

# MÉTODOS COMPUTACIONAIS PARA OTIMIZAÇÃO DE PROCESSOS METALÚRGICOS<sup>1</sup>

Carlos Eduardo Gurgel Paiola<sup>2</sup>  
Ricardo Caruso Vieira<sup>3</sup>

## Resumo

O objetivo deste trabalho é descrever e estudar uma metodologia de otimização de processos de controle, tendo por base valores históricos de operação. Para exemplificar esta metodologia, é utilizado como objeto de estudo um reator de alta temperatura, típico da indústria metalúrgica. O levantamento do modelo de otimização é feito a partir do uso de ferramentas computacionais específicas, que permitem a maximização dos ganhos do processo e a minimização do uso de recursos. Estas ferramentas contemplam algoritmos genéticos, PCA (Principal Component Analysis), análise de correlação, lógica Fuzzy e árvores de decisão. Passo a passo, a metodologia proposta caminha sobre as seguintes fases: definição do problema, classificação de variáveis, preparação e visualização dos dados, modelamento do processo, análise do modelo resultante e estimativa dos benefícios.

**Palavras-chave:** Otimização; Controle avançado de processo; Modelagem; Simulação; Lógica nebulosa.

## COMPUTATIONAL METHODS FOR METALLURGICAL PROCESSES OPTIMIZATION

### Abstract

The objective of this work is to describe and study a methodology for optimizing process control, based on historical process values. To illustrate this methodology, a high temperature reactor typically used on metallurgical industry is used as the object of study. Optimization model is built from the specific use of computational tools that allow the maximization of process gains while minimizing use of resources. These tools include genetic algorithms, PCA (Principal Component Analysis), correlation analysis, Fuzzy logic and decision-trees. Methodology proposed in this article follows these steps: problem definition, classification of variables, data preparation and visualization, process modeling, analysis of the resulting model and benefits estimation.

**Key words:** Optimization; Advanced process control (APC), Modeling; Simulation; Fuzzy logic.

<sup>1</sup> *Contribuição técnica ao 13º Seminário de Automação de Processos, 7 a 9 de outubro de 2009, São Paulo, SP.*

<sup>2</sup> *Engenheiro de Controle e Automação e Mestre em Engenharia de Sistemas, USP. Gerente de Contas da Aquarius Software (cpaiola@aquarius.com.br, 11-3178-1700).*

<sup>3</sup> *Engenheiro de Controle e Automação e Mestrando em Engenharia de Sistemas, USP. Gerente de Contas da Aquarius Software (rcaruso@aquarius.com.br, 11-3178-1700).*

## 1 INTRODUÇÃO

O objetivo deste trabalho é descrever e estudar uma metodologia de otimização de processos de controle, tendo por base valores históricos de operação. Para exemplificar esta metodologia, é utilizado como objeto de estudo um reator de alta temperatura, típico da indústria metalúrgica.

São utilizadas ferramentas computacionais específicas para o levantamento do modelo de otimização, que permitem a maximização dos ganhos do processo, além da minimização do uso de recursos. Estas ferramentas contemplam algoritmos genéticos, PCA (*Principal Component Analysis*), análise de correlação, lógica Fuzzy e árvores de decisão. Passo a passo, a metodologia proposta caminha sobre as seguintes fases:

- definição do problema;
- classificação de variáveis e preparação e visualização dos dados;
- modelagem do processo; e
- análise do modelo resultante e estimativa dos benefícios.

## 2 SISTEMA OBSERVADO

A metodologia apresentada pretende ser genérica e aplicável a um sistema industrial arbitrário do qual se tenha armazenado uma quantidade suficiente de dados de funcionamento que exemplifique todos os estados alcançados dentro do regime que se deseja otimizar. Nos casos em que o sistema não atingiu estados importantes no período de observação, deve-se avaliar a possibilidade de se forçar essa situação por meio da manipulação planejada de suas variáveis.

Como exemplo, foi adotado um sistema de forno a arco com suas variáveis armazenadas por aproximadamente uma semana amostradas de minuto em minuto.

O primeiro passo é a identificação da função de cada uma das variáveis dentro do sistema. Existem basicamente quatro funções: Meta (*Target*), Perturbação (*Disturbance*), Estado (*State*) e Controle (*Adjustable*). A meta é a variável que se deseja otimizar, isto é, manter em um determinado intervalo de valores. As perturbações são os valores de entrada do sistema que podem ser medidos, mas não podem ser controlados. Os estados são medições produzidas pelo sistema, mas que não desejamos otimizar. Variáveis de controle são as que podemos manipular, mesmo que dentro de determinadas faixas de valores (Tabela 1).

Abaixo são listadas as variáveis do sistema utilizado como exemplo, com suas respectivas classificações. Neste caso, o objetivo é manter a temperatura de fundo estável, visando manter a integridade do anodo.

**Tabela 1.** Classificação das variáveis do sistema

Meta	Perturbação	Estado	Controle
Temp_Anodo	CRO_Cr2O3	Camada_Cong	CaO_Vazao
	FPP	H2	Metal
		CO	MW
		CO2	Minerio_Alum
			Redutor
			Escoria

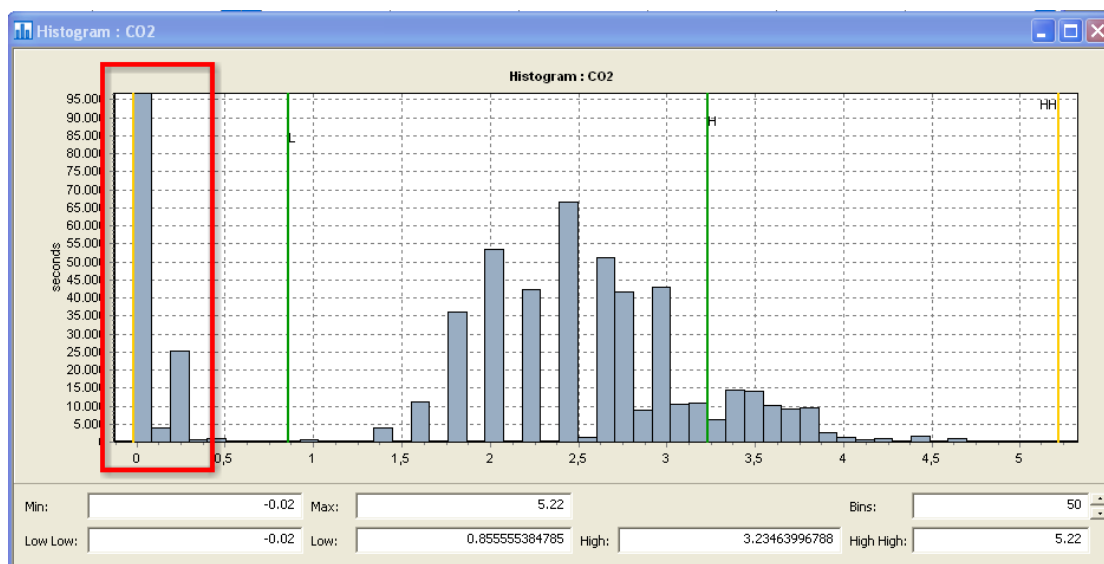
### 3 ANÁLISE E TRATAMENTO DOS DADOS

A metodologia de otimização adotada é inteiramente baseada em medições de processo, portanto é fundamental garantir a qualidade dos dados a serem trabalhados. Dois aspectos que devem ser observados são a taxa de amostragem e a amplitude de cada uma das variáveis.

A taxa de amostragem deve ser suficiente para captar a dinâmica do processo. Um método teórico que pode ser usado como referência é o chamado teorema de Nyquist. Ele sugere que a taxa de amostragem seja minimamente duas vezes menor que a menor constante de tempo do sistema.

Bases de dados criadas pelo funcionamento normal do sistema tendem a apresentar alguns dados em seu conjunto, que não se deseja considerar, como de momentos de desligamento dos equipamentos ou operações fora dos padrões normais. Uma forma rápida de identificar esses pontos é a análise da amplitude do sinal e de seus valores máximos e mínimos, usando análise gráfica por tendência ou histograma.

No exemplo adotado, podemos observar pela um grupo de valores próximos a zero para a variável CO2 (Figura 1), que provavelmente representam um desligamento do forno. Como o objetivo é estudar o processo em regime permanente, esses valores devem ser eliminados.

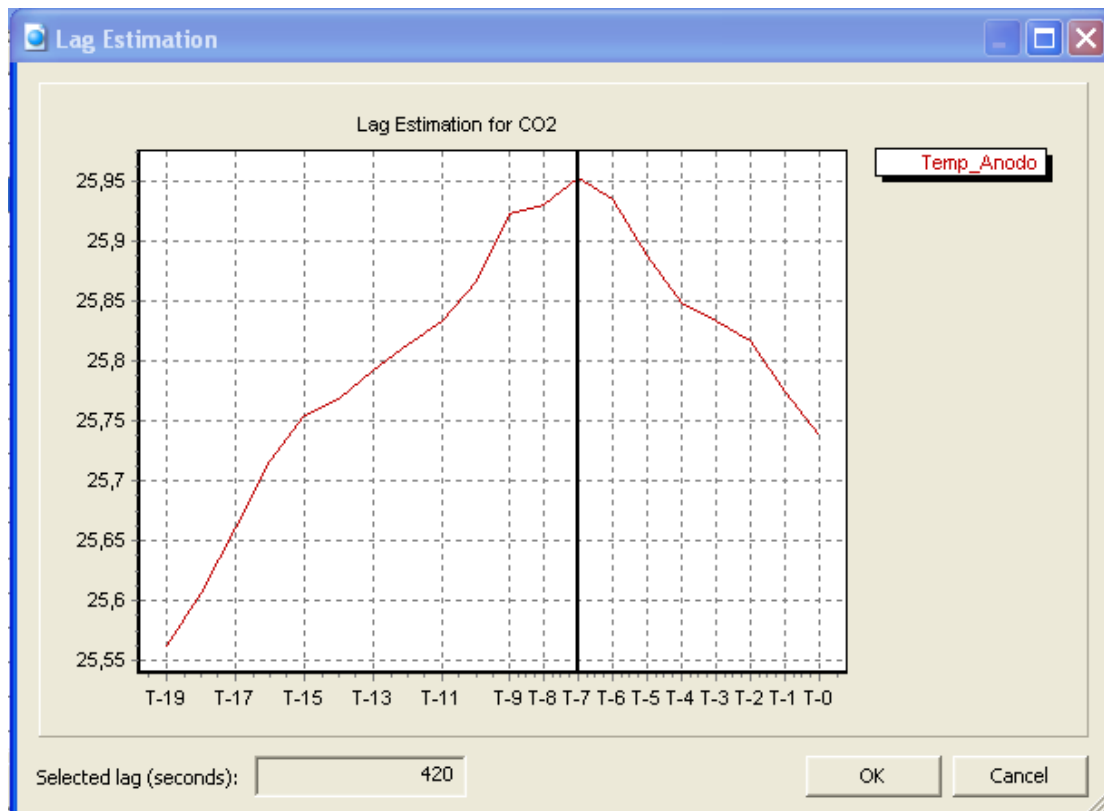


**Figura 1.** Histograma com valores do CO2 a serem desconsiderados.

Como a maioria dos processos não possui apenas uma etapa ou reação, é importante analisar os atrasos entre causa e efeito entre as variáveis. Uma ferramenta matemática bastante usada para esse fim é a chamada correlação

cruzada. Deve-se escolher uma variável como referência e encontrar, por meio da correlação cruzada, os atrasos, positivos ou negativos, das demais. A escolha natural da referência é a variável meta.

O resultado da correlação cruzada é a correlação entre as variáveis, considerando atrasos com passos definidos. O atraso real mais provável é o de maior valor de módulo. Na Figura 2 é apresentado o resultado da correlação cruzada entre o CO2 e o Temp\_Anodo, com o passo de 60s.



**Figura 2.** Correlação cruzada entre CO2 e Temp\_Anodo.

Com as variáveis devidamente tratadas e com os atrasos encontrados, pode-se iniciar o processo de extração de resultados. Um cálculo que pode ser efetuado imediatamente é a matriz de correlação linear.

A matriz de correlação é uma tabela onde os nomes das variáveis são escritos no cabeçalho das linhas e copiados para o cabeçalho das colunas. Cada número no seu interior representa o índice de correlação entre a variável da linha e a variável da coluna. Esse índice é um número de -1 a 1, ou de -100% a 100% sendo que 1 representa que as variáveis são diretamente proporcionais, -1 inversamente proporcionais e 0 que não são correlacionadas. A diagonal principal indica o índice de correlação entre a variável e ela mesma, portanto apresenta sempre valor 1.

Observando-se essa matriz, pode-se ter uma primeira idéia de como as variáveis se comportam em relação às outras. É especialmente importante observar se existem variáveis de controle altamente correlacionadas entre si. Quando isso acontece, é um indício de que provavelmente podemos optar por controlar apenas uma delas, e a outra a seguirá pelas características naturais do sistema.

Construindo-se a matriz para todas as variáveis estudadas, temos os resultados seguintes. Os resultados, em módulo, maiores que 90% foram ressaltados em vermelho e entre 75% e 90% foram ressaltados em azul (Figura 3).



Figura 3. Matriz de correlações.

Essa análise preliminar dos dados já apresenta alguns resultados interessantes. Observando o Temp\_Anodo, meta do estudo, vemos que ele é fortemente correlacionado com a Escória, que é uma variável de controle. Essa informação nos dá um indício de que uma estratégia de controle eficiente para a estabilização da Temp\_Anodo envolve a estabilização da Escória.

#### 4 MODELAGEM POR CASOS

O modelo de casos extrai as principais regras de funcionamento do sistema, usando como base a classificação da variável meta em faixas, tipicamente baixo, normal e alto (Figura 4). Esse modelo permite um estudo de estratégias de manipulação da variável meta por meio das variáveis de controle e é especialmente útil na definição de estratégias de controle e análise corretiva de falhas.

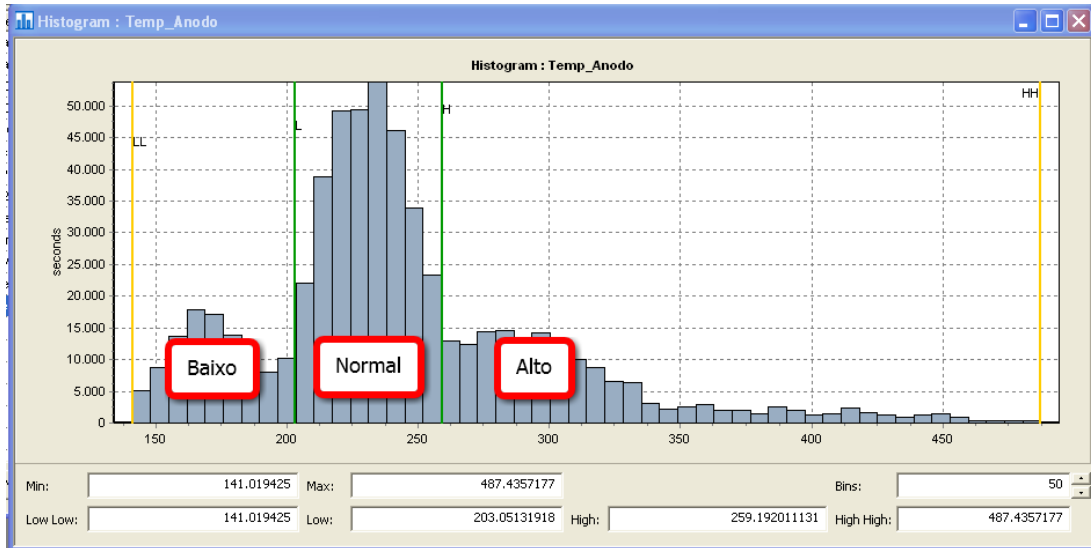


Figura 4. Histograma com a representação das faixas limítrofes.

A forma natural de visualização desse modelo é uma estrutura chamada árvore de decisões. Ela é uma árvore binária com o primeiro nó representando todos os dados considerados no modelo e, a cada camada, esses dados são separados de acordo com critérios de uma única variável (Figura 5).

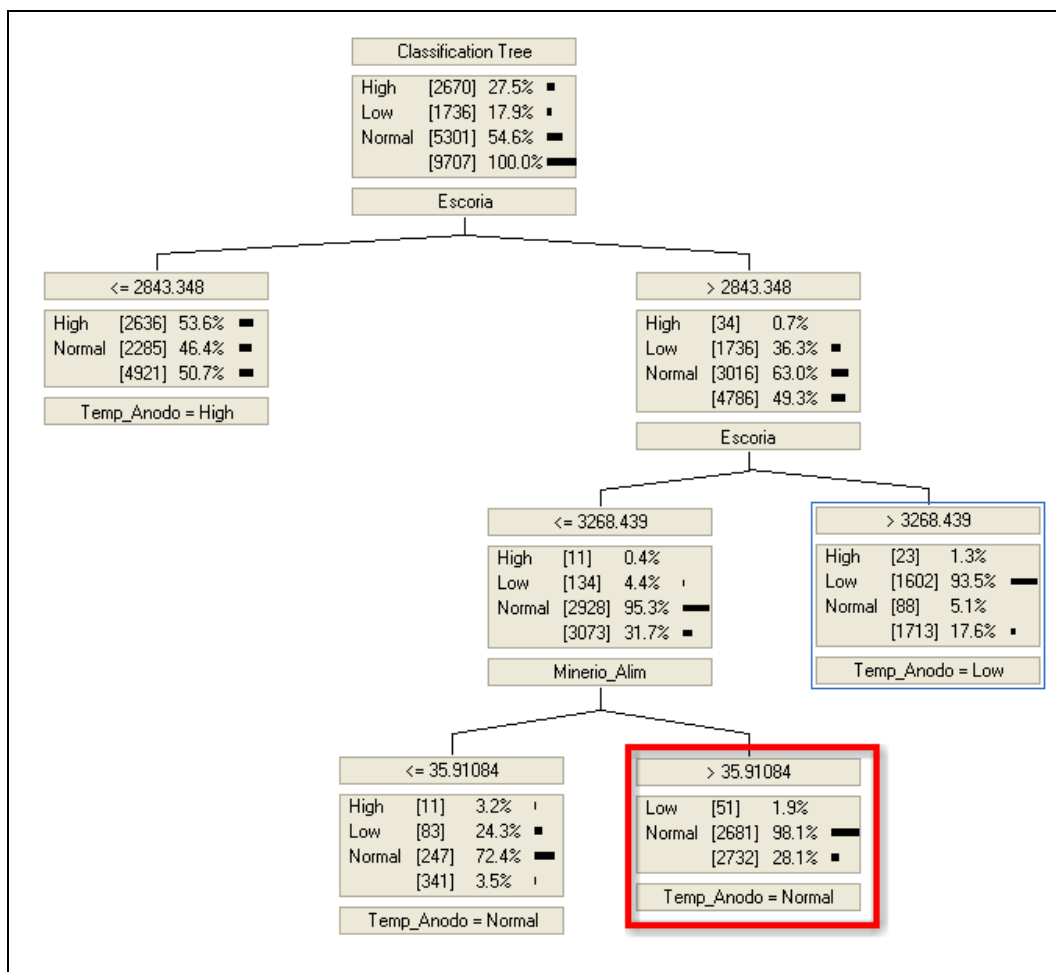


Figura 5. Árvore de decisão.

A árvore da Figura 5 representa um estudo da variável Temp\_Anodo, em relação a Escória e Minério\_Alim. Ela indica que, para os dados estudados, foram mantidas 98,1% das medições dentro da faixa considerada normal quando a Escória foi mantida entre os valores 2843,35 e 3268,44 e o Minério\_alim maior que 35,91.

## 5 MODELAGEM INFERENCIAL

Um modelo inferencial é um modelo matemático levantado a partir de uma série de dados provenientes do processo que se deseja modelar e permite que sejam encontrados valores simulados que não pertenciam ao conjunto inicial. Esses modelos possuem uma série de aplicações, entre elas simulação computacional do processo e desenvolvimento de controladores baseados em modelo.

Uma das técnicas mais abrangentes e versáteis para levantamento de modelos inferenciais é a de redes neurais. Redes neurais são algoritmos matemáticos que imitam o funcionamento dos neurônios do cérebro animal para o desenvolvimento de programas que aprendem com base em uma série de exemplos. Sua principal vantagem sobre os métodos convencionais, como a regressão linear multivariável e a correlação cruzada, é que ela modela de forma bastante eficiente tanto processos lineares quanto não-lineares.

Um cuidado importante que deve ser tomado quando se lida com redes neurais é dividir os dados em conjunto de treinamento e conjunto de validação. Isso é necessário para testar se realmente o modelo descreve o funcionamento do processo ou simplesmente “decorou” a lista de dados passada para treinamento.

Foi desenvolvida uma rede neural para inferir o valor de Temp\_Anodo usando as demais variáveis como entradas. O resultado do teste de validação está apresentado na Figura 6.

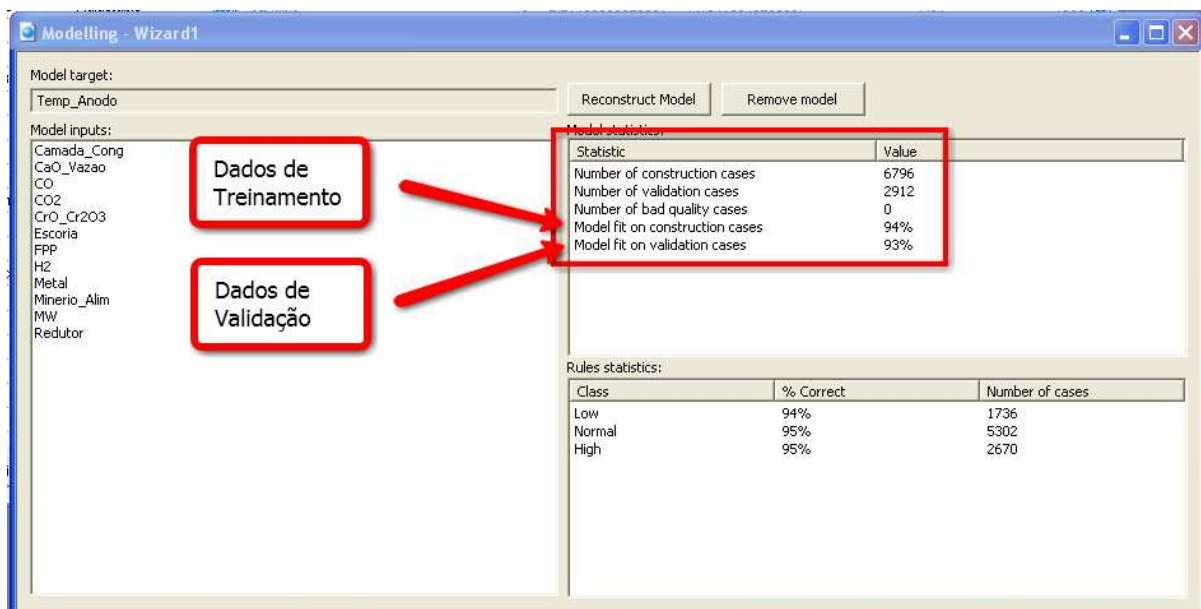


Figura 6. Resultado dos testes de validação com o modelo criado.



## 6 APLICAÇÕES DO MODELO MATEMÁTICO

Com o modelo do processo levantado e validado, as aplicações para otimização são diversas. Com ele, é possível simular situações de operação específicas e prever como seria a resposta do processo a um conjunto de condições. Como exemplo, são citadas três aplicações bastante comuns: Alarme Inteligente, Simulação de Estratégias de Controle e Controle Preditivo.

### 6.1 Alarme Inteligente

Os alarmes configurados nos sistemas de controle, essenciais para a operação, são simplesmente configurações de limites fixos. O sistema apresenta uma mensagem visual ou sonora quando alguma das variáveis superar os valores configurados, indicando que alguma ação deve ser tomada. O operador, usando seu conhecimento sobre o processo, toma as ações corretivas necessárias.

Alarmes inteligentes são sistemas que utilizam o modelo do processo para interpretar as causas de determinadas variações do valor monitorado. Com isso, acompanhando a mensagem de que houve uma variação indesejada, o operador recebe a lista de variáveis que podem ter causado essa variação, com suas probabilidades estatísticas. Essa informação apóia a decisão do operador sobre a melhor medida corretiva, permitindo ações mais rápidas e acertadas.

No caso do forno a arco, ele pode apoiar a operação encontrando o motivo de a variável Temp\_Anodo sair dos limites desejados. Para esse exemplo, foram configurados para o alarme os mesmos limites usados para a classificação da árvore de causas (Figura 7).

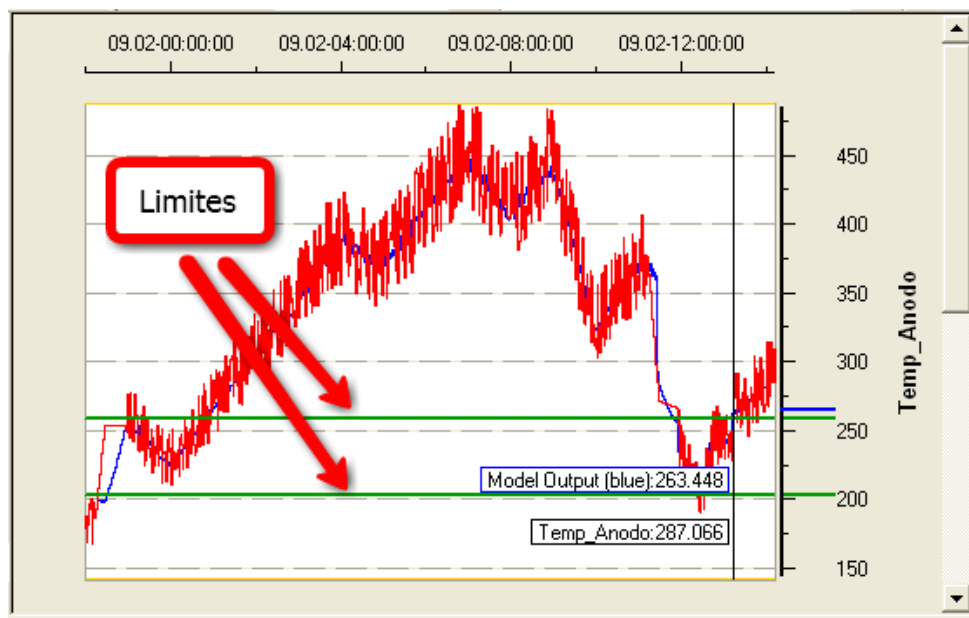



Figura 7. Configuração dos limites de alarme.

Usando o modelo levantado com os dados de treinamento, pode-se, em tempo real, estimar as causas prováveis dessa variação, analisando a contribuição dinâmica de cada uma das demais variáveis.






**Figura 8.** Influência dinâmica de cada variável sobre a Temp\_Anodo.

A conclusão, avaliando o gráfico de barras, é de que a componente mais provável dessa variação é o valor da Escória.

## 6.2 Simulação de Estratégias de Controle

Com a melhoria do poder computacional dos controladores, a possibilidade de usar filosofias de controle além do tradicional PID vem se tornando cada vez mais comum. A parametrização e teste desses controladores normalmente se tornam tarefas complicadas diante da necessidade de manter o processo constantemente dentro de seus padrões de funcionamento produtivo. Com um modelo computacional, os testes podem ser feitos sem riscos para a produção.

No gráfico abaixo (Figura 9), comparamos o valor do Temp\_Anodo que foi coletado com o processo em funcionamento e a mesma variável com um controlador fuzzy experimental controlando o modelo.



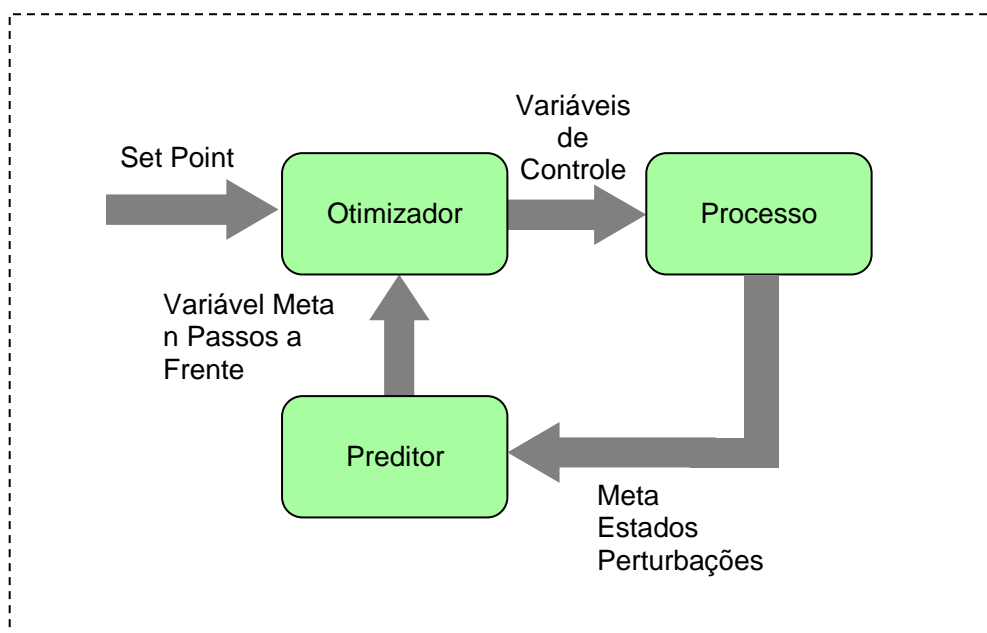
**Figura 9.** Resultado da comparação entre a variável medida e a gerada pelo modelo.

Comparando os histogramas, percebemos que o novo controlador é bem mais eficiente em estabilizar a variável meta do que o anterior. No gráfico de tendência, essa diferença se torna mais clara evitando os valores elevados de temperatura.

### 6.3 Controle preditivo

O controlador preditivo é o controlador que, com base em um modelo do processo, simula seu comportamento alguns passos a frente e, por meio de um algoritmo de otimização, estima uma trajetória otimizada das variáveis de controle.

Esse tipo de controlador é bastante eficiente em situações onde controladores PID não são eficientes, como em processos com grandes não-linearidades ou tempo morto.



**Figura 10.** Controle avançado do processo.

Conforme o esquema da Figura 10, o preditor utiliza do modelo para, com base nos estados, perturbações e no valor presente da meta, prever qual será a variável meta em um intervalo de tempo pré-determinado. Com esse valor, o otimizador estima os melhores valores para as variáveis de controle.

## **7 CONCLUSÃO**

Com a implementação da metodologia proposta, foi possível encontrar um modelo genérico de otimização para processos multivariáveis que detalhou de maneira bastante precisa a dinâmica de interação entre as variáveis do processo.

No caso de estudo, que consiste no controle de um reator, composto por uma camada de escória onde os óxidos são reduzidos para formar uma segunda camada metálica, foi possível obter-se um modelo resultante que permitirá controlar a temperatura do anodo, garantindo que ela seja mantida dentro de uma faixa desejada.

Com a otimização resultante, será possível aumentar a vida útil do reator e, principalmente, otimizar o processo de estudo, reduzindo o uso de matéria prima e energia.

## **REFERÊNCIAS**

- 1 Zaroni, Cícero. Análise Energética de um Forno a Arco. Dissertação de Mestrado em Engenharia Elétrica, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, RS, 2004.
- 2 Burns, Roland S.. Advanced Control Engineering. Ed. Botterworth-Heinemann, Woburn, MA, 2001.
- 3 Documentação da CSense Systems. Catálogo do produto CSense, site da CSense. Disponível em: <http://www.csensesystems.com> Acesso em: 02 jun. 2009.