das somas



(VI) Método do centro de gravidade da maior área

Este método pode ser aplicado quando existe uma saída fuzzy composta de dois ou mais conjuntos fuzzy. Neste caso, opta-se pela maior área dentre os conjuntos fuzzy presentes e o valor crisp correspondente à saída será o centro de gravidade desta área. Assim, o valor de z^* pode ser determinado utilizando a equação 6, previamente apresentada (ROSS, 2009), e mostrada na figura 10:

Figura 10: Defuzzificação através do método do centro de gravidade da maior área




(VII) Método do primeiro (ou último) dos máximos

Este método está entre os mais simples, uma vez que pode ser determinado facilmente sem a necessidade de grande processamento matemático. Ele consiste em determinar o primeiro ponto de máximo da função de pertinência de saída e tomar seu elemento correspondente como a saída crisp do sistema (ROSS, 2009). Na figura abaixo, este elemento é apresentado como $z1^*$. Analogamente, pode-se optar pelo último ponto em que a máxima pertinência da função está presente, o que é mostrado na figura abaixo como sendo o elemento $z2^*$. Desta forma, é possível inferir que, no caso de uma função de pertinência triangular, o primeiro e o último dos máximos serão

iguais, o que torna este método análogo ao método da máxima pertinência. A função é mostrada pela figura 11:

Figura 11: Defuzzificação através do método do primeiro dos máximos ($z1^*$) e último dos máximos ($z2^*$)



Conforme observado, a lógica fuzzy é capaz de transformar o conhecimento de um especialista na operação de um dado processo em um sistema de controle, sem que haja a necessidade de se conhecer todos os elementos internos da planta para realizar uma modelagem matemática precisa (BEDE, 2013). Isto é feito através das regras Se-Então, que irão expressar o conhecimento na forma de variáveis linguísticas.

Tradicionalmente, na lógica clássica, ocorre o uso dos chamados silogismos, em que a veracidade de uma premissa A implica na veracidade de outra premissa B, desde que exista uma premissa que determine esta relação ($A \rightarrow B$). Neste caso, diz-se que A implica em B. Desta forma, a lógica clássica segue o seguinte formato: (MOZELLI, 2008)

Premissa (regra): SE x é A , ENTÃO y é B ($A \rightarrow B$)

Premissa (fato): x é A

Conclusão: y é B

No entanto, uma vez que sistemas fuzzy trabalham com variáveis que pertencem a conjuntos nebulosos, há a necessidade de se alterar também a maneira de utilizar implicações lógicas, uma vez que a lógica clássica apenas é satisfatória para trabalhar com conjuntos crisp (JANG; SUN; MIZUTANI, 1997). Desta forma, ainda que se mantenha a mesma regra de implicação em que A implica em B , $A \rightarrow B$, há de se considerar que um valor aproximado de A , A' , também deverá obedecer à regra apresentada, porém, implicando em um valor aproximado de B , B' . Assim:

Premissa: SE x é A , ENTÃO y é B ($A \rightarrow B$)

Fato: x é A'

Conclusão: y é B'

Desta forma, o raciocínio clássico pode ser expandido e passar a considerar imprecisões, o que o torna capaz de trabalhar com variáveis fuzzy. Assim, quando há a referência a um valor aproximado de A (A'), existe a referência aos conjuntos fuzzy, em que um valor mais próximo de A implica em um grau de pertinência maior ao conjunto, enquanto um valor menos próximo de A implica em um menor grau de pertinência no mesmo conjunto (JANG; SUN; MIZUTANI, 1997). Por fim, esta forma de raciocínio que considera valores nebulosos é uma generalização do raciocínio clássico, o que torna o raciocínio clássico apenas um caso específico daquele. Então, conforme esperado, se x é exatamente A (possui pertinência 1 com o conjunto), y é exatamente B .

Uma vez utilizando a forma expandida da lógica clássica, os sistemas fuzzy utilizam regras Se-Então com o seguinte formato, em que R_i é uma regra pertencente ao conjunto de regras do sistema fuzzy, x e y são elementos de entrada, z é um elemento de saída, A e B são variáveis linguísticas de entrada e C é uma variável linguística de saída: (MOZELLI, 2008)

$$R_i: \quad \text{SE} \quad (x \text{ é } A) \text{ E } (y \text{ é } B) \\ \quad \text{ENTÃO} \quad z \text{ é } C$$

As regras Se-Então são compostas de 2 partes: a primeira é chamada de proposição, precedente ou premissa e compõe tudo aquilo que forma a condição SE. A segunda parte é o chamado consequente ou conclusão, que engloba o que ocorre no caso de a proposição ser acionada e aparece na regra após o ENTÃO (MATHWORKS, 2013). Tanto a proposição quanto o consequente podem apresentar conectores lógicos para estabelecer a relação entre as variáveis. No caso acima, utilizou-se a função lógica E para relacionar os termos da proposição. Os operadores mais utilizados para tal função são os operadores E e OU.

Uma vez ocorrida a fuzzificação das entradas e a posterior comparação com a base de regras para se determinar quais saídas serão ativadas pelas entradas do sistema, ocorre os processos de implicação e agregação, que são responsáveis por determinar, respectivamente, como as diversas funções de pertinência de entrada irão se relacionar para ativar uma saída e para determinar como as diversas funções de pertinência de saída irão se relacionar para se obter apenas um sistema fuzzy de saída, que será então defuzzificado.

Apesar de existirem diversos tipos de sistemas de inferência, os sistemas do tipo

Mamdani e Takagi-Sugeno são os mais empregados em controladores fuzzy, sendo que o sistema de inferência Mamdani é o mais popular entre os dois (SIVANANDAM; SUMATHI; DEEPA, 2007).

Uma vez que o software escolhido para a criação do controlador fuzzy foi o MATLAB[®], através de sua extensão *Fuzzy Logic Toolbox*TM, este trabalho irá utilizar o sistema de inferência do tipo Mamdani, que é o sistema padrão utilizado em controladores fuzzy neste software. Além disso, o método de Mamdani garante a continuidade das variáveis de saída do controlador, evitando variações bruscas nos elementos de atuação.


Este método foi o primeiro a ser utilizado em um sistema de controle usando a lógica fuzzy e foi proposto no ano de 1975 por Ebrahim Mamdani, que se baseou nos

trabalhos publicados anos antes por Zadeh (MATHWORKS, 2013). O método criado por Mamdani utiliza as entradas do sistema fuzzy e as relaciona com as funções de pertinência e também com a tabela de regras do tipo Se-Então. Fazendo isso, este método de inferência resulta em um conjunto fuzzy resultante que, por fim, irá passar pelo processo de defuzzificação, resultando em um número real que será a saída do controlador.

A inferência proposta por Mamdani é composta por duas etapas: implicação e agregação. Primeiramente, ocorre o processo de implicação, em que uma ou mais entradas são computadas de acordo com as regras Se-Então e é verificado qual ou quais saídas são acionadas com as entradas (previamente fuzzificadas) fornecidas ao controlador. No caso de haver mais de uma entrada, elas se relacionam através do operador lógico E que, conforme a equação 2, representa o mínimo das funções de pertinência das saídas ativadas pelas entradas dadas (SIVANANDAM; SUMATHI; DEEPA, 2007).

Após terminado o processo de implicação, poderá existir mais de uma função de pertinência de saída, dependendo do número de regras Se-Então ativadas pelas entradas fuzzificadas. Uma vez que é necessário apenas uma única função de pertinência para que se possa efetuar a defuzzificação, ocorre o processo de agregação, em que as várias funções de pertinência saídas do processo de implicação são agregadas de forma a criar apenas uma. Assim, utiliza-se o operador lógico OU que, conforme a equação 1, representa o máximo das funções de pertinência de saída envolvidas. Na figura 12 é possível observar os processos de implicação e agregação de um sistema fuzzy hipotético com duas entradas e uma saída que apresenta três regras Se-Então.

Figura 12: Sistema de inferência Mamdani



(Fonte: adaptado de SIVANANDAM; SUMATHI; DEEPA, 2007)

C. Resultados das simulações para a referência rampa ruidosa

Figura 1- Sinal de referência rampa ruidosa




Figura 2- Controlador PID






Figura 3- Controlador MPC**Figura 4- Controlador RNA**




Figura 5- Controlador Fuzzy 1**Figura 6- Controlador Fuzzy 2**

Figura 7- Controle de nível de todos os controladores**Tabela 1- Sobressinal, tempo de acomodação e erro estacionário**

Controlador	Sobressinal máximo	Tempo de acomodação máximo (s)	Erro estacionário máximo
PID	16%	48	3,5%
MPC	0,15%	16	0%
RNA	16%	80	10%
Fuzzy 1	25%	87	15%
Fuzzy 2	15%	41	4,5%



Figura 8- Ação de controle de todos os controladores**Figura 9- Ação de controle entre 0 e 120s**

Figura 10- Ação de controle entre 120 e 240s




Figura 11- Ação de controle entre 240 e 360s




Figura 12- Índice de desempenho ISE




Figura 13- Índice de desempenho ITSE

