

CONTROLADOR PREDITIVO NEURAL DO NÍVEL DO MOLDE DO LINGOTAMENTO CONTÍNUO SINTONIZADO VIA ALGORITMO GENÉTICO

Gustavo Maia de Almeida

Instituto Federal do Espírito Santo

gmaia@ifes.edu.br

José Leandro Félix Salles

Universidade Federal do Espírito Santo

jleandro@ele.ufes.br

Resumo – O Controlador Preditivo Baseado em Modelo (MPC) tem sido cada vez mais aplicado nos processos industriais, pois geralmente exibe um bom desempenho e robustez, desde que os seus parâmetros sejam sintonizados corretamente. Este trabalho utiliza o Algoritmo Genético para realizar a sintonia dos parâmetros do MPC Neural aplicado no controle do nível do molde do lingotamento contínuo, já que não existe nenhum método analítico para resolver este problema de sintonia. O nível do molde é uma das malhas de controle mais importantes na siderurgia, pois variações no nível acima de 10 mm prejudicam a qualidade do aço produzido. A estabilidade e a robustez de dois tipos de algoritmos MPC neural serão comparadas, quando o nível do molde é afetado pelos distúrbios de *clogging* e *bulging*.

Palavras-chave – Controle Preditivo, Algoritmo genético, Lingotamento contínuo, Siderurgia

Abstract – The Model Based Predictive Control (MPC) is increasingly applied in industry because it generally exhibit a good performance and robustness, since the parameters are tuned correctly. In this work, it will be used the Genetic Algorithm to perform the tuning of the Neural MPC parameters, which will be applied in the control of the mold level in the continuous casting process, since there is no analytical method that can be used to solve this tuning problem. The mold level control is one of the most important control loop present in the steel industry, since variations in the level above 10 mm reduce the quality of steel. The stability and robustness of two Neural MPC algorithms will be compared when the mold level is affected by *clogging* and *bulging* disturbs.

Keywords – Predictive Controller, Genetic algorithm, Continuous casting, Steel Industry.

1. INTRODUÇÃO

O Controlador Preditivo baseado em Modelo (MPC) originou-se nos anos 70 e, desde então, tem sido bastante estudado no meio acadêmico e aplicado no controle de diversas plantas industriais ([1]). O MPC geralmente exibe um bom desempenho e robustez, desde que os parâmetros de sintonia sejam adequadamente escolhidos pelo projetista. Entretanto, a seleção dos parâmetros não é uma tarefa fácil, na medida em que não há nenhuma metodologia precisa que assegure a estabilidade ([2]). O método mais usado na literatura para o ajuste dos parâmetros dos MPC atualmente é o tentativa e erro, exigindo, além de um bom conhecimento do processo por parte do operador, também um certo tempo até que a resposta obtida seja satisfatória. Muitas vezes, em processos instáveis em malha aberta, como o Nível do Molde a ser estudado neste trabalho e também em sistemas multivariáveis como o Laminador apresentado em ([3]), não se consegue determinar os parâmetros de sintonia através de tentativa e erro, a fim de obter uma resposta estável e otimizada. Por isto, observa-se na literatura que a aplicação do MPC em sistemas instáveis em malha aberta, lineares ou não, é ainda pouco explorada.

O objetivo é utilizar o MPC com modelo Neural, a fim de realizar o controle do Nível do Molde do Lingotamento Contínuo, o qual é um processo instável em malha aberta e não linear ([4]; [5]). Portanto, para este caso, o método de sintonia do MPC baseado em tentativa e erro é praticamente inviável de ser aplicado, sendo fundamental utilizar ferramentas computacionais baseadas em computação evolucionária a fim de obter automaticamente os parâmetros do controlador. Exemplos de artigos que utilizam o Algoritmo Genético para sintonizar os parâmetros do MPC são encontrados em ([6]; [7]; [8]).

O processo de lingotamento contínuo consiste, basicamente, da transformação do aço, inicialmente em seu estado líquido e temperatura superiores a 1.600°C, em placas de aço de formato, espessura, superfície, consistência e propriedades mecânicas conhecidas segundo padrões existentes. É no molde da máquina de lingotamento contínuo que se realiza o processo de resfriamento primário, formando uma "casca" de aço sólido. Para que isto seja realizado é necessário manter um nível constante e predeterminado de aço líquido no seu interior em diferentes condições de processo.

Apesar da aplicação de controlador clássico PID ser ainda encontrado no controle do molde, a sua frágil robustez diante dos efeitos e variações de parâmetros presentes no processo de lingotamento tem impulsionado pesquisadores do mundo inteiro ao desenvolvimento, tanto na siderurgia quanto no meio acadêmico, de técnicas mais sofisticadas de controle.

Duas técnicas MPC com Redes Neurais serão estudadas: uma delas utiliza Linearização Instantânea do Modelo Neural do Molde e a outra utiliza o Gradiente da Função Objetivo para determinar a ação de controle. Tais métodos serão comparados quanto a robustez, estabilidade e qualidade de controle. O texto possui a seguinte organização: na seção 2 apresentam-se os conceitos básicos do MPC, os algoritmos MPC neural a serem implementados, e mostra-se como o Algoritmo Genético foi utilizado na sintonia destes controladores. Utilizando-se de dados reais, apresenta-se na seção 3 a modelagem da malha de controle do nível do molde usando redes neurais e também é feita a representação matemática dos distúrbios existentes que afetam a qualidade do processo. Na seção 4 discutem-se as simulações computacionais obtidas, apresentando a comparação entre as duas técnicas MPC neural, e na seção 5 é feita a conclusão.

2. O CONTROLADOR PREDITIVO BASEADO EM MODELO (MPC)

Os algoritmos de controle pertencentes à família MPC são caracterizados pelos seguintes elementos:

- i) O Modelo do processo, que tem um papel decisivo no desempenho do controlador, devendo ser capaz de capturar a dinâmica do processo de forma a prever precisamente as saídas futuras, assim como ser simples na sua implementação e entendimento.
- ii) O Preditor, onde se estima a saída futura, que é definida por $\hat{y}(t+k)$, $k = N_1, \dots, N_2$ onde N_1 e N_2 são os horizontes de predição mínimo e máximo, respectivamente.
- iii) A Trajetória de Referência, que é o sinal desejável que a saída do processo siga. A saída poderá ou não ser igual a Referência, dependendo do sinal de controle calculado pelo Otimizador. A Trajetória de Referência definida por w é, normalmente, uma aproximação suave do valor atual da saída, definida por $y(t)$, em direção à referência conhecida (denominada $r(t)$) por meio de um sistema de primeira ordem representado por:

$$\begin{aligned} w(t) &= y(t) \\ w(t+k) &= \alpha w(t+k-1) + (1-\alpha)r(k) \quad k = 1, \dots, N_2 - N_1 \end{aligned} \quad (1)$$

onde α é um parâmetro entre 0 e 1 que suaviza a resposta do sistema à medida que se aproxima de 1.

- v) O Otimizador, através do qual se determina uma sequência de ações de controle definida por $u(t+k)$, $k = 0, 1, 2, \dots, N_u$ onde N_u é denominado horizonte de controle. Estas ações são obtidas minimizando uma função custo, que geralmente é uma função quadrática dada por:

$$J = \sum_{k=N_1}^{N_2} \delta [\hat{y}(t+k) - w(t+k)]^2 + \sum_{j=1}^{N_u} \lambda [\Delta u(t+k-1)]^2 \quad (2)$$

onde $\Delta u(k) = u(k) - u(k-1)$; δ e λ são parâmetros que ponderam os erros de previsão e o sinal de controle, respectivamente.

Uma solução explícita pode ser obtida se o modelo é linear e não existem restrições; caso contrário um método de otimização iterativo tem que ser usado. O primeiro sinal ($u(t)$) da sequência das ações de controle $u(t+k)$, $k = 0, \dots, N_u - 1$ é enviado ao processo, enquanto que o restante da sequência é descartada. Tal estratégia é denominada de "Controle por Horizonte Retrocedente".

2.1 Sintonia do MPC

O bom desempenho do controlador preditivo é obtido somente se os parâmetros de sintonia (horizonte de predição (N_2), horizonte de controle (N_u), ponderação do erro de previsão (δ), fator de supressão (λ), constante da trajetória de referência (α)) forem adequadamente definidos pelo projetista. Em geral esta sintonia é feita através de heurística, baseada em tentativa e erro, sendo viável na sintonia do controlador preditivo de processos que possuem comportamento estável em malha aberta. No, entanto, nos casos em que o processo é instável em malha aberta (como é o nível do molde do Lingotamento Contínuo), este procedimento torna-se entediante, podendo não obter uma resposta estável em malha fechada, ou quando o processo é estabilizado em malha fechada, o desempenho do controlador preditivo fica abaixo das expectativas.

2.1.1 Sintonia do MPC Através do Algoritmo Genético (AG)

Uma das principais características do AG é realizar ajuste de todos os parâmetros de maneira automática. A execução do algoritmo é feita da seguinte maneira: primeiramente, deve-se fornecer o modelo do processo. Em seguida define-se os parâmetros necessários para a execução do AG tais como: o tamanho da população (M), o número de gerações (G), a taxa de crossover e a taxa de mutação, o tipo de função fitness considerada e o critério de seleção. Feito isto, M indivíduos serão criados aleatoriamente por AG, que terão o seguinte formato:

$$[N_u, N_2, \alpha, \delta, \lambda]. \quad (3)$$

sendo que a codificação foi feita com variáveis reais.

Depois disto, cada indivíduo será aplicado dentro do algoritmo do MPC, com o intuito de controlar o processo e calcular o fitness de cada indivíduo dentro da população inicial. Através da função fitness, irá se separar os melhores dos piores indivíduos. A função fitness denominada, Fit é dada por:

$$Fit(N_u, N_2, \alpha, \delta, \lambda) = \frac{1}{\sum (y - w)^2}. \quad (4)$$

onde y é a saída do processo e w é a referência. Logo após, o AG irá fazer a evolução da espécie através da realização das três operações genéticas (reprodução, crossover ponto único e mutação aleatória) onde os melhores indivíduos terão uma probabilidade maior de ter descendentes nas gerações futuras. Neste trabalho, o método de seleção usado foi o da roleta, onde através da Equação 4, se determina a porção que o indivíduo terá dentro da roleta. Foi feito $M - 1$ execuções da roleta para selecionar os indivíduos. Paralelo a seleção por roleta, foi utilizada a técnica de elitismo, onde se assegura que os resultados nunca serão piores do que os da geração anterior.

O AG irá executar um loop de G gerações, e ao final da última apresentar-se-á o melhor indivíduo.

Com este procedimento, basta entrar com o modelo da planta que se deseja controlar para que o algoritmo calcule os valores dos parâmetros do MPC de forma automática. É importante mencionar que o algoritmo desenvolvido neste trabalho pode ser aplicado em qualquer tipo de processo onde se possa utilizar o MPC.

2.2 MPC Neural

No MPC neural o modelo é obtido através de uma rede feedforward com pelo menos uma camada oculta, tendo em vista que tais redes são consideradas estimadores universais ([9]). No caso do modelo neural do Nível do Molde, a rede terá a estrutura NNARX, cuja previsão da saída k passos a frente pode ser escrita como:

$$\begin{aligned} \hat{y}(t+k) &= g[\hat{y}(t+k-1), \dots, \hat{y}(t+k-\min[k, n]), y(t-1), \\ &\dots, y(t-\max[n-k, 0]), u(t+k-d), \dots, u(t+k-d-m)]. \end{aligned} \quad (5)$$

onde: n é o número de regressores da saída, m é o número de regressores da entrada, d é o atraso, g é uma rede perceptron de duas camadas.

As estratégias de controle MPC Neural se diferem, basicamente, na forma de calcular a ação de controle que minimize a função custo J . Uma classe utiliza a regra do gradiente, PNRG e outra realiza uma linearização local da função não linear g da rede PNLI. Os algoritmos destas duas estratégias de controle neural serão descritos a seguir.

2.3 MPC Neural Com Regra Baseada no Gradiente (PNRG)

Seja $U^i(t) = [u^i(t), u^i(t+1), \dots, u^i(t+N_u-1)]$ o vetor de ações de controle a ser determinado a cada iteração i pelo Algoritmo PNRG através da seguinte regra:

$$U^{(i+1)}(t) = U^{(i)}(t) + \mu^i d^i \quad (6)$$

onde μ^i é o passo com que U^i caminha para o mínimo de J e d^i é o vetor direção contrário ao Gradiente da função J em relação a U^i , o qual é denotado por $G[U^i]$. O algoritmo PNRG se baseia no método de Quasi-Newton, o qual considera $d^i = -B^i G(U^i)$, onde B^i é a aproximação da inversa da Hessiana de J em relação a U^i , calculada pelo método de Broyden-Fletcher-Goldfarb-Shanno (BFGS). O Algoritmo PNRG foi proposto por ([10]) sendo descrito resumidamente a seguir:

Passo 0 Selecionar uma sequência de controle U^0 , determinar $G[U^0]$. Fazer $B^0 = I$ e $i = 0$;

Passo 1 Obter $d^i = -B^i G[U^i]$, determinar o passo μ^i e atualizar a sequência de controle conforme (6);

Passo 2 Vá para o Passo 4 se $|U^{i+1} - U^i| < \epsilon$ ou o número máximo de iterações for atingido.

Passo 3 Faça $i = i + 1$, atualize o cálculo de B^i usando o método BFGS, e vá para o passo 1.

Passo 4 Aceitar a sequência U^i como o mínimo de J e pare.

2.4 MPC Neural com Linearização Instantânea (PNLI)

A idéia da linearização instantânea é extrair o modelo linear de uma rede neural não-linear em cada período de amostragem. Assume-se que o modelo de entrada e saída de uma rede neural do sistema a ser controlado é avaliado como:

$$y(t) = g[\varphi(t)] \quad (7)$$

onde o vetor de regressão é dados por:

$$\varphi(t) = [y(t-1), \dots, y(t-n), u(t-d), \dots, u(t-d-m)] \quad (8)$$

O princípio da linearização instantânea é o seguinte (mais detalhes podem ser encontrados em ([10])):

- i) Interpretar o vetor de regressão como um vetor definindo os estados do sistema e o tempo $t = \tau$. Linearize g em torno dos estados corrente $\varphi(t)$ para obter o modelo aproximado.

$$\tilde{y}(t) = -a_1\tilde{y}(t-1) - \dots - a_n\tilde{y}(t-n) + b_0\tilde{u}(t-d) + \dots + b_m\tilde{u}(t-d-m) \quad (9)$$

onde:

$$a_i = -\frac{\partial g[\varphi(t)]}{\partial y(t-i)} \Big|_{\varphi(t)=\varphi(\tau)} \quad b_i = -\frac{\partial g[\varphi(t)]}{\partial u(t-d-i)} \Big|_{\varphi(t)=\varphi(\tau)} \quad (10)$$

e:

$$\tilde{y}(t-i) = y(t-i) - y(\tau-i) \quad \tilde{u}(t-i) = u(t-i) - u(\tau-i) \quad (11)$$

- ii) Separando a parte da expressão que contém os componentes do vetor de regressão corrente, $\varphi(t)$, o modelo linear aproximado pode ser representado como:

$$y(t) = [1 - A(q^{-1})]y(t) + q^{-d}B(q^{-1})u(t) + \zeta(\tau) \quad (12)$$

onde o termo $\zeta(t)$ é dado por:

$$\zeta(t) = y(\tau) + a_1y(\tau-1) + \dots + a_ny(\tau-n) - b_0u(\tau-d) - \dots - b_mu(\tau-d-m) \quad (13)$$

Os coeficientes a_i e b_i são os coeficientes dos polinômios $A(q^{-1})$ e $B(q^{-1})$ do modelo CARIMA.

Após obtido o modelo CARIMA, usa-se o algoritmo do controlador linear GPC para determinar a ação de controle, conforme a metodologia apresentada em ([11]).

3 MODELAGEM DA MALHA DE CONTROLE DO NÍVEL DO MOLDE

O controlador do nível do molde avalia o comportamento do nível medido e envia as devidas correções ao sistema de atuação hidráulica, que posiciona um cilindro acoplado a uma válvula gaveta. A válvula gaveta é um dispositivo formado por três placas sobrepostas que possuem um orifício idêntico em cada uma destas placas, onde a placa central é provida de movimento horizontal (X_{sg}), fazendo com que a área de passagem de aço, consista na área de intersecção dos orifícios. Obtém-se a área efetiva (A_s) de passagem de aço, através de um cálculo considerando a intersecção de orifícios concêntricos de raio R . De acordo com [12] a área efetiva é dada por:

$$A_s = 2 \left[R^2 \cos^{-1} \left(\frac{R - \frac{X_{sg}(t)}{2}}{R} \right) - \left(R - \frac{X_{sg}(t)}{2} \right) \sqrt{RX_{sg} - \left(\frac{X_{sg}(t)}{2} \right)^2} \right] \quad (14)$$

A válvula gaveta está localizada logo após a saída do distribuidor e o transporte do fluxo do aço da válvula gaveta para o molde é feita através da válvula submersa. Considerando o comprimento da válvula submersa de $L = 600mm$ e a velocidade do fluxo de aço na saída da válvula gaveta de $V_n = \sqrt{2 \cdot g \cdot h}$, o atraso de transporte será dado por $T_v = 0,11s$. Assim a equação dinâmica do nível do molde ([12]), é dada por:

$$\frac{dH(t)}{dt} = \frac{1}{A_m} [A_s \cdot V_n(t - T_v) - A_m \cdot V_{cs}(t)] \quad (15)$$

no qual:

H é a altura do nível do molde; A_m é a área do molde; g é a gravidade; h é a altura do fluido entre os níveis de aço do distribuidor e do molde e V_{cs} Velocidade de Lingotamento ou extração da placa.

A partir de (15) chega-se à seguinte função de transferência:

$$H = \frac{1}{A_m s} \left[A_s e^{-sT_v} \sqrt{2gh} - A_m V_{cs} \right] \quad (16)$$

caracterizando-se, portanto, como uma malha integradora (não estável em malha aberta). Para a representação matemática dos demais blocos que compõem a malha de controle, foram realizados experimentos na planta real, afim de identificar o modelo conforme mostra ([13]).

Desta maneira, mostra-se na Figura 1 o sistema não-linear completo simulado no Matlab para representação do processo real de controle do nível do molde.




Figura 1: Diagrama de Blocos da Malha de Controle de Nível do Molde

Em seguida foi realizada a identificação da rede neural que representa o modelo matemático não linear do nível do molde em malha aberta. A rede escolhida possui estrutura NNARX com $m = 2$, $n = 2$ e $d = 1$ na equação (5). Esta rede mostrou-se adequada, pois na etapa de validação o erro de previsão a 10 passos a frente foi menor que 10^{-3} .

3.1 Os Distúrbios Presentes no Controle do Nível do Molde

Em uma malha real de controle de nível de molde, verifica-se a ocorrência de uma série de efeitos inerentes ou não ao processo metalúrgico de produção de placas que afetam de forma direta e indireta o regime estável do nível de aço na superfície do molde, podendo então ser interpretados como distúrbios a serem controlados/reduzidos pelo sistema de controle. A seguir são descritos os efeitos que mais interferem na estabilidade de uma malha de controle de nível de molde, seus comportamentos e as respectivas propostas de representação destes, objetivando retratar com fidelidade o processo a ser controlado.

3.1.1 Distúrbio de Clogging

O acúmulo progressivo de deposição de alumina ou outros produtos nas paredes da válvula submersa e/ou da própria válvula gaveta é conhecido como efeito *Clogging*. Como esse acúmulo é progressivo, há a redução também progressiva da área efetiva de passagem de aço, fazendo-se necessária a compensação pelo controlador da abertura da válvula gaveta. Em adição a esse efeito, há também o desprendimento abrupto da alumina acumulada (*Unclogging*), liberando o fluxo e provocando a necessidade de ação rápida do controlador para retornar o processo às condições anteriores.

O comportamento do efeito de *clogging* pode ser perfeitamente simulado em Matlab, incluindo este na malha da válvula gaveta de acordo com a expressão:

$$A_{clg}(t) = \begin{cases} 1 - \beta_1(t - T_1) & , T_1 \leq t < T_2 \\ f & , T_2 \leq t < T_3 \\ f + \beta_2(t - T_3) & , T_3 \leq t < T_4 \end{cases}$$

onde T_1 é o instante em que inicia o entupimento da válvula gaveta, T_2 é o instante em que ocorre o entupimento máximo, T_3 e T_4 são os instantes em que inicia e termina o processo do desentupimento respectivamente, f é o fator de entupimento máximo tal que $0 < f < 1$ e $f = 1 - \beta_1(T_2 - T_1) = 1 - \beta_2(T_4 - T_3)$.

No processo de *Clogging* real, por observação, é prudente afirmar que os instantes de $T_1 < T_2 < T_3 < T_4$ são aleatórios e encontram-se entre os intervalos: $20s < T_2 - T_1 < 120s$ e $10s < T_3 - T_2 < 60s$, $0 < T_4 - T_3 < 5s$.

3.1.2 Distúrbio de Bulging

A placa de aço, ainda no estado líquido, exerce, portanto uma força ferrostática que tende a empurrar o aço líquido para fora do veio, movimento impedido pelos rolos que compõem os segmentos. Como estes rolos possuem um espaçamento D entre eles, a pele de aço formada cede um pouco, de forma que o aço ocupe parte deste espaçamento. Ao passar pelos rolos, haverá

diminuição do espaço e conseqüente laminação deste aço sólido/líquido, provocando o rearranjo de aço líquido no interior da máquina.

Após passar por entre os rolos, o aço expande-se novamente até o próximo conjunto (caso ainda não tenha sido formada pele espessa o suficiente para contrapor a pressão ferrostática). Este fenômeno de retração e expansão ocorre simultaneamente por toda a máquina onde há presença de aço líquido no interior, chegando até o molde. Como a máquina de Lingotamento possui uma velocidade de extração da placa em seu interior, denominada v_c , verifica-se como efeito decorrente da expansão e retração interna da placa no interior da máquina o surgimento de ondas senoidais na superfície do molde.

Estas ondas são conseqüência, portando, da variação de volume de aço no interior do veio, função do espaçamento entre os respectivos rolos de onde ocorre o fenômeno e da velocidade de extração. A freqüência de oscilação pode ser determinada com boa aproximação por:

$$f_{oscilacao}(Hz) = \frac{V_c(m/min)}{D(m) * 60} \quad (17)$$

Para a simulação do efeito de *Clogging* e *Bulging* no processo identificado, será necessário definir o ponto correto de inserção do fenômeno no diagrama de blocos do processo identificado, na Figura 1.

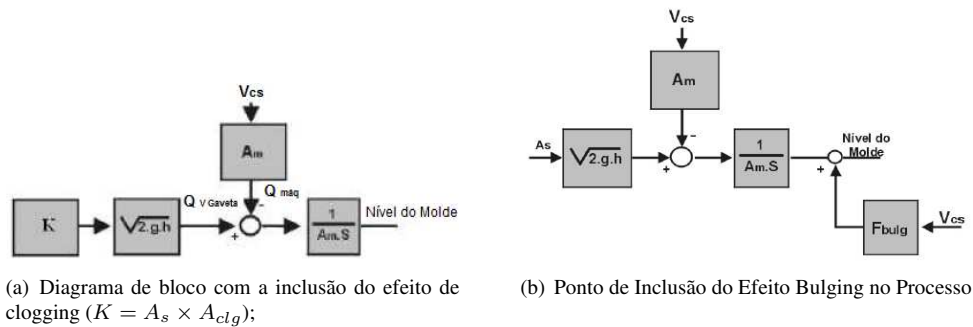


Figura 2: Inclusão dos Distúrbios no Modelo

4. RESULTADOS DA SIMULAÇÃO COMPUTACIONAL

Os algoritmos propostos por ([10]) e discutidos na seção 2 para o controle preditivo neural foram modificados para incluir a sintonia feita através de algoritmo genético, cuja população é constituída por 50 indivíduos com 30 gerações e as taxas de crossover e mutação são de 0,8 e 0,1 respectivamente.

As condições operacionais em que a simulação foi realizada no MatLab são: $h = 1,2m$ (Altura do Distribuidor); $A_m = 0,25m^2$ (área do molde); $\bar{X}_{sg} = 0,35m$ (Abertura da válvula gaveta para uma velocidade constante de $0,02m/seg$). O período de amostragem foi de $0,1seg$.

As restrições no processo são: abertura da Válvula Gaveta ($u(t) \leq 0,7m$) e na sua velocidade de abertura ($\Delta u(t) \leq 0,0041m$ por período de amostragem) e nos limites físicos do sensor do nível do molde ($y(t) \leq 0,2m$).


4.1 Controle Preditivo Neural Sem Distúrbios

Primeiramente, não se considera a presença dos distúrbios relacionados tanto para o caso onde se utiliza a linearização instantânea (PNLI), quanto para o caso onde se utiliza a regra do gradiente (PNRG). Para esta situação os parâmetros ajustados por AG para a sintonia do controle preditivo neural com linearização instantânea foram: $N_u = 10$, $N_2 = 10$, $\alpha = 0,8843$, $\delta = 91,3287$ e $\lambda = 0,0796$. Já os parâmetros ajustados por AG para a sintonia do controle preditivo neural com a regra do gradiente foram: $N_u = 1$, $N_2 = 1$, $\alpha = 0,5755$, $\delta = 747,6628$ e $\lambda = 645,5345$. Desta forma, as respostas a diversos degraus do nível do lingotamento contínuo, apresentadas para os dois controladores sem a presença de distúrbios, são semelhantes e podem ser vistos nas Figura 3(a) e 3(b).

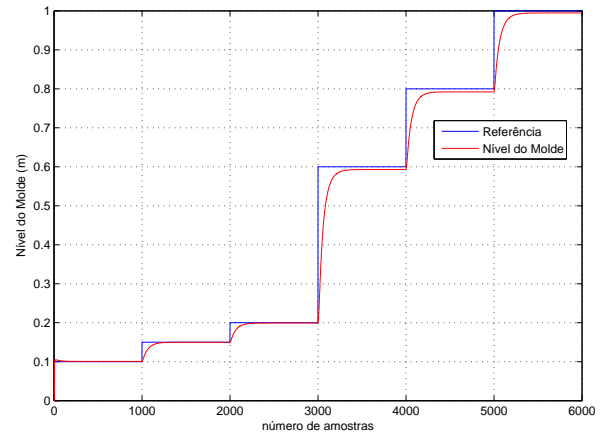
Observa-se através desta Figura, que os controladores projetados, conseguem fazer com que o nível siga a referência em todo o intervalo da altura do molde. Assim, os controladores projetados podem trabalhar em diversas regiões do molde, obtendo um controle satisfatório. É importante mencionar também que os índices *ise* (definido como a inversa da função Fitness dado em (4)) apresentados pelos dois controladores foram muito próximos, sendo de $7,7477$ para o PNLI e de $7,754$ para o PNRG. Os tempos de processamento de cada simulação foram de $32,67seg$. para o PNLI e de $48,44seg$. para o PNRG. Isto se justifica, uma vez que o algoritmo PNRG executa, a cada período de amostragem, um procedimento que determina iterativamente a ação de controle que converge para mínimo da função custo. Já no PNLI a ação de controle é calculada num único passo a cada período de amostragem.

4.2 Controle Preditivo Neural com Distúrbio de Bulging

O distúrbio de *bulging* pode ser representado por um sinal senoidal com amplitude de $20mm$ e uma freqüência $w = (2\pi)(0,077)$ rad/seg, interferindo no nível do Molde. Desta forma, a resposta apresentada pelo sistema de nível do lingota-



(a) Resposta a diferentes degraus do nível com o controlador PNLI



(b) Resposta a diferentes degraus do nível com o controlador PNRG

Figura 3: Comparação entre os Controladores PNLI e PNRG



mento contínuo com a presença do distúrbio de *bulging* utilizando o PNLI e o PNRG, permitiu que as oscilações no nível do Molde fossem reduzidas de $20mm$ para cerca de $5mm$, o que mostra a eficácia destes controladores para este tipo de distúrbio.

Os parâmetros de sintonia dos controladores PNLI e PNRG foram os mesmos anteriores para o caso sem distúrbio. O tempo de simulação foi de $16,73seg.$ para o PNLI e de $25,49seg.$ para o PNRG.



4.3 Controle Preditivo Neural com Distúrbio de Clogging

Neste parte, será simulado o controle de nível do molde com o distúrbio de *clogging*, considerando o pior caso do distúrbio, pois desta forma, tem-se um controlador preditivo robusto. Nas simulações, o fator de entupimento f foi incrementado gradativamente de 10% em 10% para se obter o entupimento máximo para o qual o controlador consegue estabilizar o nível.

As Figuras 4(a) e 4(b), mostram o controle do nível do molde com a presença do distúrbio de *clogging*, onde este entupimento chega até um máximo de 80% para o PNLI e de 75% para o PNRG, bem como os seus respectivos sinais de controle e variação do sinal de controle. Para este caso, é importante mencionar que foi preciso fazer um ressintonia para os dois controladores, tanto o PNLI, quanto para o PNRG, pois os parâmetros utilizados nos exemplos anteriores, não foram capazes de estabilizar o sistema com o entupimento citado. Esses parâmetros foram $N_u = 2, N_2 = 4, \alpha = 0,1342, \delta = 14,2027$ e $\lambda = 1,5825$ para o PNLI e $N_u = 2, N_2 = 4, \alpha = 0,1522, \delta = 825,8170$ e $\lambda = 538.3424$ para o PNRG.



(a) Simulação com Controlador PNLI e Clogging com $f=0,8$



(b) Simulação com Controlador PNRG e Clogging com $f=0,75$

Figura 4: Comparação dos Controladores PNLI e PNRG com Clogging

Observa-se nas Figuras 4(a) e 4(b) que no momento em que se inicia o processo de entupimento, aplica-se um degrau no sistema para que o nível do molde suba, pois, caso contrário, o nível ficaria negativo durante um instante de tempo após ocorrer o desentupimento da válvula, o que não poderia acontecer na prática.

Para que o algoritmo do controlador PNRG consiga controlar o nível com distúrbio *clogging*, é necessário reinicializá-lo no momento em que acontece o desentupimento. Isto é devido aos erros numéricos do cálculo da Hessiana aumentarem no instante

de desentupimento, causando instabilidade no algoritmo PNRG. O tempo de simulação obtido neste experimento foi de 4, 86seg. para o PNLI e de 17, 48seg. para o PNRG.

5. CONCLUSÃO

A partir dos resultados obtidos por simulação computacional, conclui-se que as estratégias PNLI e PNRG possuem desempenhos semelhantes quando o processo está sem distúrbio ou quando apresenta o distúrbio de *bulging*, reduzindo as oscilações na saída de 20mm para 5 mm, o que está dentro da faixa tolerável que é de 10 mm. No entanto, na presença do distúrbio de *clogging*, foi necessário fazer a resintonia dos parâmetros para garantir que o molde não transborde ou esvazie durante o período em que ocorre este distúrbio. Para o pior caso de *clogging*, observou-se uma pequena superioridade do controlador PNLI em relação ao PNRG, pois o primeiro mantém o nível do aço dentro dos limites físicos do sensor, quando o entupimento da válvula atinge 80%, enquanto que no PNRG o máximo entupimento chega a 75%. A explicação para isto é que os erros numéricos no cálculo da aproximação da inversa da Hessiana aumentam consideravelmente no instante de desentupimento da válvula, sendo necessário reiniciar o algoritmo PNRG após este momento. Outra desvantagem é o tempo de processamento maior do PNRG, que necessita de 8,2 milissegundos para calcular a ação de controle a ser aplicada no processo (no PNLI isto é executado na metade deste tempo no máximo). No entanto, este tempo de processamento é suficiente para realizar o controle em tempo real do nível do molde, já que o período de amostragem utilizado no controlador real é 0,01 segundos. Outro comentário relevante é que nos controladores PNLI e PNRG, a ação de controle é do tipo derivativa ($\Delta u(t) = u(t) - u(t - 1)$). Isto é devido ao fato do nível do molde apresentar uma elevada instabilidade à ação de controle integrativa dada por $u(t) = u(t - 1) + \Delta u(t)$, conforme mostra a análise de estabilidade feita em ([13]) para o molde linear.

É oportuno esclarecer que estas conclusões não poderiam ser obtidas se a sintonia do controlador preditivo fosse feita por tentativa e erro, pois para este tipo de processo (instável em malha aberta) esta metodologia não é viável de ser usada. Para trabalhos futuros, pretende-se adaptar filtros à rede neural, tendo em vista que o sinal que entra na rede, vindo do sensor de nível, possui ruídos provocados pela injeção do gás Argônio, presente no processo de lingotamento contínuo do aço.

REFERÊNCIAS

- [1] S. Qin and T. Badgwell. “A Survey of Industrial Model Predictive Control Technology”. *Control Engineering Practice*, vol. 11, no. 7, pp. 733–764, 2003.
- [2] R. R. Bitmead, M. Gevers and V. Wertz. *Adaptative optimal control. The thinking man’s GPC*. System and Control Engineering Englewood Cliffs, New Jersey: Prentice-Hall, 1995.
- [3] G. de Almeida, J. Salles and J. Filho. “Tunning Multivariable Predictive Control of a Hot Rolling Mill With Genetic Algorithm”. In *IX Simpósio Brasileiro de Automação Inteligente (SBAI)*, 2009.
- [4] F. Sanchotene and J. Salles. “Estudo de Caso do Sistema de Controle do Nível do Molde do Lingotamento Contínuo: Modelagem e Aplicação do GPC”. In *VI seminário Nacional de Controle e Automação (SNCA)*, 2009.
- [5] F. Sanchotene, G. de Almeida, A. Mattedi and J. Salles. “Controle Preditivo do Nível do Molde do Lingotamento Contínuo na Presença de Distúrbios e Restrições do Processo”. In *IX IEEE/IAS International Conference on Industry Applications (INDUSCON)*, 2010.
- [6] S. Filalit and V. Wertz. “Using genetic algorithms to optimize the design parameters of generalized predictive controllers”. *International Journal of Systems Science*, vol. 32, no. 4, pp. 503–512, 2001.
- [7] G. de Almeida, J. Salles and J. Filho. “Using Genetic Algorithms for Tuning the Parameters of Generalized Predictive Control”. In *VII Conferência Internacional de Aplicações Industriais INDUSCON*, Recife, 2006.
- [8] G. de Almeida, J. Salles and J. Filho. “Optimal Tuning Parameters of the Dynamic Matrix Predictive Controller with Constraints”. *Latin American Research Applied*, vol. 39, no. 1, 2009.
- [9] A. Farago and G. Lugosi. “Strong Universal Consistency of Neural Networks Classifiers”. *IEEE Trans. On Information Theory*, vol. 39, pp. 1146–1151, 1993.
- [10] M. Norgaard, O. Ravn, N. Poulsen and L. Hansen. *Neural Networks for Modelling and Control of Dynamic Systems*. Springer-Verlag, 2000.
- [11] E. F. Camacho and C. Bordons. *Model Predictive Control*. New York: Springer, 2004.
- [12] S. Yoo. “Development of Mold Level Controller using Sliding Mode Control in a Continuous Casting Processing.” In *Instrumentation and Control Research Team*, Posco, Korea, 1991.
- [13] F. Sanchotene. “Modelagem e Controle no Sistema de Nível de Aço no Molde do Lingotamento Contínuo da Arcelor Mittal Tubarão”. Master’s thesis, DEL-UFES, 2009.