

PROJETO DE CONTROLE PID DIGITAL BASEADO EM SUPERVISÓRIO *FUZZY* VIA CRITÉRIO DE ESTABILIDADE ROBUSTA PELO TEOREMA DO GANHO PEQUENO

ARNALDO PINHEIRO DE AZEVEDO JÚNIOR*, GINALBER LUIZ DE OLIVEIRA SERRA†

* *Universidade Federal do Maranhão*
São Luís, Maranhão, Brasil

† *Instituto Federal do Maranhão*
São Luís, Maranhão, Brasil

Emails: arnaldoee.ifma@gmail.com, ginalber@ifma.edu.br

Abstract— In this paper a methodology for *fuzzy* supervisory control design, from the combination of genetic algorithm technique, robust stability based on the Small Gain Theorem and digital PID control strategy, is proposed. Experimental results to illustrate the effectiveness of the proposed methodology with a case study for modeling and control of a thermal system are presented.

Keywords— Supervisory control, *Fuzzy* systems, Small gain theorem, Digital PID controller, Genetic algorithm.

Resumo— Neste trabalho é proposta uma metodologia para projeto de controle supervísório *fuzzy*, a partir da combinação da técnica de algoritmo genético, estabilidade robusta com base no Teorema do Ganho Pequeno e estratégia de controle PID digital. Os resultados experimentais para ilustrar a eficácia da metodologia proposta, para os quais é feito um estudo de caso de modelagem e controle de um sistema térmico, são apresentados.

Palavras-chave— Controle supervísório, Sistemas *fuzzy*, Teorema do ganho pequeno, Controlador PID digital, Algoritmo genético.

1 Introdução

O tipo de controlador que é mais utilizado em processos industriais é o controlador proporcional-integral-derivativo (PID), graças a sua estrutura simples e bom desempenho em uma larga faixa de condições de operação (Åström and Hägglund, 2006). O projeto deste controlador requer a especificação de três parâmetros: ganho proporcional, ganho integral e ganho derivativo; e ao ajuste destes parâmetros chama-se de sintonia.

No entanto, controladores PID não possuem uma solução geral para todos os problemas de controle, ou seja, com parâmetros fixos não podem produzir resultados satisfatórios para sistemas com características complexas tais como alta ordem, atrasos puro de tempo e não linearidades (Muhammad et al., 2013; Butkiewicz, 2000; Kha and Ahn, 2006). Nesse contexto, a sintonia dos parâmetros é uma questão crucial e a maioria das formulações analíticas que tem sido propostas (Åström and Hägglund, 2006; Visioli, 2001), tal como Ziegler-Nichols (Ziegler and Nichols, 1942), frequentemente falham para alcançar desempenho satisfatório e portanto o especialista tem que usar sua experiência. Por esse motivo, o uso da lógica *fuzzy* tem sido particularmente apropriado, pois permite que o conhecimento adquirido pelo especialista e alguma inteligência adicional seja inserida no controle automático (Visioli, 2001).

O controle supervísório é um controle muti camada (hierárquico), onde o supervísório localiza-se no nível mais alto (Abou Omar et al., 2013).

Este, considera as condições de operação do sistema a ser controlado e modifica os parâmetros do controlador para melhorar seu desempenho (Abou Omar et al., 2013). Esta técnica é muito útil e prática na indústria, pois não requer modificações no *hardware* do sistema de controle original (Soyguder et al., 2009).

Para supervisão de controladores PID, um supervísório *fuzzy* se torna muito útil, considerando sua aplicabilidade para o controle de sistemas com não linearidades e incertezas (Abou Omar et al., 2013). Ou seja, o supervísório *fuzzy* faz uso do conhecimento do especialista e de algum critério de desempenho para ajustar os parâmetros do controlador PID, onde o conhecimento adicional pode estar associado a incertezas ou perturbações no sistema.

O projetista de um sistema de controle deve inferir que há incertezas associadas à qualidade do modelo. Considerando que grande parte dos processos industriais, ao serem modelados, apresentam algum tipo de incerteza, é interessante considerar algum teste de estabilidade que leve em consideração modelos de incerteza. O Teorema do Ganho Pequeno (TGP) é um teste de estabilidade robusta muito prático, pois pode ser aplicado na presença de qualquer tipo de modelo de incerteza (Tong and Li, 2016; Geiselhart et al., 2015; Jiang and Wang, 2008).

Neste artigo é proposta uma metodologia de projeto de controle supervísório *fuzzy*, a partir da combinação das técnicas de algoritmo genético, estabilidade robusta baseada no Teorema do Ganho

Pequeno e estratégia de controle PID digital. Inicialmente, são apresentados os fundamentos da teoria de sistemas *fuzzy*, em seguida são reunidos alguns conceitos sobre o modelo de processo utilizado, modelo de incertezas, Teorema do Ganho Pequeno e sobre o controlador PID, que facilitará o entendimento da metodologia proposta. Por fim, é realizado um estudo caso com um processo térmico para ilustrar a eficiência da metodologia proposta.

2 Fundamentação Teórica

2.1 Controlador PID Digital

A combinação dos ganhos proporcional (K_p), integral (K_i) e derivativo (K_d) são usados para gerar o que é chamado de controlador proporcional-integral-derivativo ou simplesmente controlador PID. A função de transferência resultante de um controlador PID digital é dada por:

$$C(z) = \frac{\alpha + \beta z^{-1} + \gamma z^{-2}}{1 - z^{-1}} \quad (1)$$

onde os parâmetros α , β e γ devem ser ajustados adequadamente no sentido de garantir as especificações pré-estabelecidas ao sistema de controle.

2.2 Teorema do Ganho Pequeno

Um projeto de controle robusto garante que um controlador projetado assegure especificações de desempenho em malha fechada sem um modelo “perfeito” do processo (Ioannou and Sun, 1996). Para isso, espera-se que o controlador opere de forma “satisfatória” para uma família de modelos.

Analiticamente, para um modelo nominal (G_0) dado, um controlador robusto estabilizador para uma família de modelos G_p definida por:

$$G_p(z) = G_0(1 + \delta(z)), \quad (2)$$

onde $\delta(z)$ é uma representação de incerteza (neste caso não estruturada multiplicativa).

O teorema do ganho pequeno (TGP) assegura que, dado um modelo de incerteza $\delta(z)$ e uma a função de sensibilidade complementar, definida como

$$T(z) = \frac{C(z)G_0(z)}{1 + C(z)G_0(z)}, \quad (3)$$

é possível verificar a estabilidade de um sistema de controle para uma família de modelos $G_p(z)$, conforme segue:

$$|T(e^{j\omega})\delta(e^{j\omega})| < 1, \forall \omega. \quad (4)$$

Desse modo, conclui-se que se a Eq. (4) é satisfeita, o controlador $C(z)$ é estavelmente robusto.

3 Metodologia Proposta

Como mencionado, processos físicos reais podem possuir características complexas, de modo que muitas vezes não é recomendável realizar um projeto de controle baseado em modelo fixo. Para solucionar este problema são propostas duas estratégias. Primeiro, a sintonia do controlador é repetida em vários pontos de operação, sendo esta baseada no TGP, o que torna o projeto robustamente estável. Segundo, o supervisor *fuzzy* associa o conjunto de parâmetros $[\alpha^i, \beta^i, \gamma^i]$ no i -ésimo ponto de operação e monta, por sua vez, um mecanismo de ajuste não linear destes parâmetros.

O controlador PID digital determina o sinal de controle, enquanto o sistema de inferência *fuzzy* ajusta *online* os parâmetros do controlador com base nas condições de operação do processo com o objetivo de melhorar o desempenho do sistema de controle em malha fechada, de acordo com o diagrama da Fig.1.




Figura 1: Diagrama de blocos do sistema de controle supervisorio *fuzzy* baseado em critério de estabilidade robusta.

3.1 Identificação do Modelo de Incerteza

Para identificar o modelo de incerteza é necessário estimar o modelo nominal G_0 e perturbado G_p . Isso pode ser feito por meio de uma técnica de identificação de sistemas baseada em um conjunto de dados de entrada e saída coletados experimentalmente.

Matematicamente o modelo nominal é definido como:

$$G_0^i(z) = \frac{b_{01}^i + b_{02}^i z^{-1} + \dots + b_{0m_0}^i z^{-m_0}}{1 + a_{01}^i z^{-1} + a_{02}^i z^{-2} + \dots + a_{0n_0}^i z^{-n_0}}, \quad (5)$$

onde $\rho_0^i = [a_{01}^i \ a_{02}^i \ \dots \ a_{0n_0}^i \ b_{01}^i \ b_{02}^i \ \dots \ b_{0m_0}^i]^T$ é o vetor de parâmetros do modelo nominal no ponto de operação i .

De forma similar, pode-se definir o modelo

perturbado como:

$$G_p^i(z) = \frac{b_{p_1}^i + b_{p_2}^i z^{-1} + \dots + b_{p_{m_p}}^i z^{-m_p}}{1 + a_{p_1}^i z^{-1} + a_{p_2}^i z^{-2} + \dots + a_{p_{n_p}}^i z^{-n_p}} z^{-d}, \quad (6)$$

onde d é o atraso puro de tempo do processo e $\rho_p^i = [a_{p_1}^i \ a_{p_2}^i \ \dots \ a_{p_{n_p}}^i \ b_{p_1}^i \ b_{p_2}^i \ \dots \ b_{p_{m_p}}^i]^T$ é o vetor de parâmetros do modelo perturbado no ponto de operação i .

Por fim, o modelo de incerteza não estruturada multiplicativa é expresso pela seguinte relação:

$$\delta^i(z) = \frac{G_p^i(z) - G_0^i(z)}{G_0^i(z)}. \quad (7)$$

3.2 Supervisório Fuzzy

Como mencionado, a entrada do supervisório *fuzzy* representa alguma condição de operação do processo a ser controlado. Por esse motivo, escolheu-se a saída do processo $y(k)$ como entrada do supervisório *fuzzy*. A Fig.1 mostra o diagrama em blocos do supervisório desenvolvido. A base de regras, por sua vez, é definida por:

$$\mathbf{R}^i : \mathbf{SE} \ y(\tilde{k}) \text{ é } \Upsilon_{\tilde{y}}^i \ \mathbf{ENTÃO} \ \tilde{\alpha} \text{ é } F_{\tilde{\alpha}}^i, \ \tilde{\beta} \text{ é } G_{\tilde{\beta}}^i, \ \tilde{\gamma} \text{ é } \Psi_{\tilde{\gamma}}^i$$

onde i representa o ponto de operação, $\Upsilon_{\tilde{y}}^i$ é o termo linguístico do antecedente, $F_{\tilde{\alpha}}^i$, $G_{\tilde{\beta}}^i$ e $\Psi_{\tilde{\gamma}}^i$, relativos às saídas α , β e γ , respectivamente.

A entrada do supervisório $y(k)$ primeiramente é fuzzificada e convertida para um valor de pertinência que, juntamente com a base de regras, é associada às regras relacionadas de modo que as seguintes saídas podem ser geradas:

$$\mu_{\alpha}(\alpha) = \sup_{y(k) \in \Upsilon_{\tilde{y}}} [\mu_{y^*}(y) \star \mu_{R_{\alpha}}(y(k), \alpha)], \quad (8)$$

$$\mu_{\beta}(\beta) = \sup_{y(k) \in \Upsilon_{\tilde{y}}} [\mu_{y^*}(y) \star \mu_{R_{\beta}}(y(k), \beta)], \quad (9)$$

$$\mu_{\gamma}(\gamma) = \sup_{y(k) \in \Upsilon_{\tilde{y}}} [\mu_{y^*}(y) \star \mu_{R_{\gamma}}(y(k), \gamma)], \quad (10)$$

onde $\mu_{y^*}(y)$ representa a fuzzificação da saída do processo, $\star$ é uma norma-t, $\mu_{R_{\alpha}}(y(k), \alpha)$, $\mu_{R_{\beta}}(y(k), \beta)$ e $\mu_{R_{\gamma}}(y(k), \gamma)$ é a combinação mamdani de todas as regras para as saídas α , β e γ , respectivamente, nos pontos de operação.

Por fim, os valores numéricos dos parâmetros $[\alpha^* \ \beta^* \ \gamma^*]$ do controlador PID digital são obtidos por utilizar um defuzzificador centroide, conforme segue:

$$\alpha^* = \frac{\int_{V_{\alpha}} \alpha \mu_{\alpha}(\alpha) d\alpha}{\int_{V_{\alpha}} \mu_{\alpha}(\alpha) d\alpha}; \quad (11)$$

$$\beta^* = \frac{\int_{V_{\beta}} \beta \mu_{\beta}(\beta) d\beta}{\int_{V_{\beta}} \mu_{\beta}(\beta) d\beta}; \quad (12)$$

$$\gamma^* = \frac{\int_{V_{\gamma}} \gamma \mu_{\gamma}(\gamma) d\gamma}{\int_{V_{\gamma}} \mu_{\gamma}(\gamma) d\gamma}. \quad (13)$$

onde V_{α} , V_{β} e V_{γ} são os universos de discurso referentes às saídas α , β e γ , respectivamente.

3.3 Estratégia Genética para projeto do controlador PID digital

A estratégia genética considerada para otimizar os parâmetros α^i , β^i e γ^i de um controlador PID digital no i -ésimo ponto de operação a partir do TGP é baseada na função custo dada por:

$$f^i(\alpha^i, \beta^i, \gamma^i) = \sup_{\omega} |T^i(e^{j\omega}) \delta^i(e^{j\omega})| \quad (14)$$

onde $T^i(e^{j\omega})$ é a resposta em frequência da função de sensibilidade complementar definida na Eq. (3) e $\delta^i(e^{j\omega})$ é a resposta em frequência do modelo de incerteza não estruturada multiplicativa baseado na Eq. (7).

O cruzamento entre dois *cromossomos* gera dois *descendentes* por um operador de cruzamento simples, como segue:

$$\begin{aligned} \text{cromossomo}_1 &= [p_{m1}, p_{m2}, \dots, p_{mn}] \\ \text{cromossomo}_2 &= [p_{p1}, p_{p2}, \dots, p_{pn}] \\ \text{descendente}_1 &= \eta * p_{mn} + (1 - \eta) * p_{pn} \\ \text{descendente}_2 &= \eta * p_{pn} + (1 - \eta) * p_{mn} \end{aligned}$$

onde os termos p_{mn} e p_{pn} representam os n genes do cromossomo mãe (*cromossomo*₁) e os genes do cromossomo pai (*cromossomo*₂) respectivamente, *descendente*₁ é o novo descendente gerado de dois cromossomos e η é um valor aleatório entre 0 e 1. O operador de mutação seleciona aleatoriamente um gene de um cromossomo da população e modifica seu valor para outro dentro de uma faixa de valores que os ganhos do controlador PID digital podem assumir. O melhor cromossomo da geração anterior é preservado para a próxima geração, que é completada pelos descendentes e o resultado da mutação sobre eles. O estágio de avaliação, classificação, seleção, cruzamento, mutação e formação de uma nova população são repetidos a cada iteração do algoritmo.

4 Resultados Experimentais

A plataforma de controle utilizada nos resultados experimentais deste artigo é composta de um processo térmico, o *software LabVIEWTM* (*Laboratory Virtual Instrument Engineering Workbench*), o CompactRIO 9073, o módulo para entrada analógica NI 9219, o módulo para saída analógica NI 9263, o sensor de temperatura LM 35 e o atuador CI TCA 785. O processo térmico é uma torradeira monofásica de 220 Volts em corrente alternada, com faixa de temperatura no intervalo de 25 °C a 200 °C. O *LabVIEWTM* é um ambiente de desenvolvimento flexível que contém todas as ferramentas para projetar e implementar sistemas

de medição e controle. Na Fig.2 é apresentado a bancada utilizada para implementar a metodologia proposta.




Figura 2: Plataforma utilizada para implementação do sistema de controle proposto.

O Supervisor *Fuzzy* foi projetado com base em três pontos de operação. Os pontos de operação escolhidos foram: $60^{\circ}C$, $100^{\circ}C$ e $150^{\circ}C$. Para cada ponto de operação foi realizada a identificação do modelo de incerteza e o projeto de controle PID digital clássico com base no TGP.

Para estimar o modelo de incerteza em cada ponto de operação é utilizado o método de mínimos quadrados que fornece os vetores de parâmetros ρ_0^i (ver Eq. (5)) e ρ_p^i (ver Eq. (6)) no i -ésimo ponto de operação. Desse modo, encontram-se:

$$\rho_0^1 = [-0,0400 \ 0,0516 \ -0,6570 \ -0,3319]^T, \quad (15)$$

$$\rho_0^2 = [-0,0079 \ 0,0178 \ -0,9682 \ -0,0225]^T, \quad (16)$$

$$\rho_0^3 = [-0,0135 \ 0,0224 \ -1,2441 \ 0,2517]^T, \quad (17)$$

bem como,

$$\rho_p^1 = [-0,0249 \ 0,0100 \ 0,0055 \ 0,0225 \ -0,5993 \ -0,2636 \ -0,1732 \ 0,0487]^T, \quad (18)$$

$$\rho_p^2 = [-0,0036 \ 0,0190 \ -0,0300 \ 0,0213 \ -0,8632 \ -0,3445 \ -0,0597 \ 0,2736]^T, \quad (19)$$

$$\rho_p^3 = [-0,0185 \ 0,0393 \ -0,0258 \ 0,0105 \ -0,9426 \ -0,3267 \ -0,0738 \ 0,3475]^T. \quad (20)$$

Em referência à Eq. (7) pode-se obter as representações de incerteza não estruturada multiplicativa em cada ponto de operação. O diagrama de bode de cada modelo de incerteza pode ser visto na Fig.6.

Por meio do AG foram obtidos os parâmetros dos projetos individuais de controle PID digital clássico em cada um dos pontos de operação considerados. A evolução dos parâmetros α , β e γ do melhor indivíduo em cada geração podem ser vistos em Fig. 3, Fig. 4 e Fig. 5, respectivamente. Além disso, cada um destes parâmetros foram apresentados na Tabela 1.

A base de regras deste problema pode ser definida conforme descrito abaixo:

$$\mathbf{R}^1 : \text{SE } y(k) \text{ é } \Upsilon_y^1 \text{ ENTÃO } \tilde{\alpha} \text{ é } F_{\tilde{\alpha}}^1, \tilde{\beta} \text{ é } G_{\tilde{\beta}}^1, \tilde{\gamma} \text{ é } \Psi_{\tilde{\gamma}}^1$$

$$\mathbf{R}^2 : \text{SE } y(k) \text{ é } \Upsilon_y^2 \text{ ENTÃO } \tilde{\alpha} \text{ é } F_{\tilde{\alpha}}^2, \tilde{\beta} \text{ é } G_{\tilde{\beta}}^2, \tilde{\gamma} \text{ é } \Psi_{\tilde{\gamma}}^2$$

$$\mathbf{R}^3 : \text{SE } y(k) \text{ é } \Upsilon_y^3 \text{ ENTÃO } \tilde{\alpha} \text{ é } F_{\tilde{\alpha}}^3, \tilde{\beta} \text{ é } G_{\tilde{\beta}}^3, \tilde{\gamma} \text{ é } \Psi_{\tilde{\gamma}}^3$$




Figura 3: Evolução do parâmetro α do melhor indivíduo da população ao longo das gerações do AG.




Figura 4: Evolução do parâmetro β do melhor indivíduo da população ao longo das gerações do AG.




Figura 5: Evolução do parâmetro γ do melhor indivíduo da população ao longo das gerações do AG.




Figura 6: Resposta em frequência dos modelos de incerteza nos pontos de operação escolhidos.

Os conjuntos *fuzzy* do antecedente são definidos na Fig.7 e os conjuntos do consequente são definidos na Fig.8.

Com base nestes valores pôde-se montar, por

	α	β	γ
ponto de opera��o 1	3,3444	-3,3510	0,0793
ponto de opera��o 2	3,7014	-3,7349	0,0684
ponto de opera��o 3	4,0000	-4,0421	0,0720

Tabela 1: Valores de α , β e γ do controlador PID digital, nos pontos de opera  o escolhidos.




Figura 7: Conjuntos *fuzzy* do antecedente.




Figura 8: Conjuntos *fuzzy* do consequente.

sua vez, o supervis rio *fuzzy* cujo mapeamento n o linear de par metros   descrito na Fig.9.




Figura 9: Fun  o n o linear de ajuste *online* dos par metros α , β e γ baseada nas condi  es de opera  o do processo.

Para validar a metodologia proposta, foram realizados dois experimentos com o processo t rmico. O primeiro   a implementa  o do supervis rio *fuzzy* e o segundo consiste em um projeto de controle PID digital cl ssico via Ziegler-Nichols.

Nos experimentos realizados, o sistema de controle foi submetido a duas refer ncias de temperatura, uma em $80^\circ C$ e outra em $125^\circ C$ a uma taxa de amostragem de 1 s. O experimento totalizou 2000 s. Para verificar a robustez foi inserida

uma perturba  o din mica na forma de confinamento da temperatura do processo, que ocorreu no instante de tempo $t = 500$ s e foi removida no instante $t = 1500$ s. A seguir s o detalhados algumas caracter sticas observadas nos experimento utilizando o supervis rio *fuzzy* e o projeto de controle PID cl ssico via Ziegler-Nichols com par metros iguais a $\alpha = 0,5167$, $\beta = -0,7833$ e $\gamma = 0,3$.

Na primeira refer ncia de temperatura ($80^\circ C$), no intervalo de tempo de $0 < t < 500$ s, o supervis rio apresentou sobressinal de 3,3933%, tempo de subida de 30,0906 s e tempo de acomoda  o de 488,0822 s, enquanto que o PID cl ssico apresentou sobressinal de 24,5%, tempo de subida de 65,9 s e n o conseguiu acomodar-se. Quando a perturba  o foi inserida e antes da mudan a de refer ncia, no intervalo de tempo de $500 < t < 1000$ s, no supervis rio o sobressinal resultante foi de 8,1328% e o tempo de acomoda  o foi de 509,909 s, enquanto que o projeto cl ssico resultou em um sobressinal de 14,88% e n o conseguiu acomodar-se.

Na segunda refer ncia de temperatura ($125^\circ C$), no intervalo de tempo de $1000 < t < 1500$ s, o supervis rio apresentou sobressinal de 7,1292%, tempo de subida de 19,8760 s e tempo de acomoda  o de 430,500 s. O projeto cl ssico resultou em sobressinal de 20,8%, tempo de subida de 53,48 s e novamente n o conseguiu acomodar-se. Quando a perturba  o foi removida, no supervis rio, no intervalo de $1500 < t < 2000$ s, o *undershoot* resultante foi de 6,7200% e o tempo de acomoda  o foi de 567,900 s, enquanto que no projeto cl ssico o *undershoot* foi de 14,4% e o tempo de acomoda  o foi de 427,8 s.

As caracter sticas da resposta temporal da sa da dos experimentos realizados podem ser vistas na Fig.10, bem como suas respectivas a  es de controle na Fig.11. A varia  o dos par metros do supervis rio durante o experimento pode ser vista na Fig.12.




Figura 10: Resposta temporal da sa da para o Supervis rio *Fuzzy* e PID cl ssico via Ziegler-Nichols.

Para atestar a robustez do supervis rio projetado em rela  o ao projeto PID cl ssico via Ziegler-Nichols   apresentado o valor instant neo do TGP durante os experimentos na Fig.13.




Figura 11: Ação de controle do Supervisório *Fuzzy* e PID clássico via Ziegler-Nichols.




Figura 12: Evolução temporal dos parâmetros α , β e γ do Supervisório *Fuzzy*.




Figura 13: Estimação do TGP para o supervisório *fuzzy* e PID clássico via Ziegler-Nichols.

5 Conclusões

A metodologia de projeto proposta neste artigo que baseia-se em um supervisório *fuzzy* com características robustas graças ao TGP mostrou-se suficientemente eficaz ao ser implementada para o controle de um processo térmico. Percebe-se, por sua vez, que além de combinar melhores desempenhos de projetos de controle PID individuais, feitos em cada ponto de operação, no ponto de vista temporal, o controlador resultante do ajuste feito pelo supervisório garante estabilidade robusta apesar da influência de perturbações. Isso, por sua vez, garante a aplicabilidade da metodologia proposta em controle de processos industriais.

Agradecimentos

Os autores gostariam de agradecer ao IFMA, UFMA e CAPES pelo apoio financeiro no desenvolvimento deste trabalho.

Referências

- Abou Omar, M., Khedr, T. and Abou Zalam, B. (2013). Particle swarm optimization of fuzzy supervisory controller for nonlinear position control system, *Computer Engineering Systems (ICCES), 2013 8th International Conference on*, pp. 138–145.
- Åström, K. and Hägglund, T. (2006). *Advanced PID Control*, ISA-The Instrumentation, Systems, and Automation Society.
- Butkiewicz, B. (2000). System with hybrid fuzzy-conventional pid controller, *Systems, Man, and Cybernetics, 2000 IEEE International Conference on*, Vol. 5, pp. 3705–3709 vol.5.
- Geiselhart, R., Lazar, M. and Wirth, F. (2015). A relaxed small-gain theorem for interconnected discrete-time systems, *Automatic Control, IEEE Transactions on* **60**(3): 812–817.
- Ioannou, P. and Sun, J. (1996). *Robust Adaptive Control*, number v. 1 in *Control theory*, PTR Prentice-Hall.
- Jiang, Z.-P. and Wang, Y. (2008). A generalization of the nonlinear small-gain theorem for large-scale complex systems, *Intelligent Control and Automation, 2008. WCICA 2008. 7th World Congress on*, pp. 1188–1193.
- Kha, N. and Ahn, K. K. (2006). Position control of shape memory alloy actuators by using self tuning fuzzy pid controller, *Industrial Electronics and Applications, 2006 1ST IEEE Conference on*, pp. 1–5.
- Muhammad, Z., Yusoff, Z., Kasuan, N., Nordin, M., Rahiman, M. and Taib, M. (2013). On-line tuning pid using fuzzy logic controller with self-tuning method, *System Engineering and Technology (ICSET), 2013 IEEE 3rd International Conference on*, pp. 94–98.
- Soyguder, S., Karakose, M. and Alli, H. (2009). Design and simulation of self-tuning pid-type fuzzy adaptive control for an expert {HVAC} system, *Expert Systems with Applications* **36**(3, Part 1): 4566 – 4573.
- Tong, S. and Li, Y. (2016). Adaptive fuzzy output feedback control for switched nonlinear systems with unmodeled dynamics, *Cybernetics, IEEE Transactions on* **PP**(99): 1–11.
- Visioli, A. (2001). Tuning of pid controllers with fuzzy logic, *Control Theory and Applications, IEE Proceedings -* **148**(1): 1–8.
- Ziegler, J. G. and Nichols, N. B. (1942). Optimum Settings for Automatic Controllers, *Transactions of ASME* **64**: 759–768.