

SISTEMA DE CONTROLE PREDITIVO POR MATRIZ DINÂMICA EMBARCADO EM UM CONTROLADOR LÓGICO PROGRAMÁVEL

SANDRO JOSÉ GARANI*, JOÃO PAULO CARVALHO HENRIQUES*, ALEXANDRE BARATELLA LUGLI*,
JEREMIAS BARBOSA MACHADO†, FADUL FERRARI RODOR‡

**Instituto Nacional de Telecomunicações, INATEL, Santa Rita do Sapucaí, MG, 37540-000, Brasil*

†*Universidade Federal de Itajubá, IESTI-UNIFEI, Itajubá, MG, 37500-903, Brasil*

Emails: sandroj@inatel.br, joao.paulo@inatel.br, baratella@inatel.br,
jeremias@unifei.edu.br, fadulrodor@gmail.com

Abstract— This paper presents issues about the control of linear dynamic systems, which a Dynamic Matrix Control (DMC) is embedded in a commercial Programmable Logic Controller. The practical results were obtained using an educational temperature plant and the results were compared with a simulation using the Open Source Scilab.

Keywords— Model Predictive Controle, Programmable Logic Controller, Scilab.

Resumo— Neste trabalho é abordado o problema de controle de sistemas dinâmicos lineares, no qual um algoritmo de controle preditivo por matriz dinâmica (DMC) é embarcado em um Controlador Lógico Programável comercial. Os resultados práticos do controlador foram comprovados utilizando uma planta didática de temperatura e os resultados obtidos, utilizando o controlador embarcado, foram comparados com resultados simulados utilizando a ferramenta *Open Source Scilab*.

Palavras-chave— Controle Preditivo, Controlador Lógico Programável, Scilab.

1 Introdução

A utilização de plantas industriais cada vez mais complexas e a demanda por processos mais precisos exigem a utilização de técnicas de controle mais eficientes. Dentre as técnicas de controle avançado adequadas à aplicações industriais, o controle preditivo baseado em modelo têm emergido como uma técnica e apresentado resultados significativos (Camacho and Bordons, 2004).

O controle preditivo baseado em modelo MPC¹ é uma estratégia de controle baseada na otimização do sinal de controle com uma função de custo definida a partir de uma previsão sobre o comportamento do sistema (Camacho and Bordons, 2004). O conceito de controle preditivo foi introduzido nos trabalhos de Richalet et al. (1978) com o IDCOM² e de Cutler and Ramaker (1980) com o DMC³. O trabalho de Clarke et al. (1987) apresentou o controlador preditivo generalizado GPC⁴, o qual difundiu na literatura a metodologia de controle MBPC⁵.

Nos algoritmos de controle preditivo, a lei de controle e, consequentemente o desempenho do sistema em malha fechada, estão relacionados com o modelo do processo a ser controlado. Desta forma, a modelagem do processo é uma etapa vital para o bom desempenho do sistema de controle. Diferentes modelos podem ser utilizados para representação do processo a ser controlado, destacando-se: os sistemas de controle preditivo utilizando modelo CARIMA (Clarke and Mohtadi, 1989), modelos obtidos através de base de funções ortonormais (BFO)(Oliveira, 1997) e mo-

delos utilizando resposta ao impulso e resposta ao degrau (Morari et al., 1989; Kwong, 2010), de especial interesse neste trabalho.

A implementação de tais técnicas de controle em geral demandam a utilização de dispositivos de elevado poder computacional e de alto custo financeiro, o que pode inviabilizar sua aplicação. Desta forma, apresenta-se neste trabalho o desenvolvimento e a implementação de um controlador preditivo DMC em um Controlador Lógico Programável comercial. Pretende-se mostrar a eficiência do sistema de controle bem como a viabilidade computacional de sua implementação em um CLP padrão. Além disso, procura-se com a implementação deste sistema de controle possibilitar uma ferramenta didática para o ensino de técnicas de controle preditivo através da utilização de equipamentos industriais com aplicações reais, tendo em vista que este ensino em geral fica restrito à utilização de simuladores.

2 Identificação de Sistemas Dinâmicos

Modelar um sistema dinâmico significa obter uma representação matemática capaz de descrever as principais características de sistemas físicos reais. Existem diferentes maneiras de representar sistemas dinâmicos utilizando equações e relações matemáticas, podendo haver um modelo que se adapte melhor ao sistema a ser estudado (Ljung, 1999).

Segundo Aguirre (2004), as principais etapas de um problema de identificação são:

- Coleta de Dados do Processo - Os dados de Entrada/Saída do processo a ser modelado são coletados.
- Escolha do Modelo Matemático - Conforme as

¹MPC - *Model predictive control*

²IDCOM - *Identification Command*

³DMC - *Dynamic matrix control*

⁴GPC - *Generalized Predictive Control*

⁵MBPC - *Model Based Predictive Control*

características do sistema a ser modelado, a estrutura do modelo (ARX, ARMAX, Box-Jenkin, dentre outras) é definida. Além disso, nesta etapa é definida a ordem do modelo, o atraso de transporte, etc.

- Estimação dos Parâmetros - Através de procedimentos numéricos, os coeficientes do modelo são obtidos.
- Validação do Modelo - Tendo obtido o modelo original, é necessário verificar se o modelo incorpora todas as características do sistema original.

Algumas representações discretas são especialmente adequadas à modelagem de sistemas utilizando-se algoritmos conhecidos para a estimação de parâmetro (Aguirre, 2004). Dentre elas, pode-se destacar modelo geral de um sistema discreto como apresentado em (1).

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (1)$$

sendo q^{-1} o operador de atraso, $v(k)$ ruído branco e $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ os polinômios definidos em (Aguirre, 2004).

O modelo geral apresentado em (1) é utilizado como base para diversos tipos de modelos como: Modelo auto-regressivo com entradas externas (ARX - *Autoregressive with exogenous inputs*); Modelo auto-regressivo com médias móvel e entradas exógenas (ARMAX - *autoregressive moving average with exogenous inputs*); Modelo de reposta ao impulso finita; Modelo Box-Jenkins dentre outros.

O modelo ARX, de especial interesse neste trabalho, pode ser obtido a partir do modelo geral apresentado em (1), tomando-se $C(q) = D(q) = F(q) = 1$ sendo $A(q)$ e $B(q)$ polinômios arbitrários, resultando na equação apresentada em (2).

$$A(q)y(k) = B(q)u(k) + v(k) \quad (2)$$

Para a estimação dos parâmetros do modelo ARX adotado, utiliza-se o método de mínimos quadrados (Ljung, 1999).

3 Controle Preditivo DMC

Por incorporar na lei de controle restrições operacionais relacionadas com a entrada e saída do sistema e possuir fácil sintonia, os algoritmos de controle preditivo baseados em modelo não estão restritos aos meios acadêmicos, e são utilizados com sucesso na indústria de processos e no controle de máquinas e equipamentos (Xu et al., 2013a; Qin and Badgwell, 2000; Zhao et al., 2001; Seki et al., 2001). Quando comparados às outras metodologias de controle, os controladores preditivos apresentam as seguintes características (Camacho and Bordons, 2004):

- São indicados para controlar desde processos com dinâmica simples até processos multivariáveis e sistemas de fase não-mínima;

- Compensam intrinsecamente atrasos de transporte;
- A extensão do seu algoritmo para o tratamento de restrições é conceitualmente simples;
- Possui uma metodologia aberta baseada em princípios básicos que possibilitam futuras expansões.

Em um algoritmo de controle MPC, o comportamento futuro do processo é predito utilizando o modelo dinâmico do sistema e as medidas disponíveis. A ação de controle é calculada de modo a minimizar a diferença entre a resposta predita do processo e a resposta desejada. A cada instante de tempo de amostragem, o cálculo da ação futura de controle é realizado e as previsões são atualizadas com base nas medidas atuais (Cutler and Ramaker, 1980). A Figura 1 ilustra o comportamento de um algoritmo de controle preditivo com relação ao horizonte de predição (Camacho and Bordons, 2004).




Figura 1: Horizonte de Previsão do Controlador Preditivo.

O horizonte de predição (N_p) representa o intervalo em que é calculado o comportamento futuro do processo. O horizonte de controle N_u corresponde ao número de ações de controle consideradas, e a partir das quais, a entrada do sistema é dada como constante.

O desempenho do sistema em malha fechada durante o horizonte de predição é especificado a partir de um critério de custo, definido através da saída prevista do sistema e do esforço de controle. Desta forma, a ação de controle é calculada a partir da otimização deste critério de custo em relação ao conjunto de sinais de controle a serem aplicados no processo durante o horizonte de predição.

Dentre as técnicas de controle preditivo encontradas na literatura, é de especial interesse neste trabalho o Controle Preditivo por Matriz Dinâmica (DMC), no qual um modelo de convolução discreto do processo (resposta ao degrau) é utilizado para prever a trajetória de saída do sistema no horizonte de predição. Entre as principais características deste tipo de controlador, destacam-se a robustez e o bom desempenho no tratamento de interferências (Xu et al., 2013b). A estrutura básica de um controlador DMC é apresentada na Figura 2.




Figura 2: Diagrama em blocos de controlador preditivo DMC.

Para processo SISO (*Single Input-Single Output*), o DMC utiliza o modelo de convolução discreta variacional recursiva apresentada em (3), relacionando a variável de saída com a variável de entrada ao longo do tempo, para prever a saída no próximo instante de amostragem $k + 1$ (Kwong, 2010):

$$\hat{y}_{k+1} = \hat{y}_k + \sum_{i=1}^N h_i \Delta u_{k+1-i} \quad (3)$$

em que $\Delta u_k = u_k - u_{k-1}$, $\hat{y}_{k+1}$ é a saída predita do sistema no instante de amostragem $k + 1$; u_{k+1-i} é a entrada do sistema no instante de amostragem $k + 1 - i$. Os parâmetros h_i são os coeficientes relacionados com a resposta do sistema a um degrau unitário.

O cálculo da ação de controle de um controlador DMC é baseado na minimização do erro predito em um número finito R de instantes de amostragens futuras. O modelo da convolução variacional pode ser estendido para R instantes futuros como definido em (4).

$$\hat{y}_{k+j} = \hat{y}_{k+j-1} + \sum_{i=1}^N h_i \Delta u_{k+j-i} \quad (4)$$

A informação realimentada y_k permite que a predição seja corrigida recursivamente. Isto equivale a admitir que o erro na predição calculado em (4) corresponde ao erro observado no instante atual k , isto é, $y_k - \hat{y}_k$. Desta forma, a predição corrigida pode ser escrita como apresentado em (5) (Kwong, 2010).

$$\hat{y}_{k+j}^c = \hat{y}_{k+j-1}^c + \sum_{i=1}^N h_i \Delta u_{k+j-i} \quad (5)$$

para $j = 1, 2, \dots, R$ e $y_k = \hat{y}_k$.

Como apresentado em detalhes em Kwong (2010), a estratégia do controlador DMC consiste em obter um sistema sobredeterminado, reduzindo arbitrariamente a dimensão do vetor Δu de R para L admitindo que $\Delta u_{k+j} = 0$ para $j \geq L$. Assim, é possível escrever a forma matricial da equação apresentada em (5) para L ações futuras:

$$\begin{bmatrix} y_{k+1}^c \\ y_{k+2}^c \\ \vdots \\ y_{k+R-1}^c \\ y_{k+R}^c \end{bmatrix} = \begin{bmatrix} a_1 & 0 & \dots & 0 \\ a_2 & a_2 & \dots & 0 \\ & & \ddots & \\ a_{R-1} & a_{R-2} & \dots & a_{R-L} \\ a_R & a_{R-1} & \dots & a_{R-L+1} \end{bmatrix} \dots$$

$$\dots \begin{bmatrix} \Delta u_k \\ \Delta u_{k+1} \\ \vdots \\ \Delta u_{k+L-2} \\ \Delta u_{k+L-1} \end{bmatrix} + \begin{bmatrix} y_k + P_1 \\ y_k + P_2 \\ \vdots \\ y_k + P_{R-1} \\ y_k + P_R \end{bmatrix} \quad (6)$$

em que a_i são os coeficientes da resposta ao degrau definidos em (7) e P_i definidos em (8):

$$a_i = \sum_{j=1}^i h_j \quad (7)$$

$$P_i = \sum_{m=1}^i S_m \quad i = 1, 2, \dots, R \quad (8)$$

$$S_m = \sum_{i=m+1}^N h_i \Delta u_{k+m-i} \quad i = 1, 2, \dots, R \quad (9)$$

Desta forma, o vetor contendo os valores dos erros preditos $\hat{E}$ pode ser calculado pela equação apresentada em (10) (Kwong, 2010):

$$\hat{E} = -A\Delta u + \hat{E}' \quad (10)$$

em que A é a matriz dinâmica de dimensão $R \times L$ definida em 11.

$$A = \begin{bmatrix} a_1 & 0 & \dots & 0 \\ a_2 & a_2 & \dots & 0 \\ & & \ddots & \\ a_{R-1} & a_{R-2} & \dots & a_{R-L} \\ a_R & a_{R-1} & \dots & a_{R-L+1} \end{bmatrix} \quad (11)$$

O sistema sobredeterminado apresentado na equação (10) não possui solução exata. Entretanto, é possível obter a melhor solução no sentido dos mínimos quadrados, minimizando o índice de performance como apresentado na equação (12) (Kwong, 2010)

$$J(\Delta u) = \hat{E}^T Q^T Q \hat{E} \quad (12)$$

em que Q é uma matriz de ponderação definida positiva com dimensão $R \times R$, e permite adicionar uma ponderação nos erros preditos. Desta forma, a solução ótima para a lei de controle é dada pela equação (13).

$$\Delta u = (A^T Q^T Q A)^{-1} A^T Q^T Q \hat{E}' = K_c \hat{E}' \quad (13)$$

no qual K_c é a matriz de ganhos *feedback* com dimensões $L \times R$, calculada a partir da matriz A como apresentado em (14).

$$K_c = (A^T A)^{-1} A^T \quad (14)$$

Para sistemas lineares, de especial interesse neste trabalho, a matriz A é constante e consequentemente a matriz K_c precisa ser calculada uma única vez.

4 Desenvolvimento

Utilizado em grande escala em ambientes industriais, o Controlador Lógico Programável (CLP) foi desenvolvido na década de 70 com o objetivo de automatizar os processos industriais substituindo os antigos painéis de relés. Os primeiros modelos de CLPs executavam o controle de pequenos processos discretos e tinham um custo elevado (Moraes and Castrucci, 2007). Com o passar dos anos, juntamente com a evolução dos sistemas computacionais, surgiram os primeiros CLPs que permitiam a leitura de grandezas analógicas, e consequentemente, o controle de sistemas dinâmicos através de algoritmos de controle clássico, como por exemplo o algoritmo de controle Proporcional Integral Derivativo (PID).

Com o aumento da complexidades dos processos a serem controlados, o desenvolvimento de novos algoritmos de controle se fez necessário. A partir desta necessidade de mercado, no início da década de 2000 surgiram os primeiros CLPs que permitiam ao programador utilizar linguagens de programação de alto nível, como por exemplo o ANSI C e o Texto Estruturado. A utilização destas linguagens no ambiente industrial permitiu que novos algoritmos de controle fossem desenvolvidos e embarcados em CLPs (Capelli, 2008). Neste contexto, o presente trabalho descreve a implementação de um algoritmo de controle preditivo DMC em um controlador lógico programável para o controle de processo reais.

Para a implementação do sistema de controle proposto neste trabalho, o primeiro passo consiste em obter o modelo do processo a ser controlado. Como descrito anteriormente, os algoritmos de controle preditivo DMC utilizam um modelo de convolução discreto a partir da resposta ao degrau da planta em malha aberta. Desta forma, a Figura 3 apresenta o fluxograma contendo os passos necessários para a obtenção do modelo do processo de maneira *offline*, neste caso específico utilizando o software *Scilab* (ENTERPRISES, 2012).




Figura 3: Fluxograma dos passos para a obtenção do modelo para o DMC.

Obtido o modelo do processo a ser controlado e definidos os parâmetros do controlador, o algoritmo

DMC é embarcado no CLP. A partir da saída prevista e da leitura da variável a ser controlada, as ações de controle são calculadas seguindo o fluxograma apresentado na Figura 4.




Figura 4: Fluxograma dos passos para o cálculo das ações de controle.

Os passos apresentados na Figura 4 foram implementados utilizando a linguagem Texto Estruturado e embarcados em um bloco de função denominado *DMCFunctionBlock*. O desenvolvimento deste bloco de função possibilita a utilização deste algoritmo para diferentes processos industriais, uma vez que os parâmetros do controlador DMC (horizonte de predição, horizonte de controle, vetor K_c e vetor A), são tratados como variáveis de entrada do bloco de função. Já a ação de controle é definida como uma variável de saída com valores compreendidos entre 0 e 100%.

A execução do algoritmo apresentado na Figura 4 se dá em um único ciclo do CLP. O tempo de execução deste ciclo (*Cycle Time*) pode ser ajustado de acordo com as características dinâmicas do processo. Para o sistema de controle em questão, o *Cycle Time* foi determinado em função do atraso de transporte do processo a ser controlado como apresentado em (Kwong, 2010).

5 Aplicação e Resultados

A fim de comprovar o funcionamento do algoritmo de controle DMC embarcado, e analisar a viabilidade em relação ao processamento da CPU, utilizou-se uma planta didática de temperatura como apresentado na Figura 5. A planta é formada por uma caixa metálica onde estão instalados um resistor de potência e um relé de estado sólido. A medida de temperatura é feita por um sensor LM35 e um circuito de adequação, uma vez que a entrada analógica do CLP é de 0 a 10 Vdc. Esta planta foi utilizada neste trabalho por estar disponível no laboratório da instituição.

Para a implementação do sistema de controle desenvolvido, utilizou-se um CLP comercial fabricado




Figura 5: Montagem da Planta Didática de Temperatura

pela B&R Automação Industrial, com as seguintes características:

- Processador: ELAN SC520 100 Mhz;
- Memória Principal: 64 MB DRAM;
- Memória de Programa: 48 KB SRAM;
- Um módulo de entrada analógica com A/D de 12 bits e um módulo de saídas digitais a transistor.

Como apresentado na Figura 3, a primeira etapa para a implementação do controlador proposto é a obtenção do modelo processo a ser controlado. Desta forma, aplicou-se um degrau na entrada da planta de temperatura, e os dados de entrada e saída foram amostrados utilizando o CLP, com um período de amostragem igual a 0,1s. Para a obtenção do modelo matemático, neste caso a função de transferência do processo linearizada em torno de um ponto de operação, utilizou-se a representação discreta ARX, no qual a estimação dos parâmetros do modelo foram obtidos através do método dos mínimos quadrados (Aguirre, 2004). A equação (15) apresenta a função de transferência discreta do processo a ser controlado e a Figura 6 apresenta a comparação entre o sistema real e o modelo matemático.

$$H(z) = \frac{0,0002783}{z - 0,9994} z^{-140} \quad (15)$$




Figura 6: Comparação entre o sistema real e o modelo obtido

Obtida a função de transferência do sistema a ser controlado, definiu-se, a partir do trabalho apresentado em Kwong (2010), os parâmetros do controlador DMC: Horizonte de Predição $R = 15$, Horizonte de controle: $L = 10$, Horizonte do Modelo: $N = 30$ e $\alpha = 0$. O tempo de execução do controlador (*cycle time* do CLP), foi determinado em função do atraso de transporte da planta, ou seja, para o controlador em questão definiu-se $T_s = 14s$.

Definidos os parâmetros, o vetor A e a matriz K_c foram calculadas de maneira *offline* e embarcados no CLP. Esta abordagem permite um ganho significativo de processamento dentro do CLP, uma vez que evita cálculos complexos como inversão de matriz na rotina embarcada no CLP. Com objetivo de verificar o funcionamento do sistema de controle desenvolvido, foram aplicados três degraus consecutivos em $45^\circ C$, $55^\circ C$ e $45^\circ C$ no sinal de referência do controlador (*setpoint*). A resposta do sistema em malha fechada é apresentada na Figura 7.




Figura 7: Resposta do Sistema Real

Como pode ser observado na Figura 7, o sistema de controle preditivo atuou corretamente na planta, e a temperatura do sistema atingiu a referência desejada sem nenhum *overshoot* com um tempo de acomodação de aproximadamente $T_a = 140s$. Para fins de validação do sistema de controle embarcado no CLP, realizou-se a comparação entre a resposta real do sistema controlado e a resposta do sistema simulado, utilizando as ferramentas Scilab e Xcos. A Figura 8 apresenta o diagrama em blocos implementado no Xcos, e na Figura 9 apresenta-se a comparação entre a saída do sistema real e a saída do sistema simulado.




Figura 8: Diagrama em Bloco do Sistema Controlado utilizando Scilab




Figura 9: Resposta do Sistema Simulado

Os resultados apresentados na Figura 9 demonstram que o funcionamento do algoritmo de controle preditivo embarcado no CLP se aproxima da resposta obtida a partir do sistema simulado. Além de demonstrar um funcionamento adequado para a planta didática em questão, o controlador DMC não apresentou um custo computacional significativo. A taxa de utilização da CPU presente no laboratório da instituição, obtida através de uma ferramenta nativa do CLP denominada *Profiler*, foi de aproximadamente 1.5%, ou seja, o algoritmo de controle preditivo poderia ser embarcado em outro CLP com menor capacidade de processamento.

6 Conclusões

Neste trabalho apresentou-se o desenvolvimento de um controlador preditivo DMC embarcado em Controlador Lógico Programável. Primeiramente, obteve-se o modelo do processo a ser controlado e definiu-se os parâmetros do controlador DMC. A partir do modelo e dos parâmetros do controlador, a matriz de realimentação K_c e a matriz dinâmica A foram calculados de maneira *offline* utilizando o software de cálculo numérico Scilab. O algoritmo de controle DMC foi implementado em Texto Estruturado e embarcado em um bloco de função em um controlador lógico programável.

De maneira a comprovar o desempenho do projeto, o controlador proposto foi aplicado no controle de uma planta didática de temperatura presente no laboratório desta instituição. Os resultados obtidos mostraram a viabilidade de utilização deste tipo de controle embarcado em *hardware* industrial com baixa capacidade de processamento e baixo custo. A taxa de utilização da CPU na aplicação analisada foi relativamente baixa, com valor de aproximadamente 1.5%. Com objetivo de validar o desenvolvimento do controlador, os resultados obtidos no controle da planta de temperatura real foram comparados com resultados obtidos através de simulação.

Como perspectivas de trabalhos futuros, propõe-

se a implementação de um algoritmo que faça a identificação, sintonia e controle utilizando um algoritmo DMC de maneira *online*, ou seja, todo o processo embarcado no CLP.

Referências

- Aguirre, L. A. (2004). *Introdução à Identificação de Sistemas*, 2ª edn, Editora UFMG, Av. Antônio Carlos, 6627. Belo Horizonte, MG, Brasil.
- Camacho, E. F. and Bordons, C. (2004). *Model Predictive Control*, 2nd edn, Springer.
- Capelli, A. (2008). *Automação Industrial - Controle do movimento e processos contínuos*, Érica.
- Clarke, D. and Mohtadi, C. (1989). Properties of generalized predictive control, *Automatica* **25**(6): 859 – 875.
- Clarke, D., Mohtadi, C. et al. (1987). Generalized Predictive Control, *Automatica*, Vol. 23, pp. 137–160. part i. the basic algorithm and part ii. extensions and interpretations.
- Cutler, C. and Ramaker, B. (1980). Dynamic Matrix Control - A computer control algorithm, *Joint Automatic Control Conference*.
- ENTERPRISES, S. e. a. (2012). *Scilab: Free and Open Source software for numerical computation.*, 2nd edn, Scilab Enterprises, Orsay, France.
- Kwong, W. H. (2010). *Introdução ao controle preditivo com MATLAB*, 1st edn, UFSCAR.
- Ljung, L. (1999). *System Identification: theory for the user*, theory for the user, 2nd edn, Prentice Hall PTR, Upper Saddle River, N.J.
- Moraes, C. C. and Castrucci, P. L. (2007). *Engenharia de automação industrial*, 2 edn, LTC.
- Morari, M., Garcia, C. and Prett, D. M. (1989). Model predictive control: Theory and practice - A survey, *Automatica* **25**(3): 335–348.
- Oliveira, G. H. d. C. (1997). *Controle Preditivo para Processos com Incertezas Estruturadas baseado em Séries de Funções Ortonormais*, PhD thesis, UNICAMP - FEEC.
- Qin, S. and Badgwell, T. (2000). An overview of nonlinear model predictive control applications, *Nonlinear Model Predictive Control*, Vol. 26 of *Progress in Systems and Control Theory*, pp. 369–392.
- Richalet, J., Rault, A., Testud, J. and Papon, J. (1978). Model predictive heuristic control: Applications to industrial processes, *Automatica* **14**(5): 413–428.
- Seki, H., Ogawa, M., Ooyama, S., Akamatsu, K., Ohshima, M. and Yang, W. (2001). Industrial application of a nonlinear model predictive control to polymerization reactors, *Control Engineering Practice* **9**(8): 819 – 828. Advanced Control of Chemical Processes.
- Xu, Z., Yao, Z., Chen, L. and Du, S. (2013a). Greenhouse air temperature predictive control using the dynamic matrix control, *Intelligent Control and Information Processing (ICICIP), 2013 Fourth International Conference on*, pp. 349–353.
- Xu, Z., Yao, Z., Chen, L. and Du, S. (2013b). Greenhouse air temperature predictive control using the dynamic matrix control, *Intelligent Control and Information Processing (ICICIP), 2013 Fourth International Conference on*, pp. 349–353.

Zhao, H., Guiver, J., Neelakantan, R. and Biegler, L. (2001). A nonlinear industrial model predictive controller using integrated {PLS} and neural net state-space model, *Control Engineering Practice* **9**(2): 125 – 133.