

Universidade Federal de Minas Gerais
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica
Curso de Especialização em Automação Industrial

MONOGRAFIA FINAL DE CURSO

**MINIMIZAÇÃO DE CUSTOS DE UM SISTEMA
ASPERSOR DE POLÍMEROS EM VAGÕES**

Lucas Dal-Rios Neves

Orientador: Prof. João Antônio de Vasconcelos

Belo Horizonte - MG
Março de 2012

Universidade Federal de Minas Gerais
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica
Curso de Especialização em Automação Industrial

Minimização de Custos de um Sistema
Aspersor de Polímeros em Vagões

Lucas Dal-Rios Neves

Monografia submetida à Banca Examinadora designada pela Comissão Coordenadora do Curso de Especialização em Automação Industrial, como parte dos requisitos necessários à obtenção do Certificado de Especialista em Automação Industrial.

Orientador: Prof. João Antônio de Vasconcelos

Belo Horizonte - MG

Março de 2012

**MINIMIZAÇÃO DE CUSTOS DE UM SISTEMA
ASPERSOR DE POLÍMEROS EM VAGÕES**

Monografia apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais como requisito parcial para obtenção do título de Especialista em Automação Industrial.

Lucas Dal-Rios Neves

Trabalho aprovado em 22 de maio de 2012.

BANCA EXAMINADORA

Prof. Dr. João Antônio de Vasconcelos
(Orientador)

Prof. Dr. Ricardo Luiz da Silva Adriano
(Relator)

AGRADECIMENTOS

Quero agradecer à minha família, que sempre me deu apoio e força em todas as decisões que tomei, e que me amparava nos momentos de incerteza. Principalmente aos meus pais, por me educarem da melhor forma possível.

Meus amigos também foram parte importante nessa caminhada. Também sempre me diziam palavras de incentivo quando pensava que não fosse conseguir essa vitória. A eles devo parte das forças por ter sempre persistido.

Ao Professor João Antônio de Vasconcelos que, apesar de tantas tarefas, aceitou me orientar nesse projeto. Agradeço a todos os professores do Programa de Pós-Graduação em Engenharia Elétrica pelo incentivo constante no decorrer de todo esse tempo de estudo.

Agradeço à ESN Engenharia por ter acreditado no meu trabalho e por incentivar o desenvolvimento de trabalhos que agregam valores tanto para os seus profissionais quanto para a empresa. E à MRS Logística que permitiu que testes fossem realizados no sistema.

À Deus, por ter me abençoado e possibilitado a conclusão deste trabalho.

RESUMO

O sistema aspersor de polímeros é um sistema empregado na impermeabilização do carregamento de vagões que transportam materiais com baixa granulometria, de forma a evitar a dispersão de partículas nas margens da ferrovia, diminuindo a poluição e também a perda de carga. A impermeabilização é realizada por meio da aspersão de uma solução de polímero em água. O sistema deve ser capaz de manter os níveis de dispersão de partículas ao longo do percurso da composição dentro dos limites aceitáveis. A maior parte do custo do processo é atribuída ao alto valor do aglomerante utilizado. Desta forma, fica claro que a variação da concentração de aglomerante, a qual depende de fatores exógenos, como condições climáticas, velocidade de deslocamento da composição de vagões, dentre outras, pode trazer benefícios econômicos, e que a partir da obtenção de um modelo matemático que descreva o consumo de polímero no sistema é possível minimizar o custo de operação do processo. Neste contexto, o objetivo deste trabalho é minimizar o custo desta operação, cujo modelo matemático foi desenvolvido para o Sistema Aspersor de Vagões do Pátio P2-14 da MRS Logística, em Barra Mansa-RJ. Inicialmente é feita a descrição do sistema para a sua modelagem matemática. Após a obtenção do modelo que descreve a função custo e as restrições de operação para o sistema, técnicas de otimização são aplicadas na busca de soluções ótimas de operação que atendam ao modelo encontrado. Por fim, os resultados são analisados quanto à eficiência do modelo encontrado e os benefícios na sua utilização.

ABSTRACT

The sprinkler system of polymer is a system designed to sealing the loading of wagons that carry material with low particle size. This system avoids the dispersion of particles on the banks of the railroad, reduces pollution and reduces the loss of material. The sealing is performed by spraying a polymer solution and the system should be able to maintain the dispersed particles levels within acceptable limits. The most of the process cost is attributed to the high value of the polymer. Thus, the variation of polymer concentration and the variation of other conditions - weather, travel speed, flow, among others - can be economically viable, and the cost of process operation can be optimized if there is a model that describes the consumption of polymer in the system. In this context, the objective of this study is to obtain a mathematical model that describes the cost function for the Sprinkler System of MRS Logística, located in Barra Mansa – RJ. This work begins with a description of the system for mathematical modeling. Optimization techniques are applied to find the optimal points of operation from the model that describes the cost function and constraints for the system operation. Finally, it discussed the efficiency of the model and the benefits found in its use.

SUMÁRIO

RESUMO	3
ABSTRACT.....	4
SUMÁRIO	5
LISTA DE EQUAÇÕES	7
LISTA DE FIGURAS	8
LISTA DE TABELAS	9
LISTA DE SIGLAS E ABREVIACÕES.....	10
1- INTRODUÇÃO	11
2- REVISÃO BIBLIOGRÁFICA.....	13
2.1- IDENTIFICAÇÃO DE SISTEMAS E MODELOS NARMAX.....	13
2.2- ALGORÍTMOS GENÉTICOS	16
2.2.1- Função objetivo.....	17
2.2.2- Restrições.....	17
2.2.3- Variáveis	17
2.2.4- Parâmetros gerais dos algoritmos genéticos	18
2.2.5- Métodos de seleção	19
2.2.6- Operadores genéticos	21
2.2.7- Critérios de convergência	23
2.2.8- Transformação do problema irrestrito em restrito	24
2.2.9- Função de mérito ou desempenho.....	25
3- SISTEMA ASPERSOR DE POLÍMEROS.....	26
3.1- MODELAGEM DO SISTEMA.....	27
3.1.1- Função custo	28
3.1.2- Restrições relacionadas à vazão da bomba de aspersão.....	29
3.1.3- Restrições relacionadas à velocidade da composição	30
3.1.4- Restrições relacionadas à concentração de polímero	30
3.1.4- Restrições relacionadas à dispersão de partículas.....	30
3.2- PROBLEMA PROPOSTO	37
3.3- CONCLUSÕES	39
4- OTIMIZAÇÃO UTILIZANDO ALGORITMOS GENÉTICOS.....	40

5- RESULTADOS E ANÁLISES	42
6- CONCLUSÕES.....	48
REFERÊNCIAS BIBLIOGRÁFICAS.....	50

LISTA DE EQUAÇÕES

Equação (2.1)	14
Equação (2.2)	14
Equação (2.3)	14
Equação (2.4)	15
Equação (2.5)	15
Equação (2.6)	16
Equação (2.7)	22
Equação (2.8)	22
Equação (2.9).....	22
Equação (2.10).....	22
Equação (2.11)	23
Equação (2.12)	23
Equação (3.1)	28
Equação (3.2)	28
Equação (3.3)	28
Equação (3.4)	28
Equação (3.5)	28
Equação (3.6)	28
Equação (3.7)	28
Equação (3.8)	29
Equação (3.9)	29
Equação (3.10)	29
Equação (3.11)	29
Equação (3.12)	29
Equação (3.13)	29
Equação (3.14)	30
Equação (3.15)	30
Equação (3.16)	30
Equação (3.17)	30
Equação (3.18)	30
Equação (3.19)	34
Equação (3.20)	35
Equação (3.21)	35
Equação (3.22)	35
Equação (3.23)	35
Equação (3.24)	35
Equação (3.25)	36
Equação (3.26)	37
Equação (4.1)	40

LISTA DE FIGURAS

Figura 2.1: Diagrama esquemático do estimador MQ para o modelo NARMAX.....	15
Figura 2.2: Diagrama esquemático do AG aplicado na otimização de sistemas.....	19
Figura 2.3: Método de seleção tipo roleta.....	20
Figura 2.4: Método de seleção tipo torneio.....	20
Figura 2.5: Exemplo de cruzamento real.....	22
Figura 2.6: Exemplo de mutação real.....	23
Figura 3.1: Sistema aspersor de polímeros em vagões do pátio P2-14.....	26
Figura 3.2: Diagrama funcional do sistema aspersor de polímeros em vagões.....	27
Figura 3.3: Amostragem de partículas suspensas no ar para carregamento do dia 30/08/2011..	32
Figura 3.4: Comparação dos resultados obtidos - modelo proposto x medições realizadas.	36

LISTA DE TABELAS

Tabela 2.1: Classificação dos algoritmos de otimização.....	16
Tabela 3.1: Dados coletados entre os dias 30 de agosto a 01 de setembro de 2011.....	33
Tabela 3.2: Termos selecionados de acordo com ERR.	34
Tabela 3.3: Número de partículas dispersas na carga aspergida ($\mu\text{g}/\text{m}^3$).....	36
Tabela 5.1: Amostragem de 10 indivíduos, método roleta e 100 gerações.....	42
Tabela 5.2: Amostragem de 20 indivíduos, método roleta e 100 gerações.....	42
Tabela 5.3: Amostragem de 30 indivíduos, método roleta e 100 gerações.....	42
Tabela 5.4: Amostragem de 10 indivíduos, método roleta e 1000 gerações.....	43
Tabela 5.5: Amostragem de 20 indivíduos, método roleta e 1000 gerações.....	43
Tabela 5.6: Amostragem de 30 indivíduos, método roleta e 1000 gerações.....	43
Tabela 5.7: Amostragem de 10 indivíduos, método torneio e 100 gerações.....	44
Tabela 5.8: Amostragem de 20 indivíduos, método torneio e 100 gerações.....	44
Tabela 5.9: Amostragem de 30 indivíduos, método torneio e 100 gerações.....	44
Tabela 5.10: Amostragem de 10 indivíduos, método torneio e 1000 gerações.....	45
Tabela 5.11: Amostragem de 20 indivíduos, método torneio e 1000 gerações.....	45
Tabela 5.12: Amostragem de 30 indivíduos, método torneio e 1000 gerações.....	45

LISTA DE SIGLAS E ABREVIACOES

AIC	Akaike Information Criterion
AG	Algoritmo Genético
BFGS	Broyden Fletcher Goldfarb Shanno
CONAMA	Conselho Nacional do Meio Ambiente
DFP	Davidon Fletcher Powell
DS	Deterministic Sampling
ERR	Error Reduction Ratio
MQ	Mínimos Quadrados
NARMAX	Non-linear AutoRegressive Moving Average with eXogenous inputs
RMSE	Root Mean Squared Error
SRS	Stochastic Remainder Sampling
PPF	Pellet Feed Fines

1- INTRODUÇÃO

Grandes esforços têm sido feitos na modernização de plantas industriais com o objetivo de otimizar seus processos de forma a propiciar melhorias de produtividade, qualidade, redução de consumo de insumos e conseqüente aumento dos lucros. Isto pode ser observado pelos recentes investimentos das empresas.

Porém, representar plantas e processos industriais por meio de modelos e equações matemáticas sempre foi um grande desafio [GAR05]. Apenas com o advento da informática, com computadores mais baratos e com maior capacidade de processamento e velocidade, a identificação de sistemas pôde fazer uso de técnicas mais avançadas e que exigiam um enorme esforço matemático, desta forma a modelagem de sistemas tem sido cada vez mais estudada e praticada [AGU04].

Sistemas reais expressos por representações matemáticas podem ser mais bem compreendidos, o que ajuda na resolução de possíveis problemas e na própria melhoria do sistema em questão. Trabalhando com sistemas matemáticos não é necessário que haja um conhecimento prévio do sistema para que possíveis problemas sejam resolvidos. A representação matemática também permite que técnicas de otimização de sistemas sejam aplicadas, sem necessidade do conhecimento de todas as leis que regem o sistema real. Desta forma, este trabalho faz a modelagem matemática de um sistema aspersor de polímeros a partir de técnicas de identificação de sistemas.

Com um modelo bem determinado, o objetivo deste trabalho é utilizar técnicas de otimização de sistemas para que os custos de operação possam ser reduzidos. Para a tarefa de otimização do sistema escolheu-se uma técnica bem conhecida e muito utilizada [HOL92; GOL89], os algoritmos genéticos.

O presente capítulo é destinado à contextualização do trabalho e à descrição da relevância do tema. No segundo capítulo é realizada uma revisão bibliográfica das técnicas de identificação de sistemas utilizadas na modelagem matemática. Ainda no segundo capítulo, são apresentadas algumas definições e conceitos a respeito dos algoritmos genéticos, ferramenta utilizada para a minimização dos custos do processo. O terceiro capítulo traz uma descrição do sistema aspersor de polímeros em vagões que foi escolhido para o trabalho, neste capítulo também é realizada a modelagem matemática do sistema aspersor, com sua função de custo e restrições encontradas para o sistema. No quarto capítulo, com o modelo já determinado, são aplicados os conceitos

dos algoritmos genéticos para a minimização do custo de operação. O quinto capítulo traz os resultados encontrados e algumas análises dos mesmos. Finalmente, no sexto capítulo são apresentadas as conclusões e propostas de continuidade deste trabalho.

2- REVISÃO BIBLIOGRÁFICA

No presente capítulo é apresentado um estudo sobre os métodos de identificação de sistemas. Também é apresentado um breve histórico, conceitos e aplicações de algoritmos genéticos.

2.1- IDENTIFICAÇÃO DE SISTEMAS E MODELOS NARMAX

A modelagem matemática é a área do conhecimento que estuda maneiras de desenvolver e implementar modelos matemáticos de sistemas reais. Há várias técnicas de se obter estes modelos, uma delas é a modelagem caixa branca, onde características do sistema modelado são conhecidas. Existe também uma técnica conhecida como modelagem caixa preta, onde o sistema é modelado sem se ter um conhecimento do sistema real, apenas se faz necessário conhecer as entradas e saídas do sistema. No que diz respeito à modelagem caixa preta, de acordo com [LJU99], o problema de identificação de sistemas pode ser dividido em cinco etapas principais:

- Obtenção de dados de experimentação do sistema que se deseja modelar;
- Aplicação de testes aos dados obtidos para detecção de não linearidades;
- Escolha da estrutura que será utilizada para representar o modelo;
- Estimação dos parâmetros do modelo; e
- Validação do modelo obtido.

Este procedimento é empregado na identificação tanto de sistemas lineares quanto sistemas não-lineares.

No procedimento de identificação, o sistema deve ser experimentado por meio da aplicação de entradas adequadas e da observação das saídas correspondentes. Os dados de identificação assim obtidos serão utilizados, por exemplo, na detecção de não linearidades e no ajuste dos parâmetros do modelo escolhido.

A identificação e modelagem de sistemas não lineares têm sido bastante estudadas e, nos últimos anos, diversos modelos e estruturas foram propostas. Isto inclui os modelos não lineares NARMAX (Non-linear AutoRegressive Moving Average with eXogenous inputs), introduzidos por Billings and Leontaritis [BIL82; LEO85]. Os modelos NARMAX descrevem sistemas não lineares em equações de diferenças de

termos relacionando a saída atual com combinações de entradas e saídas antigas. Deste modo estes modelos são capazes de descrever uma ampla variedade de sistemas não lineares. Este método é utilizado em problemas de controle onde o principal objetivo é encontrar uma simples descrição do processo.

Os modelos NARMAX podem ser representados conforme a equação 2.1:

$$y(k) = F^l[y(k-1), \dots, y(k-n_y), u(k-1), \dots, u(k-n_u), e(k-1), \dots, e(k-n_e)] + \varepsilon(k), \quad (2.1)$$

em que: F^l é uma função polinomial de grau l ;

$y(k)$ é a saída do sistema no instante k ;

$u(k)$ é a entrada exógena do sistema no instante k ;

$e(k)$ é o ruído do sistema no instante k ;

$\varepsilon(k)$ é o erro de predição do sistema no instante k ; e

n_y, n_u e n_e são as ordens do sinal autoregressivo, das entradas externas e da média móvel, respectivamente.

A função F^l pode representar diversos tipos de funções, incluindo funções lineares. Se isto acontecer o modelo da equação 2.1 torna-se ARMAX.

Após selecionar o tipo de função F^l o desenvolvimento de um modelo para o sistema é necessário. Assim a estimação dos parâmetros do modelo é de vital importância. Um método rápido e eficiente para a determinação dos parâmetros é o estimador de mínimos quadrados (MQ) [BIL88]. Este método tem sido utilizado em diversas aplicações para determinação de modelos não lineares [NEP02; NEV07].

Para o processo de estimação de parâmetros, a equação 2.1 deve ser escrita como o modelo de predição de erros, expresso na equação 2.2:

$$y(k) = \psi^T(k-1)\hat{\theta} + \varepsilon(k), \quad (2.2)$$

em que $\psi^T(k-1)$ é a matriz de regressores com n_θ combinações de termos de processo e ruído até o instante $(k-1)$, e $\hat{\theta}$ é o vetor de parâmetros a ser estimado.

O vetor de parâmetros é relacionado aos regressores da seguinte forma:

$$\hat{\theta} = [\hat{\theta}_y^T \hat{\theta}_u^T \hat{\theta}_e^T \hat{\theta}_{yue}^T], \quad (2.3)$$

em que $\hat{\theta}_y, \hat{\theta}_u$ e $\hat{\theta}_e$ são os parâmetros lineares dependentes da saída, entradas exógenas e sinais de ruído respectivamente. $\hat{\theta}_{yue}$ representa os parâmetros não lineares resultantes das combinações dos parâmetros lineares.

A saída do modelo é representada pela equação 2.4:

$$\hat{y}(k) = \psi^T(k-1)\hat{\theta}, \quad (2.4)$$

e então, o erro de predição é expresso conforme a equação 2.5:

$$\varepsilon(k) = y(k) - \hat{y}(k). \quad (2.5)$$

Porém, em alguns sistemas a variedade de combinações de parâmetros pode ser muito grande e o número de termos do modelo se tornaria elevado trazendo problemas em sua resolução, como por exemplo, mau condicionamento numérico. Determinar quais os termos são os mais significantes e quais devem entrar no modelo é uma tarefa importante. Existem diversas estruturas de detecção e algoritmos para estimação como parte da metodologia NARMAX, dentre estas estruturas pode-se destacar o critério de informação Akaike (AIC) [HAK74], a seleção baseada em grupamentos de termos [AGU04] e o critério que leva em consideração a taxa de redução de erro (ERR) [BIL88].

No caso ERR os termos mais importantes do modelo são incluídos inicialmente e então os termos menos significativos são adicionados até que o modelo tenha um número de termos considerado ideal. Isto é exatamente o que o estimador MQ e ERR fazem baseados nos dados. Os termos mais significantes do modelo são adicionados antes, um a um. A Figura 2.1 mostra um esquema do estimador MQ para o modelo NARMAX.

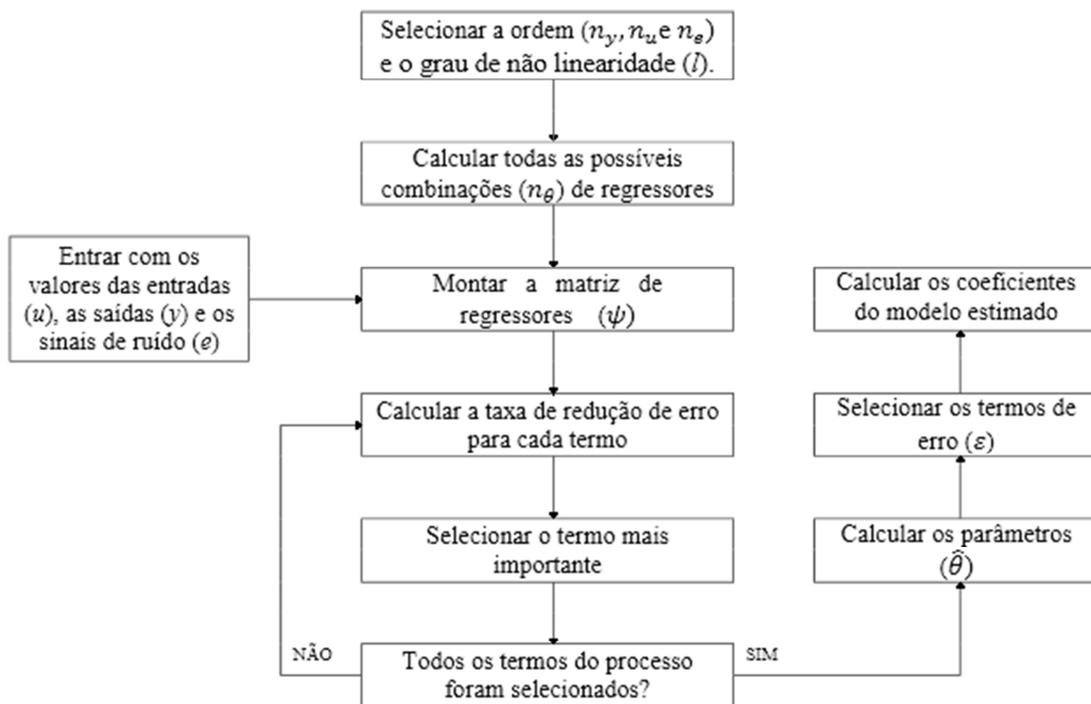


Figura 2.1: Diagrama esquemático do estimador MQ para o modelo NARMAX.

Após determinar a estrutura, os parâmetros podem ser estimados utilizando a estrutura clássica do estimador MQ:

$$\hat{\theta} = (\psi^T \psi)^{-1} \psi^T y. \quad (2.6)$$

Assim, o estimador apresentado pode estimar todos os coeficientes desconhecidos no modelo da equação 2.1.

2.2- ALGORÍTMOS GENÉTICOS

Em sistemas complexos, existem muitas interações entre variáveis e diversas restrições aos sistemas. Desta forma, a formulação matemática para um problema real, tenta fazer uma aproximação para que o sistema seja entendido, analisado e otimizado com menos dificuldade.

O conceito de otimização de sistemas está bem identificado como um mecanismo de análise de decisões, que tem como objetivo quantificar performances e selecionar as melhores. Assim, fica evidente que um bom julgamento é fundamental na interpretação dos resultados na busca de conclusões significativas.

Diversas são as ferramentas de procura e seleção de resultados para problemas de otimização. Soares (1997) classifica estes métodos de seleção em três grupos principais: determinísticos, enumerativos e estocásticos. A divisão em grupos e exemplos de estratégias pode ser observada na Tabela 2.1.

Tabela 2.1: Classificação dos algoritmos de otimização.

Técnicas de Procura	Métodos Determinísticos	Sem Cálculo de Derivadas	Coordenadas Cíclicas, Rosenbrock, outros
		Com Cálculo de Derivadas	Newton, Steepest Descent
		Direções Conjugadas	BFGS, DFP, Fletcher & Reeves
		Métodos de Penalidade	Exterior, Interior, Interior Extendida
		Outros	Elipsóide
	Métodos Enumerativos	Programação Dinâmica.	
	Métodos Estocásticos	Algoritmos Evolucionários	Estratégias evolucionárias.
			Algoritmos Genéticos
		Outros	Tabu
			Simulated Annealing

Os métodos estocásticos têm ganhado popularidade devido a sua robustez. Eles buscam a solução a partir de regras de probabilidade e também existe a facilidade de não trabalharem com derivadas. A principal motivação para utilização de algoritmos genéticos (AG's) vem de sua potencialidade que combina procedimentos de busca direcionada com busca aleatória.

Os AG's são algoritmos de otimização global, baseados nos mecanismos de seleção natural e da genética. Eles fazem uma busca paralela por pontos de alta aptidão, pontos ótimos do sistema baseados na função objetivo, de forma ao mesmo tempo estruturada e aleatória.

Para o bom entendimento dos algoritmos genéticos é necessário definir alguns conceitos gerais de otimização e do método de busca. Os mesmos serão descritos a seguir.

2.2.1- Função objetivo

Função que expressa o sistema o qual se deseja maximizar ou minimizar. A função objetivo descreve o comportamento do sistema de acordo com suas variáveis. Como AG's são mecanismos de busca e/ou desenvolvimento de indivíduos que apresentam função de aptidão acima da média, os AG's trabalham com conceitos de maximização de funções objetivos.

2.2.2- Restrições

Assim como a função objetivo, as restrições de um sistema são funções que expressam o comportamento do sistema de acordo com suas variáveis. As restrições definem limitações do espaço de busca por soluções. Uma solução para um problema de otimização só se caracteriza como ponto ótimo se atender a todas as restrições do sistema.

2.2.3- Variáveis

As variáveis de um sistema são características físicas que podem assumir diferentes valores numéricos. A combinação das variáveis descreve tanto a função objetivo, quanto as restrições do sistema. Em sistemas complexos podemos ter diversas combinações de valores de variáveis e o objetivo da otimização de sistemas é justamente encontrar as combinações mais favoráveis. Em problemas de otimização pode-se observar dois tipos de variáveis, as controladas e não controladas. Conforme a nomenclatura, as variáveis controladas podem ser variadas conforme a necessidade de controle do sistema, já as variáveis não controladas sofrem variações em seus valores sem que haja uma ação de controle.

2.2.4- Parâmetros gerais dos algoritmos genéticos

Os AG's tentam simular o processo de evolução buscando indivíduos mais rápidos geração a geração. Esta busca está diretamente relacionada com os operadores genéticos, que são estratégias de seleção, parâmetros de cruzamento e de mutação, elitismo, dentre outros.

Alguns conceitos e parâmetros gerais são apresentados a seguir:

Indivíduo – corresponde uma combinação de variáveis que representa uma possível solução para o problema.

Tamanho da população – deve corresponder ao espaço de busca das soluções do problema. Não existem definições para o tamanho correto de uma população, para sua definição é necessário levar fatores como tempo de processamento e precisão do processo. Uma população muito grande, por exemplo, pode fazer com que o processamento seja mais lento, porém faz com que se aumentem as chances de se obter um resultado mais preciso.

Comprimento do genótipo – o genótipo é o conjunto ou amostra da população que será avaliada. O comprimento é determinado em função do número de variáveis em estudo, assim quanto maior o comprimento, maior a probabilidade de os pontos ótimos estarem entre os indivíduos selecionados para o genótipo.

Seleção de indivíduos – consiste em separar dentre todos os indivíduos da população aqueles que darão origem a uma nova geração. Ainda neste capítulo alguns métodos de seleção serão abordados

Operadores genéticos – são os operadores genéticos os responsáveis por gerar uma nova geração da população a partir da combinação de indivíduos da geração atual. Ainda neste capítulo serão abordados os seguintes operadores: cruzamento, mutação e elitismo.

Critérios de convergência – são os responsáveis por avaliar se a solução encontrada satisfaz.

Conhecidos estes conceitos básicos, já é possível apresentar a estrutura do algoritmo utilizada para a otimização do sistema. O diagrama esquemático do AG é mostrado na Figura 2.2 e alguns outros conceitos serão discutidos nas seções seguintes.

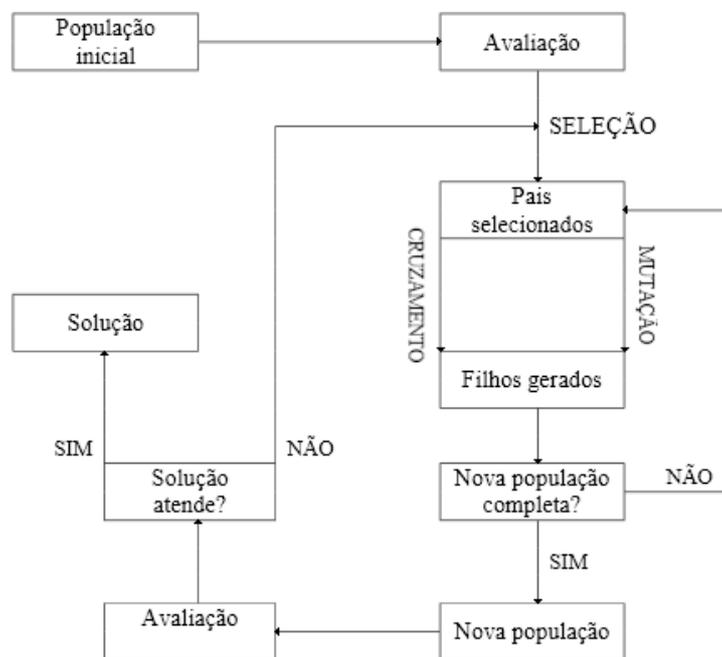


Figura 2.2: Diagrama esquemático do AG aplicado na otimização de sistemas.

2.2.5- Métodos de seleção

Existem diversos métodos de seleção de indivíduos, dentre eles podemos destacar:

Roleta – Uma nova geração é selecionada por meio de sorteio baseado em roleta. Cada indivíduo é representado proporcionalmente ao seu índice de aptidão. Assim, indivíduos com maior aptidão têm mais chances de ser selecionados. Este

método é bastante utilizado, pois tende a uma rápida convergência. A Figura 2.3 exemplifica o método de seleção tipo roleta.

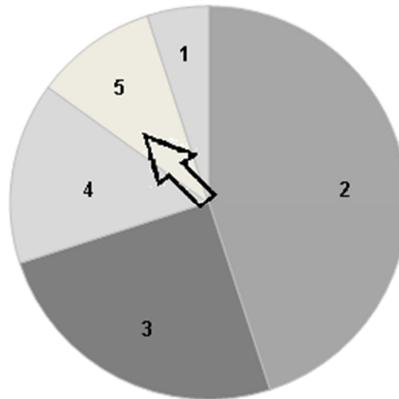


Figura 2.3: Método de seleção tipo roleta

Torneio – O método seleciona uma amostra da população e escolhe seu melhor indivíduo para a nova geração. O procedimento é repetido até que o número de indivíduos determinado para a próxima geração seja atingido. O método de torneio faz com que indivíduos com pouca aptidão possam ser selecionados para gerações futuras. A Figura 2.4 exemplifica este método.

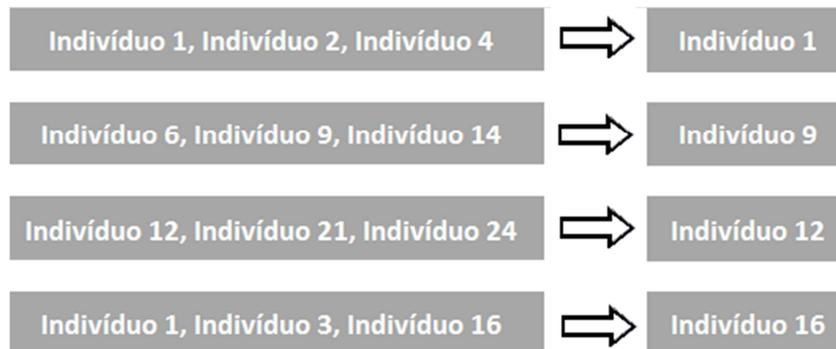


Figura 2.4: Método de seleção tipo torneio

Deterministic Sampling (DS) – Este método faz a média dos valores de aptidão dos indivíduos e calcula uma porcentagem (valor de aptidão do indivíduo pelo valor médio de aptidão). Esta porcentagem indica quanto de chance cada indivíduo tem de ser selecionado. Os indivíduos são escolhidos até que o número de indivíduos da nova geração seja alcançado. A Tabela 2.2 mostra um exemplo de amostragem para indivíduos com o respectivo fator de aptidão.

Tabela 2.2: Exemplo de indivíduos e fatores de aptidão.

	Fator de Aptidão
Indivíduo 1	258%
Indivíduo 2	23%
Indivíduo 3	47%
Indivíduo 4	29%
Indivíduo 5	136%
Indivíduo 6	107%

No exemplo da Tabela 2.2, o indivíduo 1 teria duas cópias selecionadas pois tem mais de 200% de chances em um sorteio. Analogamente os indivíduos 5 e 6 teriam uma cópia cada. Os indivíduos devem ser selecionados até que o número de indivíduos para a próxima geração seja alcançado. Caso o número de indivíduos desejados na nova geração não seja atingido, pode-se selecionar o restante dos indivíduos considerando o fator de aptidão como método de classificação, ou seja, os indivíduos 1, 3, 5, 4, 2 e 6 seriam selecionados nesta ordem, pois possuem fatores de 58%, 47%, 36%, 29%, 23% e 7% respectivamente.

Stochastic Remainder Sampling (SRS) – Este método se assemelha à seleção por DS. Só que ao contrário do anterior ele não seleciona os melhores indivíduos, de fato estes têm uma probabilidade maior de serem selecionados. No exemplo da Tabela 2.2, cada indivíduo teria uma probabilidade de ser selecionado, ou seja, o indivíduo 1 teria 257% de chances (o que corresponde a dois indivíduos selecionados e uma probabilidade de 57% de ter um terceiro indivíduo), o indivíduo 2 teria 23% de chances e assim sucessivamente.

2.2.6- Operadores genéticos

Os operadores genéticos utilizados para a formação de novas gerações (filhos) a partir da população atual (pais) são:

Cruzamento – Este operador faz uma combinação das características dos pais para gerar novos indivíduos. Pode-se considerar como padrão para cruzamento a codificação real considerada por [QIN01], em que:

$$X_{1...kcross}^{n+1,i} = \alpha_{pol} \times X_{1...kcross}^{n,i} + (1 - \alpha_{pol}) \times X_{1...kcross}^{n,j} \quad \text{se } dir = 1, \quad (2.7)$$

$$X_{1...kcross}^{n+1,j} = (1 - \alpha) \times X_{1...kcross}^{n,i} + \alpha \times X_{1...kcross}^{n,j} \quad \text{se } dir = 1, \quad (2.8)$$

$$X_{kcross...nvar}^{n+1,i} = \alpha_{pol} \times X_{kcross...nvar}^{n,i} + (1 - \alpha_{pol}) \times X_{kcross...nvar}^{n,j} \quad \text{se } dir = nvar, \quad (2.9)$$

$$X_{kcross...nvar}^{n+1,j} = (1 - \alpha) \times X_{kcross...nvar}^{n,i} + \alpha \times X_{kcross...nvar}^{n,j} \quad \text{se } dir = nvar, \quad (2.10)$$

onde: $kcross$ é um número aleatório que identifica a variável no intervalo $[1, nvar]$;
 α_{pol} é um coeficiente de multiplicação polarizado escolhido no intervalo $]0.5, 1]$;
 α é um coeficiente de multiplicação para cruzamento linear escolhido no intervalo $[-0.1, 1.1]$;
 dir é uma variável binária aleatória que indica a direção seguida no cruzamento, se do ponto de corte até a última variável (para $dir = nvar$), ou do ponto de corte até a primeira variável; e
 $X^{n,i}$ e $X^{n,j}$ dois indivíduos selecionados para se cruzarem.

Pode-se exemplificar um cruzamento real para dois indivíduos com duas variáveis com a Figura 2.5:

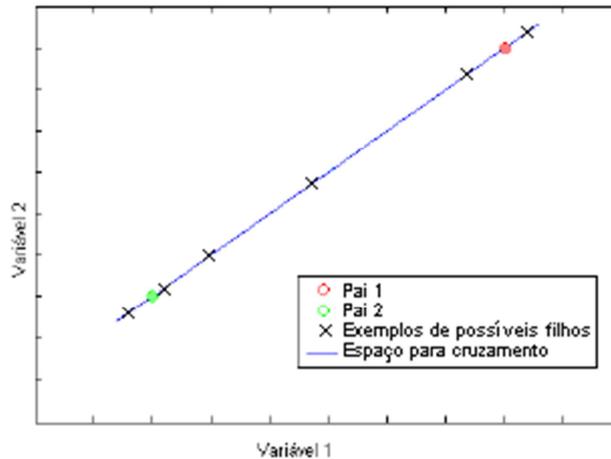


Figura 2.5: Exemplo de cruzamento real.

Mutação – Este operador permite a inserção de novas características genéticas ou até mesmo a restauração de características perdidas anteriormente. Pode-se

considerar como padrão para mutação a codificação real considerada por [QIN01], em que:

$$\gamma_{1...kmut}^{n,i} = 0,05 \times \beta \times range_{1...kmut}^{n,i} \quad \text{se } dir = 1, \quad (2.11)$$

$$\gamma_{kmut...nvar}^{n,i} = 0,05 \times \beta \times range_{kmut...nvar}^{n,i} \quad \text{se } dir = nvar, \quad (2.12)$$

em que: $kmut$ é a variável aleatória que define a realização da mutação;

β é um número aleatório com distribuição uniforme no intervalo $-1 \leq \beta \leq 1$;
 $range$ é a amplitude da faixa definida pelos limites máximo e mínimo de cada variável; e
 dir indica em qual direção a mutação será realizada (da variável de referência para mais ou menos).

Pode-se exemplificar uma mutação real para dois indivíduos com duas variáveis com a Figura 2.6:

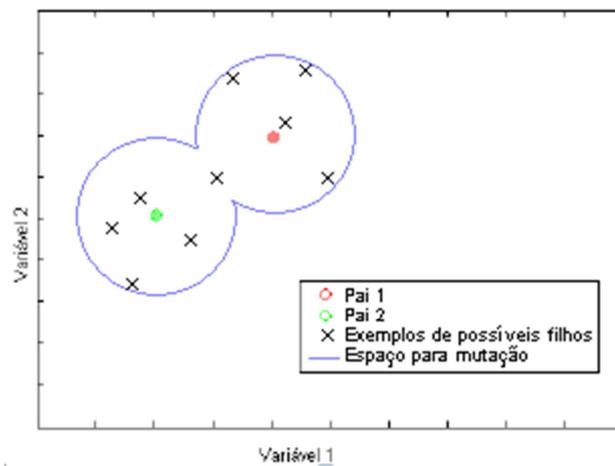


Figura 2.6: Exemplo de mutação real.

Elitismo – Este operador carrega através das gerações o melhor indivíduo representante de sua geração, desta forma, não se perde o melhor ponto encontrado.

2.2.7- Critérios de convergência

As simulações na busca por otimização do sistema precisam de um critério para poder interromper a procura por pontos ótimos. Estes critérios são conhecidos como critérios de convergência ou critérios de parada.

Um dos critérios de parada se baseia em um número máximo de iterações ou gerações, ou seja, caso a busca passe por um número determinado de gerações, a procura é interrompida e o melhor indivíduo é selecionado.

Outro critério leva em consideração a diferença entre a aptidão dos indivíduos selecionados a cada geração. Se ao passar por um número determinado de gerações a aptidão não for melhorada, pode-se dizer que houve uma convergência e o ponto ótimo não irá melhorar, podendo a procura ser interrompida.

Estes dois critérios são utilizados nas simulações deste trabalho.

2.2.8- Transformação do problema irrestrito em restrito

Na busca por pontos ótimos, além de minimizar ou maximizar uma determinada função, em alguns casos, a procura deve respeitar algumas restrições ou limitações. Assim, um problema de otimização pode ser descrito como o sistema apresentado a seguir:

Minimize $f(x)$

Suj. a:

$$g_i(x) \leq 0 \quad i = 1, l$$

$$g_i(x) = 0 \quad i = 1 + l, m$$

$$x_{jmin} \leq x_j \leq x_{jmax} \quad j = 1, k$$

Este problema pode ser transformado em uma função modificada h , que passará a ser a função objetivo a ser minimizada ou maximizada, conforme a Equação 2.13:

$$h(x, r, s) = f(x) + r \sum_{i=1}^l [g_i(x)]_+^2 + s \sum_{i=l+1}^m [g_i(x)]^2, \quad (2.13)$$

em que: r e s são parâmetros de penalidade; e $[]_+$ são restrições de desigualdade violadas.

Assim, a resolução desta função torna-se o objetivo do problema.

2.2.9- Função de mérito ou desempenho

A função de mérito ou desempenho define a aptidão de cada indivíduo da população, permitindo avalia-los e selecioná-los, conforme métodos descritos anteriormente, para novas gerações.

3- SISTEMA ASPERSOR DE POLÍMEROS

Os sistemas aspersores de polímero têm como objetivo reduzir as perdas dos materiais finos durante o transporte ferroviário. O sistema provê a proteção da superfície do minério dos vagões com uma cobertura feita por meio de uma mistura de água e polímero, que é uma substância aglomerante, evitando que partículas dos materiais sejam perdidas ao longo do trajeto. Desta forma, fica assegurado que além de evitar perdas, este sistema pode melhorar a qualidade de vida das populações localizadas às margens das linhas férreas por onde este material é transportado.

Atualmente, tramita no Congresso Nacional um projeto de lei [PL 2138/2007], que faz com que a aspersão em vagões ferroviários seja obrigatória e seja realizada no carregamento e a cada 150 km de percurso. Assim, fica evidenciada a importância do sistema em questão.

O sistema aspersor de polímeros da MRS Logística, localizado no pátio P2-14, em Barra Mansa, Rio de Janeiro, foi o sistema escolhido para o desenvolvimento do trabalho. O sistema aspersor de polímeros em vagões pode ser visto na Figura 3.1.



Figura 3.1: Sistema aspersor de polímeros em vagões do pátio P2-14.

O sistema em questão é um sistema totalmente automático. O processo do sistema aspersor de polímeros pode ser dividido em duas etapas. A primeira consiste na dosagem e preparação da solução que será aspergida sobre os carregamentos. Na segunda etapa a aspersão da solução já preparada é realizada. O sistema que viabiliza os objetivos considerados anteriormente é composto, basicamente, por tanques (de produtos, de mistura, de recuperação e de armazenamento de mistura) e por equipamentos para controlar a vazão e mistura destes produtos (válvulas, sensores, medidores de vazão, nível e pressão, dentre outros), além de quatro hastes que servirão para conduzir a solução até a superfície do material nos vagões. Um diagrama funcional do sistema descrito pode ser visto na Figura 3.2.

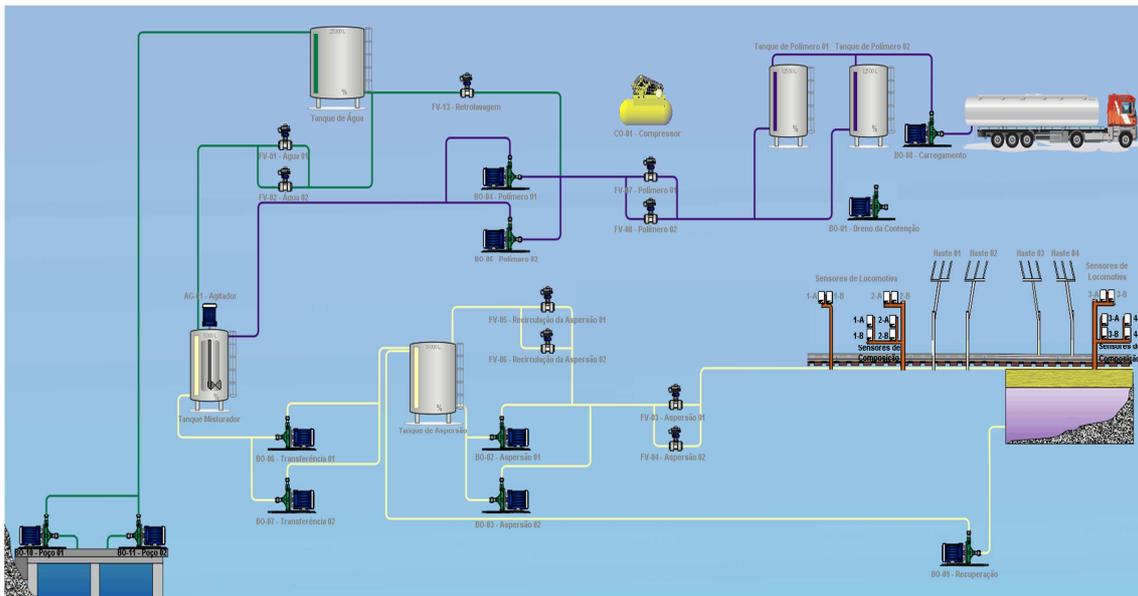


Figura 3.2: Diagrama funcional do sistema aspersor de polímeros em vagões.

Nas secções a seguir secções a seguir a metodologia para a modelagem do sistema aspersor é detalhada.

3.1- MODELAGEM DO SISTEMA

A modelagem do sistema aspersor tem como objetivo encontrar um sistema de equações que descreva o custo de operação da planta e as restrições para a operação. A

modelagem detalhada a seguir é uma mistura entre os modelos caixa branca e caixa preta, também conhecido na literatura como modelagem caixa cinza.

3.1.1- Função custo

O custo do sistema de aspersão pode ser pela equação 3.1:

$$\mathbf{Custo} = p_{ag} \times Q_{ag} + p_{pol} \times Q_{pol} + p_e \times e_m \times Q_{tot} + p_e \times P_a \times T_{asp}, \quad (3.1)$$

em que: p_{ag} é o valor da água utilizada (R\$/m³);

Q_{ag} é a quantidade de água utilizada na mistura para uma aspersão (m³);

p_{pol} é o valor do polímero utilizado (R\$/m³);

Q_{pol} é a quantidade de polímero utilizado na mistura para uma aspersão (m³);

p_e é o valor da energia elétrica consumida (R\$/kWh);

e_m é a energia necessária para produzir a mistura (kWh/m³);

Q_{tot} é a quantidade total de mistura preparada para a aspersão (m³);

P_a é a potência elétrica necessária para aspergir em uma composição (kW); e

T_{asp} é o tempo gasto na aspersão (h).

Considerando c a concentração de polímero na mistura, as quantidades de água e polímero são relacionadas à quantidade total de mistura de acordo com as equações 3.2 e 3.3:

$$Q_{ag} = (1 - c) \times Q_{tot}, \text{ e} \quad (3.2)$$

$$Q_{pol} = c \times Q_{tot}. \quad (3.3)$$

Os valores de energia elétrica e potência consumidos nos processos de mistura e aspersão podem ser representados pelas equações 3.4 e 3.5, respectivamente.

$$p_{em} = p_e \times e_m, \text{ e} \quad (3.4)$$

$$p_{asp} = p_e \times P_a. \quad (3.5)$$

em que: p_{em} representa o valor da energia elétrica consumida na mistura (R\$/m³); e

p_{asp} representa o valor da potência consumida na aspersão (R\$/h).

Da substituição das equações 3.2 a 3.5 na equação 3.1, tem-se que:

$$\mathbf{Custo} = p_{ag} \times (1 - c) \times Q_{tot} + p_{pol} \times (c) \times Q_{tot} + p_{em} \times Q_{tot} + p_{asp} \times T_{asp} \therefore$$

$$\mathbf{Custo} = [(1 - c) \times p_{ag} + c \times p_{pol} + p_{em}] \times Q_{tot} + p_{asp} \times T_{asp}. \quad (3.6)$$

Pode-se considerar a quantidade total de mistura aspergida, Q_{tot} , como descrito na equação 3.7:

$$Q_{tot} = Vaz \times T_{asp}. \quad (3.7)$$

em que: Vaz é a vazão na aspersão de mistura (m^3/h).

Finalmente, pode-se considerar o tempo de aspersão, como função da velocidade e comprimento do carregamento, como representado na equação 3.8:

$$T_{asp} = \frac{l}{v}. \quad (3.8)$$

em que: l é o comprimento da composição (km); e

v é a velocidade de deslocamento do carregamento (km/h).

Assim a função custo fica definida conforme descrito na equação 3.9:

$$Custo = [(1 - c) \times p_{ag} + c \times p_{pol} + p_{em}] \times Vaz \times \frac{l}{v} + p_{asp} \times \frac{l}{v}, \quad \text{ou}$$

$$Custo = \{[(1 - c) \times p_{ag} + c \times p_{pol} + p_{em}] \times Vaz + p_{asp}\} \times \frac{l}{v} \quad (3.9)$$

3.1.2- Restrições relacionadas à vazão da bomba de aspersão

O sistema aspersor possui algumas restrições quanto à operação e funcionamento relacionadas à vazão da bomba de aspersão. Elas são:

1. A vazão da bomba que realiza a aspersão tem um valor máximo.

$$Vaz \leq Vaz_{max}, \quad (3.10)$$

em que: Vaz_{max} é a vazão máxima da bomba de aspersão (m^3/h).

2. A vazão da bomba que realiza a aspersão tem um valor positivo.

$$Vaz > 0. \quad (3.11)$$

3. A quantidade total de mistura preparada para a aspersão não pode ultrapassar o volume do tanque de mistura.

$$Q_{tot} \leq V_{tot}, \quad (3.12)$$

em que: V_{tot} é o volume do tanque de armazenamento de mistura (m^3).

Da equação 3.7 pode-se reescrever a restrição como:

$$Q_{tot} \leq Vaz \times \frac{l}{v}. \quad (3.13)$$

3.1.3- Restrições relacionadas à velocidade da composição

O sistema aspersor possui algumas restrições quanto à operação e funcionamento relacionadas à velocidade da composição. Elas são:

4. A velocidade do trem deve ser sempre positiva.

$$v > 0. \quad (3.14)$$

5. A velocidade do trem deve ser restringida a no máximo 60 km/h.

$$v \leq 60. \quad (3.15)$$

3.1.4- Restrições relacionadas à concentração de polímero

O sistema aspersor possui algumas restrições quanto à operação e funcionamento relacionadas à concentração de polímero na mistura. Elas são:

6. A concentração na mistura deve ser maior que zero.

$$c > 0. \quad (3.16)$$

7. Devido às características físicas e químicas do polímero, a concentração na mistura deve ser no máximo igual a cinco por cento.

$$c \leq 5. \quad (3.17)$$

3.1.4- Restrições relacionadas à dispersão de partículas

A quantidade total aspergida deve ser suficiente para manter o nível de dispersão dentro dos limites aceitáveis. A dispersão é uma função correlacionada com a velocidade do trem, temperatura ambiente, umidade relativa do ar, quantidade de mistura aplicada na carga e concentração da mistura. A umidade relativa e a velocidade serão consideradas constantes até o fim do percurso.

$$\Delta M \leq f(v, T, u, Q_{tot}, c), \quad (3.18)$$

em que: ΔM é a dispersão da carga da composição ($\mu\text{g}/\text{m}^3$);

T é a temperatura ambiente ($^{\circ}\text{C}$);

u é a umidade relativa do ar (%); e

$f(v, T, u, Q_{tot}, c)$ é a função que representa a perda de carga ao longo do percurso. A obtenção desta função também é objetivo do trabalho. Serão

utilizadas técnicas de modelagem matemática para encontrar a função de acordo com as variáveis.

A função $f(v, T, u, Q_{tot}, c)$ pode ser estimada por meio da modelagem de sistemas utilizando os modelos NARMAX. Para isto, dados foram coletados levando em consideração os seguintes aspectos e procedimentos:

- Foram consideradas amostras apenas de composições com a mesma característica granulométrica, ou seja, os carregamentos analisados possuíam as faixas de tamanhos das partículas de minério semelhantes. Esta escolha dos carregamentos analisados buscou padronizar o tipo de carregamento a fim de facilitar a comparação dos resultados obtidos. As composições escolhidas foram as carregadas com PFF (Pellet Feed Fines), que é o minério cujas partículas possuem tamanho inferior a 0,15 mm de diâmetro. A escolha deste tipo de minério se deve ao fato de que nos carregamentos de PFF é nítida a dispersão de partículas no ar.
- Cada composição considerada possuía três locomotivas no início, e um total de 134 vagões. O sistema aspersor de polímeros possui um atraso no início da aspersão que pode chegar a até cinco vagões (quando a composição entra no sistema com velocidade máxima de 60 km/h). Desta forma, foram considerados três segmentos para a análise: o primeiro engloba os vagões de número 6 a 30; o segundo segmento engloba dos vagões de número 31 a 95; e o terceiro dos vagões de número 96 a 134. Em todos os carregamentos analisados a aspersão foi realizada apenas no segundo segmento. Tal procedimento permite uma melhor análise comparativa entre os vagões aspergidos e não aspergidos, bem como permite que os dados dos momentos em que não existe uma composição sejam retirados da modelagem.
- O ponto de medição foi estabelecido a 75 km do local de aplicação do produto e mantido o mesmo para todas as amostras coletadas. Foi utilizado um monitor de partículas dispersas para a coleta da quantidade de partículas suspensas no ar (em $\mu\text{g}/\text{m}^3$) durante a passagem da composição em análise. O período de amostragem também foi considerado o mesmo (0,5 s) para todas as coletas.
- Procurou-se variar ao máximo as variáveis do processo, como concentração de produto na solução e quantidade de solução aplicada. Os testes

também foram realizados em diferentes dias para que as condições ambientais pudessem entrar como variáveis do sistema. Porém não foi possível controlar a velocidade das composições, pois os testes foram realizados em um longo percurso e a diminuição da velocidade ocasionaria congestionamento no fluxo de composições.

- A temperatura e umidade relativa do ar foram consideradas constantes durante todo o percurso da composição. O valor utilizado na modelagem matemática é uma média entre os valores medidos no local da aspersão, em Barra Mansa, e no local da medição, em um trecho próximo a Barra do Pirai.
- A velocidade durante o percurso também foi considerada constante. O valor utilizado na modelagem foi obtido a partir do tempo do percurso de 75 km, descontado o tempo de eventuais paradas.
- O sistema de aspersão pode trabalhar com diferentes tipos de polímero. Para os testes foi utilizado polímero pertencente ao mesmo lote.
- O total de solução aspergida é o volume total considerando como se toda a composição fosse aspergida. Tal valor é obtido por meio da quantidade média aspergida por vagão (nos segmentos aspergidos) multiplicada pelo número total de vagões da composição.

Após a aplicação do produto e medição os resultados obtidos para cada composição puderam ser visualizados da conforme exemplo da Figura 3.3.

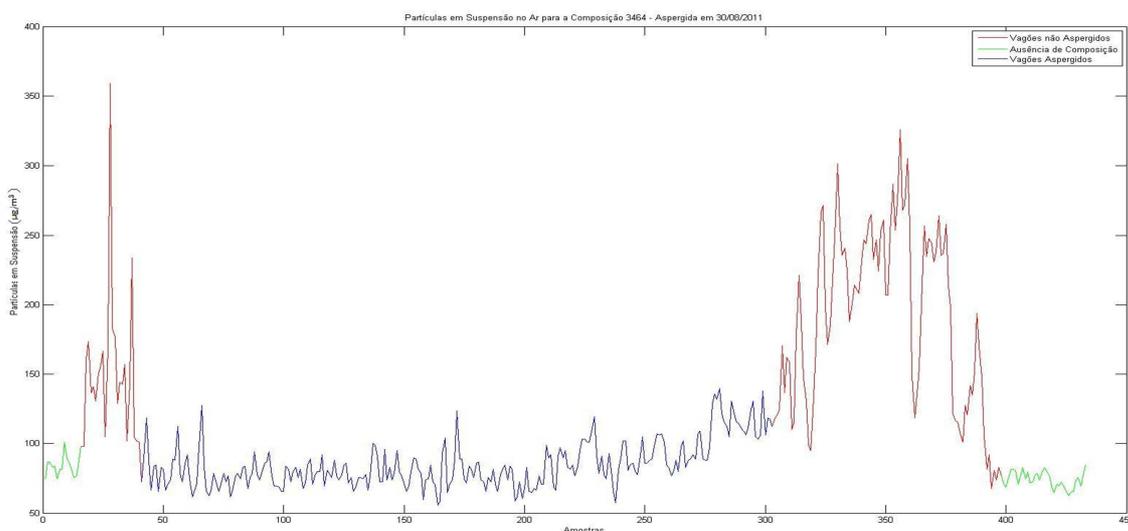


Figura 3.3: Amostragem de partículas suspensas no ar para carregamento do dia 30/08/2011.

Observando a Figura 3.3, pode-se perceber um aumento significativo na concentração de partículas dispersas no ar quando a composição com os vagões não aspergidos passa pelo ponto de medição. Após a passagem do primeiro segmento não aspergido é possível perceber a diminuição da concentração de partículas em suspensão, tal fato deve-se à aspersão realizada no segundo segmento da composição. No terceiro segmento percebe-se novamente o aumento da concentração de partículas dispersas no ar, e finalmente, uma diminuição da concentração devido ao final da composição.

Com o auxílio da análise gráfica, pode-se então encontrar valores médios para os segmentos não aspergidos (segmentos 1 e 3) e aspergido (segmento 2).

Para o estudo, foi possível a coleta de apenas 26 carregamentos. A coleta dos dados foi realizada nos dias 30 e 31 de agosto e 01 de setembro. Os dados obtidos podem ser vistos na Tabela 3.1:

Tabela 3.1: Dados coletados entre os dias 30 de agosto a 01 de setembro de 2011.

	Partículas Dispersas na Carga Aspergida ($\mu\text{g}/\text{m}^3$)	Partículas Dispersas na Carga não Aspergida ($\mu\text{g}/\text{m}^3$)	Velocidade (km/h)	Temperatura ($^{\circ}\text{C}$)	Umidade Relativa do Ar (%)	Solução Aspergida (m^3)	Concentração (%)
1	85,20	183,44	32	20,2	62,1	5092	2,0
2	102,67	178,96	37	25,0	59,5	4711	1,8
3	111,32	190,44	24	28,8	58,3	5998	1,5
4	114,54	193,33	26	30,2	57,8	5913	1,5
5	99,65	187,33	27	31,4	58,9	5812	1,7
6	104,47	189,37	37	30,7	58,3	4437	1,8
7	101,41	187,58	36	29,1	58,3	4503	1,9
8	80,98	182,47	33	21,5	60,6	5201	2,0
9	76,45	198,43	38	22,1	65,5	5003	2,5
10	97,64	200,35	41	23,9	65,7	4021	2,0
11	75,87	179,54	37	26,8	60,8	4876	2,2
12	79,45	182,35	38	26,6	62,4	4972	2,1
13	72,35	195,84	37	26,4	60,7	4823	2,5
14	70,56	196,99	32	27,2	57,2	5055	3,0
15	122,06	192,67	28	27,0	56,4	5599	0,9
16	141,35	193,85	29	25,6	53,9	5849	0,7
17	152,82	187,89	34	23,8	54,0	5167	0,5
18	102,5	179,53	29	22,4	54,6	5643	1,0
19	96,43	182,09	27	28,9	59,3	5852	1,7
20	76,53	190,32	38	23,2	53,8	4879	2,7
21	93,54	193,60	25	27,8	57,9	6012	2,4
22	101,58	204,76	29	28,2	58,4	5341	2,2
23	123,5	173,97	34	22,5	54,9	5222	0,8
24	93,99	179,01	26	30,3	60,8	5956	1,3
25	92,61	175,36	24	31,4	58,1	6101	1,1
26	107,9	189,90	26	30,6	55,3	5870	0,9

Considerando as observações do sistema, pode-se estimar um modelo matemático que represente o sistema aspersor conforme a equação 3.18. A determinação do modelo envolve a escolha do modelo utilizado, a determinação das variáveis e a estimação dos parâmetros do modelo.

Buscando encontrar uma estrutura que represente bem o sistema, foi proposto um modelo de segunda ordem dependente das seguintes combinações das variáveis:

$$v, T, u, Q_{tot}, c, v^2, vT, vu, vQ_{tot}, vc, T^2, Tu, TQ_{tot}, Tc, u^2, uQ_{tot}, uc, Q_{tot}^2, Q_{tot}c, \text{ e } c^2.$$

Porém a grande quantidade de variáveis, além de tornar o cálculo mais trabalhoso, também pode gerar mau condicionamento numérico. É importante então selecionar os fatores mais relevantes no modelo. Desta forma a taxa de redução de erro devido à inclusão de cada variável foi avaliada e as combinações mais significativas foram selecionadas. As combinações de variáveis com a ERR correspondentes podem ser vistas na Tabela 3.2.

Tabela 3.2: Termos selecionados de acordo com ERR.

Termo	ERR x 100 (%)
v	68,57
T	9,55
u	6,58
c	3,16
vc	1,79
Tc	0,89

Assim, a equação que descreve o sistema pode ser representada pela equação 3.19:

$$\Delta M = \alpha_1 v + \alpha_2 T + \alpha_3 u + \alpha_4 c + \alpha_5 vc + \alpha_6 Tc \quad (3.19)$$

Determinadas as variáveis que entrarão no modelo, pode-se aplicar o método de mínimos quadrados para a determinação dos parâmetros da equação 3.19. Para a estimação dos parâmetros, foram utilizadas as 16 primeiras amostras de aspersão (Tabela 3.1), gerando o seguinte sistema representado em 3.20 e 3.21.

$$\begin{bmatrix} M(1)_n - M(1)_a \\ M(2)_n - M(2)_a \\ \vdots \\ M(16)_n - M(16)_a \end{bmatrix} = \begin{bmatrix} v(1) & T(1) & u(1) & c(1) & v(1)c(1) & T(1)c(1) \\ v(2) & T(2) & u(2) & c(2) & v(2)c(2) & T(2)c(2) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ v(16) & T(16) & u(16) & c(16) & v(16)c(16) & T(16)c(16) \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_6 \end{bmatrix}, \quad (3.20)$$

em que: $M(i)_n$ é a quantidade de partículas dispersas sem a aspersão ter sido realizada para a *iésima* amostra (em $\mu\text{g}/\text{m}^3$); e
 $M(i)_a$ é a quantidade de partículas dispersas após aspersão para a *iésima* amostra (em $\mu\text{g}/\text{m}^3$).

Substituindo pelos valores obtidos nos testes:

$$\begin{bmatrix} 183,44 - 85,20 \\ 178,96 - 102,67 \\ \vdots \\ 193,85 - 141,35 \end{bmatrix} = \begin{bmatrix} 32 & 20,2 & 62,1 & 2,0 & 32 \times 2,0 & 20,2 \times 2,0 \\ 37 & 25,0 & 59,5 & 1,8 & 37 \times 1,8 & 25,0 \times 1,8 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 29 & 25,6 & 53,9 & 0,7 & 29 \times 0,7 & 25,6 \times 0,7 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_6 \end{bmatrix} \quad (3.21)$$

Aplicando-se o estimador de mínimos quadrados, obtém-se:

$$\begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \\ \alpha_6 \end{bmatrix} = \begin{bmatrix} -3,4535 \\ 3,8737 \\ 0,5802 \\ 33,0526 \\ 1,8209 \\ -2,1793 \end{bmatrix}. \quad (3.22)$$

Substituindo os parâmetros encontrados na equação 3.19, pode-se representar o sistema aspersor pela seguinte equação:

$$\Delta M = -3,4535v + 3,8737T + 0,5802u + 33,0526c + 1,8209vc - 2,1793Tc. \quad (3.23)$$

Assim, valores de partículas dispersas após a aspersão podem ser estimados a partir da equação 3.24:

$$M_a = M_n + 3,4535v - 3,8737T - 0,5802u - 33,0526c - 1,8209vc + 2,11793Tc, \quad (3.24)$$

em que M_a é a dispersão de partículas onde houve a aspersão e M_n é a dispersão de partículas onde não houve a aspersão de polímero.

As amostras de número 16 a 26 foram utilizadas para a validação do modelo. A Figura 3.4 mostra os valores obtidos a partir do modelo utilizando a equação 3.24. Ainda na Figura 3.4 é possível comparar os valores obtidos com o modelo, com os valores reais medidos durante o teste.

A análise do índice RMSE, índice que mede a variação dos resultados simulados para os reais de acordo com a equação 3.25, indica que o modelo apresentou bons resultados em sua simulação. O índice RMSE calculado para os resultados obtidos é de

0,154 e a maioria dos autores considera que valores inferiores a uma unidade são satisfatórios [NEP04].

$$RMSE = \frac{\sqrt{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}}{\sqrt{[\hat{y}(k) - \bar{y}]^2}} \quad (3.25)$$

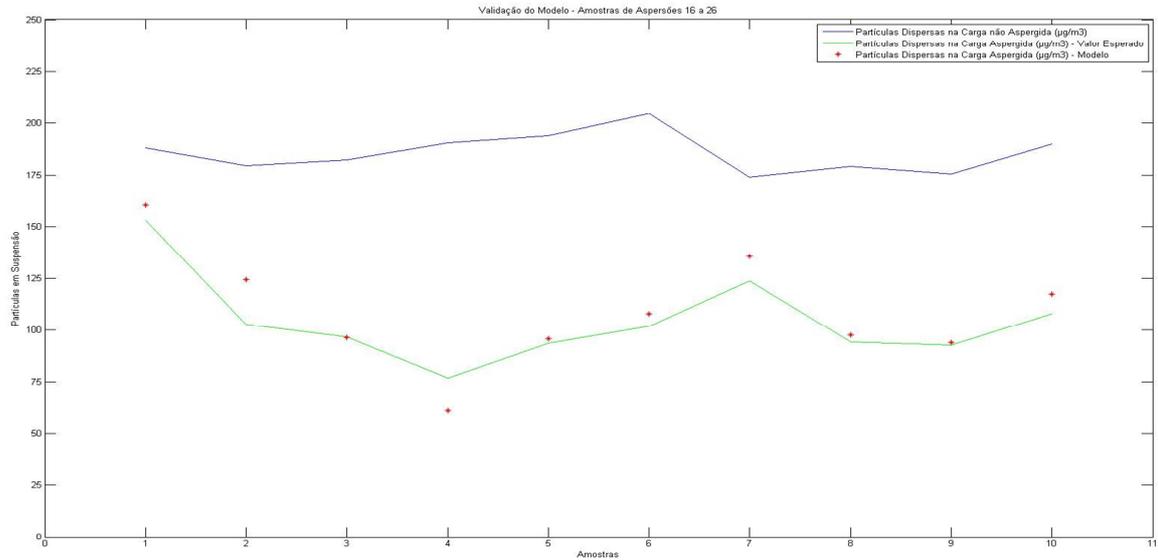


Figura 3.4: Comparação dos resultados obtidos - modelo proposto x medições realizadas.

Os valores obtidos na simulação podem ser mais bem observados na Tabela 3.3.

Tabela 3.3: Número de partículas dispersas na carga aspergida ($\mu\text{g}/\text{m}^3$)

Valores Reais	Valores Obtidos com o Modelo Proposto	Erro	Erro Percentual
152,82	160,23	7,41	4,85
102,50	124,18	21,69	21,16
96,43	96,27	0,15	0,16
76,53	60,91	15,61	20,41
93,54	95,47	1,93	2,07
101,58	107,84	6,26	6,17
123,50	135,63	12,13	9,83
93,99	97,48	3,49	3,71
92,61	93,74	1,13	1,22
107,90	117,30	9,46	8,72

Desta forma a restrição relacionada à dispersão de partículas pode ser escrita como:

$$\Delta M \leq -3,4535v + 3,8737T + 0,5802u + 33,0526c + 1,8209vc - 2,1793Tc. \quad (3.26)$$

3.2- PROBLEMA PROPOSTO

Após a modelagem o objetivo do trabalho pode ser descrito como a resolução do seguinte problema:

Minimize Custo,

$$\text{Custo} = \{[(1 - c) \times p_{ag} + c \times p_{pol} + p_{em}] \times Vaz + p_{asp}\} \times \frac{l}{v}$$

Restrições:

$$Vaz \leq Vaz_{max};$$

$$Vaz \geq 0;$$

$$Q_{tot} \leq V_{tot};$$

$$v \geq 0;$$

$$v \leq 60;$$

$$c \geq 0;$$

$$c \leq 5; e$$

$$3,4535v - 3,8737T - 0,5802u - 33,0526c - 1,8209vc + 2,1793Tc \leq -\Delta M$$

As seguintes constantes podem ser vistas no problema:

p_{ag} : valor da água. De acordo com o Instituto Nacional de Exploração de Águas (INEA) o valor cobrado para a água consumida é de R\$ 0,84/m³;

p_{pol} : valor do polímero utilizado. O valor médio do litro do polímero utilizado no processo é de R\$ 7,10, ou R\$ 7100,00/m³;

p_{em} : valor da energia elétrica consumida na mistura. No processo de mistura, os equipamentos envolvidos como moto-bombas, válvulas e agitadores possuem potência total de aproximadamente 10,65 kW e funcionam por aproximadamente 9 minutos para produzir 5 m³ de solução. Com um valor de energia de R\$0,32/kWh, obtém-se um custo de R\$ 0,10/m³;

p_{asp} : valor da potência consumida na aspersão. No processo de aspersão, os motores e válvulas responsáveis pela transmissão do produto até as hastes possui potência total de 18,50 kW. Com o valor de energia de R\$0,32/kWh, pode-se afirmar que o valor da potência consumida na aspersão é de R\$ 5,92/h;

l : comprimento da composição. Cada composição tem 1,475 km;

Vaz_{max} : vazão máxima da bomba de aspersão, que é de 150 m³/h;

V_{tot} : volume do tanque de armazenamento de mistura, que é de 15 m³; e

ΔM : dispersão da carga da composição. Segundo a resolução nº 3 da CONAMA, de 28/06/1990, um estado normal permite até 250 µg/m³ de partículas inaláveis suspensas no ar, a partir deste limite, já se pode considerar estado de atenção. Para o estudo, considerar-se-á uma diferença nos valores de dispersão antes e depois da aspersão de pelo menos 70 µg/m³.

Assim, reescrevendo a função custo e as restrições substituindo os valores das constantes, o problema pode ser escrito como segue:

$$Min\ Costo = \{[(1 - c) \times 0,84 + 7100 \times c + 0,10] \times Vaz + 5,92\} \times \frac{1,475}{v},$$

Suj. a:

$$Vaz - 150 \leq 0;$$

$$-Vaz \leq 0;$$

$$Vaz - 10,17v \leq 0;$$

$$-v \leq 0;$$

$$v - 60 \leq 0; e$$

$$-c \leq 0;$$

$$c - 5 \leq 0; e$$

$$3,4535v - 3,8737T - 0,5802u - 33,0526c - 1,8209vc + 2,1793Tc + 70 \leq 0.$$

Desta forma fica evidente que o sistema possui as seguintes variáveis de otimização:

c : concentração de polímero na mistura (%);

v : velocidade de deslocamento do carregamento (km/h); e

Vaz: vazão na aspersão (m^3/h).

E as seguintes variáveis não controladas:

T : temperatura ambiente ($^{\circ}\text{C}$); e

u : umidade relativa do ar (%).

3.3- CONCLUSÕES

O objetivo desta secção foi cumprido e foi obtido um sistema de equações que descreve o custo de operação da planta, bem como as restrições para a operação.

Utilizando conhecimentos de modelagem caixa cinza, obteve-se uma função custo que está relacionada com as características de operação (variáveis controladas), como concentração de polímero na mistura, velocidade de deslocamento do carregamento e vazão da aspersão e com fatores exógenos (variáveis não controladas), como a temperatura e umidade relativa do ar. As restrições do modelo, também relacionadas com as características de operação e com os fatores exógenos, exprimem as boas condições de operação para o sistema aspersor.

O modelo obtido será utilizado no problema de otimização que visa minimizar o custo na operação do aspersor de polímeros. A otimização será detalhada nas próximas secções.

4- OTIMIZAÇÃO UTILIZANDO ALGORITMOS GENÉTICOS

Para a solução do problema de otimização, o problema restrito foi transformado em um problema irrestrito. A modificação foi realizada conforme equação 2.13, e considerando valores de r e s iguais a 10^4 . A função objetivo resultante é mostrada na equação 4.1:

$$\begin{aligned} \text{Custo} = \{ & [(1 - c) \times 0,84 + 7100 \times c + 0,10] \times Vaz + 5,92\} \times \frac{1,475}{v} + 10^4 \times \\ & [Vaz - 150]^2 + 10^4 \times [Vaz]^2 + 10^4 \times [Vaz - 10,17v]^2 + 10^4 \times [-v]^2 + 10^4 \times \\ & [v - 60]^2 + 10^4 \times [-c]^2 + 10^4 \times [c - 5]^2 + 10^4 \times [3,4535v - 3,8737T - \\ & 0,5802u - 33,0526c - 1,8209vc + 2,1793Tc + 70]^2 \end{aligned} \quad (4.1)$$

A faixa de procura foi determinada por meio da faixa de amostragem para cada variável de controle. No caso da concentração, foi considerada $c = [0:0,1:5]$, para a vazão, $Vaz = [0:5:150]$ e finalmente a velocidade variou de $v = [0:3:60]$. Os valores considerados para a temperatura, T , e umidade relativa do ar, u , foram considerados 30°C e 67% nas simulações.

O comprimento do genótipo, ou seja o número de indivíduos selecionados para formação da geração futura, variou entre 10 e 30 indivíduos. E os critérios de seleção utilizados foram variados entre roleta e torneio. Em uma mesma simulação, conforme mostrado na Figura 2.2, foi utilizado o mesmo critério de seleção na população inicial e nas populações geradas a cada iteração.

Os operadores genéticos utilizados no trabalho foram sempre cruzamento, mutação e elitismo. A probabilidade de mutação e cruzamento variou dinamicamente, de forma a manter a diversidade no passar das gerações, ou seja, com o passar das iterações, um número maior de mutações ocorre para incluir nas amostras novos valores, evitando assim convergência prematura. A porcentagem de mutações, P_{mut} , e de cruzamento, P_{cruz} , podem ser descritas pelas equações 4.2 e 4.3:

$$P_{mut} = \left[0,9 \times \frac{n_{ger-1}}{Max_{ger-1}} + 0,1 \right] \times 100, \quad (4.2)$$

$$P_{cruz} = 100 - P_{mut}, \quad (4.3)$$

em que n_{ger} e Max_{ger} representam o número da geração atual e o número máximo de gerações. Nas simulações o número máximo de gerações variou de 100 a 1000 gerações. Max_{ger} também é utilizado como um dos critérios de convergência.

Os coeficientes de multiplicação para cruzamento α e α_{pol} , bem como o coeficiente β para a mutação, foram considerados números aleatórios a cada geração.

Definidas todas as variáveis e características do algoritmo genético, foram realizadas simulações com o auxílio do Matlab (software de simulação matemática) e os resultados são mostrados na próxima secção.

5- RESULTADOS E ANÁLISES

Os resultados obtidos a partir das variáveis e características do algoritmo genético definidas anteriormente são apresentados a seguir:

Tabela 5.1: Amostragem de 10 indivíduos, método roleta e 100 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
10	100	Roleta
Resultados Obtidos		
Velocidade	12,49 km/h	
Vazão	92,52 m ³ /h	
Concentração	2,13 %	
Custo	R\$ 1663,20	
Tempo de Processamento	7,17 s	

Tabela 5.2: Amostragem de 20 indivíduos, método roleta e 100 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
20	100	Roleta
Resultados Obtidos		
Velocidade	19,62 km/h	
Vazão	130 m ³ /h	
Concentração	1,98 %	
Custo	R\$ 1385,50	
Tempo de Processamento	14,46 s	

Tabela 5.3: Amostragem de 30 indivíduos, método roleta e 100 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
30	100	Roleta
Resultados Obtidos		
Velocidade	12 km/h	
Vazão	28,06 m ³ /h	
Concentração	4,10 %	
Custo	R\$ 1008,10	
Tempo de Processamento	123,69 s	

Tabela 5.4: Amostragem de 10 indivíduos, método roleta e 1000 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
10	1000	Roleta
Resultados Obtidos		
Velocidade	10,92 km/h	
Vazão	80,85 m ³ /h	
Concentração	0,80 %	
Custo	R\$ 631,07	
Tempo de Processamento	9,33 s	

Tabela 5.5: Amostragem de 20 indivíduos, método roleta e 1000 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
20	1000	Roleta
Resultados Obtidos		
Velocidade	30 km/h	
Vazão	88,48 m ³ /h	
Concentração	1,70 %	
Custo	R\$ 529,42	
Tempo de Processamento	85,23 s	

Tabela 5.6: Amostragem de 30 indivíduos, método roleta e 1000 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
30	1000	Roleta
Resultados Obtidos		
Velocidade	24,45 km/h	
Vazão	65,36 m ³ /h	
Concentração	1,72 %	
Custo	R\$ 485,66	
Tempo de Processamento	1207.97 s	

Tabela 5.7: Amostragem de 10 indivíduos, método torneio e 100 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
10	100	Torneio
Resultados Obtidos		
Velocidade	12 km/h	
Vazão	71,99 m ³ /h	
Concentração	4,34 %	
Custo	R\$ 2735,56	
Tempo de Processamento	9,87 s	

Tabela 5.8: Amostragem de 20 indivíduos, método torneio e 100 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
20	100	Torneio
Resultados Obtidos		
Velocidade	8,72 km/h	
Vazão	35 m ³ /h	
Concentração	2,4 %	
Custo	R\$ 1014,80	
Tempo de Processamento	18,33 s	

Tabela 5.9: Amostragem de 30 indivíduos, método torneio e 100 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
30	100	Torneio
Resultados Obtidos		
Velocidade	19,47 km/h	
Vazão	120,35 m ³ /h	
Concentração	1,50 %	
Custo	R\$ 979,74	
Tempo de Processamento	127,84 s	

Tabela 5.10: Amostragem de 10 indivíduos, método torneio e 1000 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
10	1000	Torneio
Resultados Obtidos		
Velocidade	9 km/h	
Vazão	46,37 m ³ /h	
Concentração	1,60 %	
Custo	R\$ 871,49	
Tempo de Processamento	12,90 s	

Tabela 5.11: Amostragem de 20 indivíduos, método torneio e 1000 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
20	1000	Torneio
Resultados Obtidos		
Velocidade	42 km/h	
Vazão	120 m ³ /h	
Concentração	2,20 %	
Custo	R\$ 662,36	
Tempo de Processamento	89,22 s	

Tabela 5.12: Amostragem de 30 indivíduos, método torneio e 1000 gerações

Características do Algoritmo		
Número de Indivíduos Selecionados	Número Máximo de Gerações	Método de Seleção Utilizado
30	1000	Torneio
Resultados Obtidos		
Velocidade	33 km/h	
Vazão	98,45 m ³ /h	
Concentração	1,17 %	
Custo	R\$ 371,93	
Tempo de Processamento	1156.66 s	

Observando-se os resultados pode-se afirmar que todos eles encontraram condições de operação da planta respeitando a todas as restrições impostas na

modelagem do sistema. Pode-se observar também que foram apresentados resultados em diversas faixas das variáveis consideradas (velocidade, vazão e concentração), evidenciando a estocasticidade do modelo.

O aumento no número de indivíduos selecionados a cada geração mostrou que a diversidade de características trazidas a partir de um maior número de elementos faz com que os resultados melhorem. Outro fator que contribui para encontrar melhores pontos de operação é o aumento no número máximo de gerações do modelo. Tal fator faz com que a busca seja prolongada, com um maior número de iterações, e a probabilidade de operações genéticas bem sucedidas aumenta.

Com relação aos métodos de seleção pouco pode-se observar, já que não foram notadas diferenças relevantes nos pontos de operação encontrados. O único fator que diferencia os métodos é que as simulações com o método torneio sempre tiveram um tempo de processamento menor, indicando maior facilidade de convergência.

Observando os resultados ainda pode-se concluir que as operações genéticas foram bem sucedidas. Pode-se confirmar esta afirmação pelo fato de que os valores que não faziam parte da população inicial apareceram como soluções para o problema.

Apesar de os resultados respeitarem todas as condições de operação da planta, existe uma grande variedade de resultados para condições iniciais similares, essa falta de robustez, não é o ideal para o sistema aspersor. O que se espera do algoritmo é que, dadas as condições ambientais, ele apresente a melhor resposta. O tempo de simulação, também é um fator complicador para o modelo. Uma solução viável a estes problemas seria pré-determinar a velocidade de tráfego do trem. Desta forma a complexidade do sistema é diminuída e conseqüentemente as possibilidades de combinação das variáveis de controle que restam (vazão e concentração) se tornam mais restritas e o tempo de simulação mais rápido.

Com esta solução, pode-se ainda usar os cálculos para várias composições, já que a variação das condições climáticas (temperatura e umidade) não acontece de forma dinâmica. Desta forma, pode-se, por exemplo, realizar simulações periódicas para determinar os valores de concentração e vazão do sistema aspersor.

O resultado da última simulação pode ser utilizado como exemplo. Se a velocidade for definida como sendo 33 Km/h, a uma vazão de 98,45 m³/h com uma mistura com 1,17% de concentração, a aspersão geraria um custo de R\$ 371,93 por aplicação. Esta configuração de aplicação, que foi a melhor encontrada, pode ser utilizada enquanto as condições ambientais se mantiverem ($T = 30^{\circ}\text{C}$, e $u = 67\%$). A título de comparação, o sistema atualmente opera com vazão máxima, 150 m³/h, e concentração de 1,5% para todas as composições. Considerando as mesmas condições ambientais que a simulação, o custo da aspersão seria de R\$ 717,31. Ou seja, o modelo proposto apresentou uma economia de 48,14%.

6- CONCLUSÕES

A modelagem matemática mostrou-se como uma poderosa ferramenta no estudo de sistemas complexos de engenharia. Com a utilização dos modelos NARMAX, que apresentaram grande robustez na modelagem caixa preta, pôde-se encontrar um modelo matemático que representa bem a dispersão de partículas de poeira no ar durante o deslocamento dos trens. A utilização deste modelo, junto a outras características e restrições do sistema aspersor permitiu a construção de um problema de otimização que visa minimizar o custo na operação de aspersão.

A utilização de algoritmos genéticos como ferramenta de otimização trouxe diversas combinações de resultados na busca pela solução do problema. Os resultados apresentados pelo algoritmo construído respeitam as restrições do sistema, porém, por se tratar de um método estocástico, e pelo fato de o problema de otimização permitir que um mesmo cenário apresente mais de uma solução viável, os resultados encontrados devem passar por uma análise antes de sua aplicação. Além desta necessidade de interpretação pelo operador, o tempo de processamento do algoritmo inviabiliza sua utilização em tempo real, o que dificulta sua aplicação por meio de um sistema de automação.

Foram simulados diversos cenários para comprovar a eficiência na solução do problema de otimização. Pode-se concluir que o objetivo do trabalho foi alcançado. Apesar de não apresentar a autonomia desejada, o estudo forneceu soluções viáveis e que respeitam as condições de operação do sistema aspersor de polímeros. Tal afirmação é comprovada pelo fato de que os resultados apresentados neste trabalho permitirão uma economia anual de aproximadamente R\$ 3.800.000,00 (aproximadamente 48% do custo operacional), considerando as expectativas de que sejam feitas 12.000 aspersões por ano.

Além de significativa economia, o trabalho proporcionou um maior conhecimento do sistema de aspersão de polímeros por meio da obtenção de um modelo matemático que o descreva, contribuindo ainda no processo de tomada de decisões e em outros possíveis estudos.

Trabalhos futuros visam a aplicação da metodologia apresentada para obtenção de modelos que representem o transporte de minérios com diferentes granulometrias e de outros materiais como calcário e cimento.

REFERÊNCIAS BIBLIOGRÁFICAS

[AGU04] AGUIRRE, Luiz A. Introdução à Identificação de Sistemas. 2ª ed., Editora UFMG, 2004. 659p.

[BIL82] BILLINGS, S. A. and LEONTARITIS, I. J. Parameter estimation techniques for nonlinear systems. Symposium on Identification and Systems Parameter Estimation, pp. 427-432, 1982.

[BIL88] BILLINGS, S. A., KORENBERG, M. and CHEN, S. Identification of nonlinear output-affine systems using an orthogonal least-squares algorithm. International Journal of Systems Science, Vol. 19, No. 8, pp. 1559-1568, 1988.

[GAR05] GARCIA, Cláudio. Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos. 2ª ed., EDUSP, 2005. 678p.

[GOL89] GOLDBERG, David E. Genetic Algorithms in Search, Optimization and Machine Learning. 1ª ed., Pearson Education do Brasil, 1989. 432p.

[HAK74] H. Akaike, "A new look at the statistical model identification," IEEE Trans. Automatic Control, Vol. 19, No. 6, pp. 716-723, 1974.

[HOL92] HOLLAND, John H. Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence. 5ª ed., MIT Press, 1998. 288p.

[LEO85] LEONTARITIS I. J. and BILLINGS, S. A. Input-output parametric models for non-linear systems, (part I: deterministic non-linear systems; part II: stochastic non-linear systems). Int. Journal of Control, Vol. 41, No. 2, pp. 303-344, 1985.

[LJU99] LJUNG, Lennart. System Identification: Theory for the User. 2ª ed., Prentice Hall, 1999, 611p.

[NEP02] NEPOMUCENO, Erivelton Geraldo. Identificação Multiobjetivo de Sistemas Não-Lineares. Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal de Minas Gerais, UFMG, Brasil, 2002.

[NEV07] NEVES, Lucas Dal-Rios, AGOSTINHO, Nivaldo Ulisses, NEPOMUCENO, Erivelton Geraldo, CAETANO, Sidney Martins. Forecasts of Inflation and NARMAX models. VII Encontro Brasileiro de Finanças, São Paulo, 2007.

[PL 2138/2007] Projeto de Lei 2138/2007 em tramite na Câmara dos deputados. Disponível no site da Câmara dos Deputados por WWW em <http://www.camara.gov.br/proposicoesWeb/fichadetramitacao?idProposicao=369552>

[QIN01] QING, Anyong, LEE, Ching Kwang, JEN, Lang. Eletromagnetic Inverse Scattering of Two-Dimensional Perfectly Conducting Objects by Real-Coded Genetic Algorithm. IEEE Transactions on Geoscience and Remote Sensing. Volume 39, Issue 3, pp. 665-676, 2001.

[SOA97] SOARES, Gustavo Luís. Algoritmos Genéticos: Estudo, Novas Técnicas e Aplicações. Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal de Minas Gerais, UFMG, Brasil, 1997.