



**UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE
COMUNICAÇÃO E AUTOMAÇÃO**

CLAYTON ANTONIO DE MIRANDA OLIVEIRA

**PROJETO DE OBSERVADORES DE ESTADO
UTILIZANDO ALGORITMOS GENÉTICOS**

MOSSORÓ – RN

2014

CLAYTON ANTONIO DE MIRANDA OLIVEIRA

**PROJETO DE OBSERVADORES DE ESTADO
UTILIZANDO ALGORITMO GENÉTICO**

Dissertação de mestrado acadêmico apresentada ao Programa de Pós-Graduação em Sistemas de Comunicação e Automação, como requisito para a obtenção do título de Mestre em Sistemas de Comunicação e Automação.

Orientador: Prof. Dr. Elmer Rolando Llanos
Villarreal – UFERSA

MOSSORÓ – RN

2014

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Central Orlando Teixeira (BCOT)
Setor de Informação e Referência (SIR)

O482p	Oliveira, Clayton Antônio de Miranda. Projeto de observadores de estado utilizando algoritmo genético / Clayton Antônio de Miranda Oliveira. -- Mossoró, 2014. 92 f. : il. Dissertação (Mestrado em Sistemas de Comunicação e Automação) – Universidade Federal Rural do Semi-Árido. Pró-Reitoria de Pesquisa e Pós-Graduação. Orientador: Prof.º Dr. Elmer Rolando Llanos Villarreal. 1. Sistemas de controle multivariáveis. 2. Observadores de estado. 3. Algoritmos genéticos. 4. Resposta transitória. I. Villarreal, Elmer Rolando Llanos. II. Título.
RN/UFERSA/BCOT	CDD: 629.8

Bibliotecário-Documentalista
Sale Mário Gaudêncio, Me. (CRB-15/476)

CLAYTON ANTONIO DE MIRANDA OLIVEIRA

**PROJETO DE OBSERVADORES DE ESTADO
UTILIZANDO ALGORITMOS GENÉTICOS**

Dissertação de mestrado acadêmico
apresentada ao Programa de Pós-Graduação em
Sistemas de Comunicação e Automação, como
requisito para a obtenção do título de Mestre em
Sistemas de Comunicação e Automação.

APROVADA EM: ____ / ____ / ____.

BANCA EXAMINADORA



Prof. Dr. Elmer Rolando Llanos Villarreal – UFERSA
Presidente



Prof. Dr. Samaherni Moraes Dias – UFRN
Primeiro Membro



Prof. Dr. Jose Patrocínio da Silva – UFRN
Segundo Membro

Prof. Dr. Alex Sandro de Araújo Silva – UFERSA
Terceiro Membro

Dedicatória:

*Dedico esta dissertação à minha mãe **Elizabete Batista** pelo exemplo de vida, pela dedicação materna que tem comigo e com meus irmãos, e que mesmo diante das dificuldades e dos obstáculos que a vida apresenta, não esquece a ternura, não perde o bom humor e a vontade de viver.*

*Dedico este trabalho ao meu pai **José Maria (in memorian)**, por tudo que me ensinou a ser, pelo caráter que tinha, pelo amor e carinho que tanto dedicou a mim, meus irmãos e minha mãe. Pelo exemplo de profissional de educação que sempre me inspirava e continua inspirando.*

Agradecimentos

A Deus, por ser sempre meu alicerce, minha base maior, que me ajuda ser firme e forte na fé, a manter-me fiel, a ter discernimento no dia-a-dia e a nunca me fazer desesperar diante dos problemas;

A Cristina, por está sempre ao meu lado, por ser minha companheira em tudo, pela paciência e compreensão em todos os momentos;

Aos meus irmãos e minhas primas, com quem sempre posso contar, e que sempre contribuíram comigo quando os problemas surgiram, e que sempre compartilharam comigo as dificuldades e as alegrias do dia-a-dia;

Ao Professor Elmer, pela paciência, pela dedicação e pela confiança no meu trabalho e na minha capacidade em concluí-lo. E por sempre me motivar e me ajudar a terminar este trabalho;

Aos Professores Patrocínio, Ronaldo e Fabiana, por todas as aulas ministradas, pelas conversas nos corredores ou em sala de aula, por sempre motivarem os mestrandos e por contribuírem bastante para este trabalho;

Ao professor e amigo Samaherni, por ser sempre alguém com quem posso contar e confiar;

Aos amigos do mestrado do PPSCA e todos os amigos que sempre me incentivaram e contribuíram, seja de forma direta ou indireta, para a conclusão deste trabalho.

“Existem muitas hipóteses em ciência que estão erradas. Isso é perfeitamente aceitável, eles são a abertura para achar as que estão certas”.

(Carl Sagan)

RESUMO

Neste trabalho, será proposto um algoritmo genético adequado ao projeto de observadores de estado para sistemas de controle multivariável, cuja resposta temporal atenda às especificações previamente fornecidas pelo usuário do sistema, tanto em termos do máximo sobressinal, quanto em termos do tempo de acomodação. Para isso, serão concebidas e avaliadas diferentes formas de inicialização e diferentes formas de configuração de algoritmo genético. Por outro lado, pretende-se investigar os resultados de desempenho desta técnica em sistemas de controle que utilizem os observadores de estado de ordem plena, ou de ordem reduzida. Por meio desta análise, pretendemos contribuir com a especificação de um algoritmo genético adequado ao projeto de observadores de estado para sistemas de controle multivariável, fazendo-se desta uma alternativa eficiente aos métodos tradicionais presentes na literatura.

Palavras-Chave: Sistemas de Controle Multivariáveis, Observadores de Estado, Algoritmos Genéticos, Resposta Transitória.

ABSTRACT

In this paper, we propose an appropriate genetic algorithm to design state observers for multivariable control systems, which response time meets the specifications previously provided by the user of the system, in terms of the maximum overshoot, and in terms of the settling time. For this, will be designed and evaluated different forms of initialization and different forms of setup the genetic algorithm. Furthermore, we intend to investigate the performance results of this technique in control systems utilizing state observers full order or reduced order. Through this analysis, intend to contribute to the specification of an appropriate genetic algorithm to design state observers for multivariable control systems, by making this an efficient alternative to traditional methods in the literature.

Keywords: Multivariable Control Systems, State Observers, Genetic Algorithms, Transient Response

LISTA DE TABELAS

Tabela 1. Substituições necessária para escrever a equação do observador de ordem reduzida.....	27
Tabela 2. Inicializações do AG.....	45
Tabela 3. Configurações do AG.....	46
Tabela 4. Matrizes de ganho do observador do Sistema 1.....	49
Tabela 5. Matrizes de ganho do observador do Sistema 1.....	49
Tabela 6. Matrizes de Ganho K e K_e do Sistema 1a.....	53
Tabela 7. Desempenhos das curvas transitórias do Sistema 1a.....	54
Tabela 8. Matrizes de Ganho K e K_e do Sistema 1b.....	54
Tabela 9. Desempenhos das curvas transitórias do Sistema 1b.....	55
Tabela 10. Matrizes de Ganho K e K_e do Sistema 1c.....	55
Tabela 11. Desempenhos das curvas transitórias do Sistema 1c.....	56
Tabela 12. Matrizes de ganho do observador do Sistema 2.....	59
Tabela 13. Matrizes de ganho do observador do Sistema 2.....	59
Tabela 14. Matrizes de Ganho K e K_e do Sistema 2a.....	64
Tabela 15. Desempenhos das curvas transitórias do Sistema 2a.....	64
Tabela 16. Matrizes de Ganho K e K_e do Sistema 2b.....	65
Tabela 17. Desempenhos das curvas transitórias do Sistema 2b.....	65
Tabela 18. Matrizes de Ganho K e K_e do Sistema 2c.....	66
Tabela 19. Desempenhos das curvas transitórias do Sistema 3c.....	66
Tabela 20. Matrizes de ganho do observador do Sistema 3.....	70
Tabela 21. Matrizes de Ganho K e K_e do Sistema 3a.....	73
Tabela 22. Desempenhos das curvas transitórias do Sistema 3a.....	73
Tabela 23. Matrizes de Ganho K e K_e do Sistema 3b.....	74
Tabela 24. Desempenhos das curvas transitórias do Sistema 3b.....	74
Tabela 25. Matrizes de Ganho K e K_e do Sistema 3c.....	75
Tabela 26. Desempenhos das curvas transitórias do Sistema 3c.....	75
Tabela 27. Matrizes de ganho do observador do Sistema 3.....	79
Tabela 28. Matrizes de Ganho K e K_e do Sistema 4a.....	82
Tabela 29. Desempenhos das curvas transitórias do Sistema 4a.....	82
Tabela 30. Matrizes de Ganho K e K_e do Sistema 4b.....	83

Tabela 31. Desempenhos das curvas transitórias do Sistema 4b.....	83
Tabela 32. Matrizes de Ganho K e K_e do Sistema 4c.....	84
Tabela 33. Desempenhos das curvas transitórias do Sistema 4c.....	84

LISTA DE FIGURAS

Figura 1 - Observador de estado de ordem plena.....	22
Figura 2 - Sistema de controle realimentado por estado observado.....	23
Figura 3 - Diagrama de blocos do sistema com controlador-observdor.....	25
Figura 4 - Sistema de controle realimentado por estado observado de ordem reduzida.....	26
Figura 5 - Processo de crossover.....	32
Figura 6 - Genes e cromossomos.....	33
Figura 7 - Fluxograma que ilustra o funcionamento do AG proposto.....	35
Figura 8 – Seleção de indivíduos através da roleta viciada.....	38
Figura 9 - Curva de resposta temporal a uma entrada em degrau.....	41
Figura 10 – Ganho K no plano complexo.....	42
Figura 11 – Lugar das raízes do Sistema 1.....	47
Figura 12 – Resposta ao Degrau Unitário do Sistema 1.....	47
Figura 13 – Resposta ao Impulso Unitário do Sistema 1.....	48
Figura 14 – Resposta temporal do observador para matriz K_e do Sistema 1.....	49
Figura 15 – Resposta temporal do observador para matriz K_e do Sistema 1.....	50
Figura 16 – Resposta temporal do observador para matriz K_e do Sistema 1.....	50
Figura 17 – Resposta temporal do observador para matriz K_e do Sistema 1.....	51
Figura 18 – Resposta temporal do observador para matriz K_e do Sistema 1.....	51
Figura 19 – Resposta temporal do observador para matriz K_e do Sistema 1.....	52
Figura 20 – Curvas de Resposta Transitória do Sistema 1a.....	53
Figura 21 - Curvas de Resposta Transitória do Sistema 1b.....	54
Figura 22 - Curvas de Resposta Transitória do Sistema 1c.....	55
Figura 23 - Lugar das raízes do Sistema 2.....	57
Figura 24 - Resposta ao Degrau Unitário do Sistema 2.....	58
Figura 25 - Resposta ao Impulso Unitário do Sistema 2.....	58
Figura 26 – Resposta temporal do observador para matriz K_e do Sistema 2.....	60
Figura 27 – Resposta temporal do observador para matriz K_e do Sistema 2.....	60
Figura 28 – Resposta temporal do observador para matriz K_e do Sistema 2.....	61
Figura 29 – Resposta temporal do observador para matriz K_e do Sistema 2.....	61
Figura 30 – Resposta temporal do observador para matriz K_e do Sistema 2.....	62

Figura 31 – Resposta temporal do observador para matriz K_e do Sistema 2.....	62
Figura 32 - Curvas de Resposta Transitória do Sistema 2a.....	63
Figura 33 - Curvas de Resposta Transitória do Sistema 2b.....	64
Figura 34 - Curvas de Resposta Transitória do Sistema 2c.....	65
Figura 35 – Lugar da raízes do Sistema 3.....	68
Figura 36 – Resposta ao Degrau unitário do Sistema 3.....	68
Figura 37 – Resposta ao Impulso Unitário do Sistema 3.....	69
Figura 38 – Resposta a Rampa unitária do Sistema 3.....	69
Figura 39 - Resposta temporal do observador para matriz K_e do Sistema 3.....	70
Figura 40 - Resposta temporal do observador para matriz K_e do Sistema 3.....	71
Figura 41 - Resposta temporal do observador para matriz K_e do Sistema 3.....	71
Figura 42 - Resposta temporal do observador para matriz K_e do Sistema 3.....	72
Figura 43 – Curva de Resposta Transitória do Sistema 3a.....	73
Figura 44 - Curva de Resposta Transitória do Sistema 3b.....	74
Figura 45 - Curva de Resposta Transitória do Sistema 3c.....	75
Figura 46 – Lugar das raízes do Sistema 4.....	77
Figura 47 – Resposta ao Degrau unitário do Sistema 4.....	77
Figura 48 – Resposta ao Impulso unitário do Sistema 4.....	78
Figura 49 – Resposta a Rampa unitária do Sistema 4.....	78
Figura 50 - Resposta temporal do observador para matriz K_e do Sistema 4.....	79
Figura 51 - Resposta temporal do observador para matriz K_e do Sistema 4.....	80
Figura 52 - Resposta temporal do observador para matriz K_e do Sistema 4.....	80
Figura 53 - Resposta temporal do observador para matriz K_e do Sistema 4.....	81
Figura 54 - Curva de Resposta Transitória do Sistema 4a.....	82
Figura 55 - Curva de Resposta Transitória do Sistema 4b.....	83
Figura 56 - Curva de Resposta Transitória do Sistema 4c.....	84

NOMENCLATURA

Abreviações

AG – Algoritmo Genético

DEFIG – *Double Fed Induction Generator*

FPGA – *Field Programmable Gate Array*

LQG – *Linear Quadratic Gaussian*

LQR – *Linear Quadratic Regulator*

MIMO – *Multiple Input, Multiple Output*

MLP – *Multi Layer Perceptron*

SISO – *Single Input, Single Output*

Siglas

UFERSA – Universidade Federal Rural do Semiárido

PPGSCA – Programa de Pós-Graduação em Sistemas de Comunicação e Automação

SUMÁRIO

LISTA DE TABELAS

LISTA DE FIGURAS

NOMENCLATURA

1 INTRODUÇÃO	14
1.1 MOTIVAÇÃO	14
1.2 OBJETIVO	19
1.3 ORGANIZAÇÃO DO TEXTO	20
2 OBSERVADORES DE ESTADO	21
2.1 OBERVADOR DE ESTADO DE ORDEM PLENA	22
2.2 OBSERVADOR DE ORDEM REDUZIDA	25
3 ALGORITMOS GENÉTICOS	30
3.1 ORIGEM	30
3.2 GENÉTICA: CONCEITOS BÁSICOS	31
3.3 NOMENCLATURA BÁSICA	32
3.4 ESTRATÉGIA DO ALGORITMO GENÉTICO	33
3.4.1 Inicialização	34
3.4.2 Codificação	36
3.4.3 População	36
3.4.4 Função de Avaliação	36
3.4.5 Método de Seleção	37
3.4.6 Reprodução	39
3.4.7 Critério de Parada	40
4 ESTRATÉGIA DE CONTROLE PROPOSTA	41
5 RESULTADOS	45
5.1 SISTEMAS DE ORDEM 2	45
5.1.1 Sistema 1	45
5.1.2 Sistema 2	55
5.2 SISTEMAS DE ORDEM 3.....	67
5.2.1 Sistema 3	66
5.2.2 Sistema 4	76
6 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	86
REFERÊNCIAS	89

1 INTRODUÇÃO

1.1 MOTIVAÇÃO

Atualmente, os sistemas de controle multivariáveis desempenham um papel relevante e possuem vasta aplicabilidade nas mais diversas áreas, como por exemplo, na geração de energia elétrica. Avanços recentes das técnicas de controle multivariável propiciam meios para a otimização dos sistemas dinâmicos, que melhoram a produtividade e contribuem para execução de tarefas mais complexas e de alta precisão. (DORF; BISHOP, 2009).

O comportamento dos sistemas dinâmicos podem ser avaliados a partir de modelos matemáticos quantitativos, em que as variáveis do sistema são analisadas para comporem o modelo matemático. Como os sistemas são dinâmicos, podemos descrevê-los usualmente por equações diferenciais, onde é possível obter uma representação matricial compacta conhecida como espaço de estado, no qual podemos aplicar um sinal de entrada e observar a saída, por exemplo. Estes sistemas podem ser representados por uma única entrada e por uma única saída (sistemas SISO) e podem também ser representados por múltiplas entradas e múltiplas saídas (sistemas MIMO). Os parâmetros que definem a dinâmica de um sistema podem, ainda, serem variantes ou invariantes no tempo.

O projeto de um sistema de controle visa obter os parâmetros de um controlador que, ao atuar no sistema dinâmico, permite obter a saída desejada do sistema. Na literatura, existem diferentes métodos para especificação dos parâmetros e dos tipos de sistemas de controle. Podemos destacar a alocação de polos com realimentação de estados, em que os parâmetros do controlador são obtidos, de tal forma, que garantam, principalmente, a estabilidade do sistema. Exemplos desta técnica são o Regulador Linear Quadrático (LQR, *Linear Quadratic Regulator*) e o Regulador Linear Quadrático Gaussiano (LQG, *Linear Quadratic Gaussian*) (DORF; BISHOP, 2009; OGATA, 2010).

Para projeto de sistemas de controle multivariáveis é necessário estimar a saída do sistema, e comparar como o valor medido. Contudo, nem sempre é possível observar (medir) as variáveis de estado de um sistema dinâmico, pois as medições podem ser difíceis de obter, quer seja, devido ao custo dos sensores e da instrumentação eletrônica envolvida, quer seja, da limitação do espaço físico, da inserção de sensores e quer seja das limitações tecnológicas (CERQUEIRA, 2010). Neste caso, a técnica de observadores de estado contribui de forma significativa com as suas estruturas para a representação de estados que não fazem parte do

conjunto de medições. Um observador de estado estima as variáveis de estado baseado nas medidas das variáveis de saída e das variáveis de controle. Os observadores de estado podem ser de ordem plena quando todas as variáveis do sistema são observadas, ou podem ser de ordem reduzida quando necessitamos apenas observar as variáveis não mensuráveis (OGATA, 2010; KWAKERNAAK, 1972).

A partir do conceito de observabilidade completa de um sistema dinâmico, é possível desenvolver observadores de estado utilizando a mesma técnica de alocação de polos utilizada para o controlador por realimentação de estados. Novamente, é possível destacar o Regulador Linear Quadrático Gaussiano (LQG, *Linear Quadratic Gaussian*) e, ainda, o controle estocástico baseado no Filtro de Kalman (FERREIRA, 2004). O filtro de Kalman é o estimador de estado de variância mínima para sistemas dinâmicos lineares com ruído Gaussiano. Mesmo se o ruído for não-Gaussiano, o filtro de Kalman é considerado o melhor estimador linear. Para sistemas não-lineares, não é possível, em geral, obter o estimador de estado ótimo de forma fechada, mas várias modificações do filtro de Kalman podem ser utilizadas para estimar o estado (SIMON, 2010). Estas modificações incluem o filtro de Kalman estendido, o filtro de Kalman sem cheiro e do filtro de partículas. Embora o filtro de Kalman e suas modificações sejam excelentes ferramentas para estimação de estado, podemos ter informações sobre um sistema que o filtro de Kalman não incorpora, como por exemplo, saber quais os estados que satisfazem as restrições de igualdade e desigualdade (SIMON, 2010). Neste caso, podemos modificar o filtro de Kalman para explorar informações adicionais e obter um melhor desempenho do que a filtragem de Kalman fornece. Em Simon (2010), é apresentado uma visão geral de várias maneiras de incorporar restrições de estado no filtro de Kalman e suas modificações não-lineares.

Muitos trabalho em modelos de observadores de estado para sistemas não-lineares são baseados no filtro de Kalman estendido que resultam em um algoritmo complexo não-linear. Apesar dos bons resultados, não há uma garantia, a priori, da convergência e estabilidade dos algoritmos (JANARTHANAN; PRAKASH, 2006). Para isso, surge a necessidade de criar um observador computacionalmente que em primeiro lugar, o sistema não-linear é representado como uma família de sistemas espaciais de estado lineares locais. Em segundo lugar, o estimador de estado é projetado para cada modelo de espaço de estado local desenvolvido usando a teoria do filtro de Kalman padrão. E em terceiro lugar, o estimador de estado global é desenvolvido através da combinação dos estimadores de estado locais e com o filtro de Kalman fuzzy aumentado que tem sido desenvolvido para gerar bons estados e parâmetros de

erro estimados na presença de falhas abruptas em um sistema dinâmico (JANARTHANAN; PRAKASH, 2006).

Em algumas aplicações o observador de estado pode ser desenvolvido para auxiliar outras técnicas de controle. Como em Changyning (2009) que aborda o desenvolvimento de um controle adaptativo fuzzy para uma classe de sistema não-lineares SISO com estados não mensurados em que um observador adaptativo fuzzy baseado em filtros é introduzido para estimação de estado, bem como para a identificação do sistema. Os observadores adaptativos fuzzy consistem de um algoritmo observador serial para reconstruir os estados do sistema em diferentes instantes de tempo em atraso para estimação de estados (WU e YU, 2006). Hilair et al (2007) descreve um sistema de controle tolerante a falha projetado para lidar com falhas em sensores de velocidade. Este controlador se baseia, primeiramente, num filtro de Kalman subótimo que descreve os estados da máquina, e em segundo, num estimador de frequência que contém informações de velocidade. Os dois observadores garantem os melhores desempenhos de estado dinâmico e constante exigidos pela aplicação e também melhoram a confiabilidade em caso de perda ou recuperação do sensor. Já Yi e Huang (2010) utilizam observadores tolerante à falha de ordem reduzida para monitorar os estados do sistema mesmo quando algumas saídas do sistema não são confiáveis.

Em um sistema tátil constituído por uma estrutura mecânica articulada com motores, sensores e com boa eletrônica embarcada, temos que o controle de velocidade desses sistemas tornam-se instáveis em baixa velocidade devido a velocidade imposta pela mão do operador (JABBOUR, 2009). Para esse tipo de sistema o observador de estado de ordem completa de velocidade de estado pode ser implementado, bem como um filtro de Kalman para um único grau de liberdade de interface tátil impulsionado por um motor síncrono de ímã permanente ajudam a estimar a velocidade exata (JABBOUR, 2009; MITSANTISUK et al. 2012).

Berci e Bottura (2008) utilizam uma rede neural artificial do tipo MLP (*Multi Layer Perceptron*) para realizar um mapeamento estático, caracterizando uma nova classe de observadores não baseados em modelo que estima o estado do sistema. Essa rede será treinada com base na saída mensurável do sistema para apresentar estimativas do estado, e este processo de treinamento se dá enquanto o sistema se encontra em operação, o que faz da rede neural, um dispositivo adaptativo que aprende o comportamento do estado do sistema de forma *on-line*. Alanis (2011) também desenvolve um observador neural de tempo discreto não-linear para sistemas não-lineares com perturbações externas e parâmetros incertos. Este observador baseia-se numa rede neural de ordem elevada de tempo discreto treinada com um

algoritmo filtro de Kalman estendido. O uso de observadores com base em rede neural tem-se mostrado como uma alternativa eficiente para implementar observadores de estado em sistemas embarcados. Em Loh et al (2009) apresentam uma metodologia de implementação de um observador de estado baseado em rede neural em FPGA. O estudo desta pesquisa mostrou que o projeto observador de estado pode ser implementado em hardware, sem a necessidade de sacrificar o desempenho ou aumentar o custo de implementação. As perspectivas da pesquisa pode ser aplicada a áreas como sistemas tolerantes ou de auto-diagnóstico de falhas (LOH et al, 2009).

Apesar dos resultados obtidos, a partir da aplicação dessas técnicas em processo de otimização, serem satisfatórios, infelizmente, os ajustes dos parâmetros do controlador que atendam aos requisitos de desempenho para resposta temporal do sistema não constituem uma tarefa fácil de ser realizada, devido ao processo empírico envolvido no método, de tentativa e erro, exigindo do projetista certa experiência e bastante esforço, na busca de uma solução para a definição das matrizes peso.

Diante dessa dificuldade, faz-se necessário investigar técnicas diferentes das que permitam obter o desempenho especificado para resposta temporal de um sistema. Este problema apresenta características semelhantes a um problema de otimização. Nesse aspecto, os Algoritmos Genéticos (AG's) são uma técnica com características e potencial para ser aplicada na busca dos parâmetros de um observador. Em Pereira (2011) um AG é implementado para otimizar uma rede de distribuição de um sistema de abastecimento de água, utilizando o modelo da árvore geradora mínima generalizada. Miasaki e Romero (2005; 2007) propõem uma nova estratégia para representar o problema da expansão da transmissão a longo prazo, em que um modelo matemático considera a instalação de dispositivos de compensação série e um AG especializado, com codificação inteira e real, foi implementado com a intenção de fornecer como solução, a quantidade e o local, onde devem ser instalados as novas linhas de transmissão e os dispositivos de compensação série, além do valor da compensação. Berci e Bottura (2010) implementam um controlador genético para controlar esse sistema utilizando computação massiva para encontrar o valor da entrada que leva a saída do sistema para o valor de referência, utilizando o modelo não linear do pêndulo invertido sem qualquer simplificação. Segundo Bento e Kagan (2008), o emprego do AG possibilita a análise de redes reais, sem necessidade de simplificações ou aproximações, o que permite a obtenção de soluções otimizadas em tempos de execução compatíveis para aplicações em atividades de planejamento da expansão e da operação. As variantes do AG permitem

melhorar a robustez dos resultados e reduzir os tempos de execução, compatíveis com a aplicação em redes de distribuição. Em um algoritmo genético, devem ser sempre analisados os seus principais parâmetros: tamanho da população, número de gerações, taxa de cruzamento e a taxa de mutação. Estes parâmetros serão analisados quanto a sua influência na qualidade da solução apresentada pelo algoritmo e no tempo necessário para convergência (MIRANDA et al. 2011). Os AG's apresentam-se como uma alternativa viável para a abordagem de problemas de otimização e/ou busca de alta complexidade matemática. O custo computacional dos AG's são dominados pela execução da função de fitness e dos operadores genéticos (SANTOS, 2008). Os AG's são mais apropriados de serem utilizados em problemas intratáveis, ou seja, problemas com espaço de busca tão amplo, que precisaria de um tempo extraordinariamente longo para percorrê-lo, sendo, portanto, considerados sem solução para métodos de busca exaustiva. Os AG's não percorrem necessariamente todo o espaço de busca para encontrar uma solução, mas, realizam suas buscas providos de informações, o que lhes permite encontrar boas soluções em um tempo aceitável (SIVANANDAM; DEEPA, 2008).

Os algoritmos genéticos podem manipular, eficientemente, uma grande quantidade de informação acumulada sobre o problema, através de mecanismos relativamente simples (os operadores genéticos). São capazes, também, de explorar várias soluções ao mesmo tempo (paralelismo), ao invés de, uma única solução por vez, como nas técnicas tradicionais de busca e otimização. Um AG usa princípios da evolução, a seleção natural e a genética para oferecer um método de pesquisa paralela de espaço complexos (PORTER, 1995). Estas características permitem aos AG's grande capacidade de adaptação a problemas diversos. Porter (1995) utiliza um AG para realizar estimação de estado adaptativo on-line para sistemas não-lineares, mostrando como construir uma genética em que um AG evolui os ganhos de um observador de estado em tempo real, de modo que o erro de estimação de estado é levado a zero. Apesar de não haver a garantia de encontrar a solução ótima, as aplicações correntes de AG's em projetos de controladores para sistemas SISO e MIMO têm levado à obtenção de boas soluções em termos de alocação de polos (WANG, 2006; OLIVEIRA, 2012).

Neste trabalho, será proposto um algoritmo genético otimizado adequado ao projeto de observadores de estado para sistemas de controle multivariável, cuja resposta temporal atenda às especificações previamente fornecidas pelo usuário do sistema, tanto em termos do máximo sobressinal, quanto em termos do tempo de acomodação. Para isso, serão concebidas e avaliadas 9.600 execuções de 240 tipos de algoritmos genéticos distintos, variando-se entre

estes diversos parâmetros típicos da especificação de um algoritmo genético. Por outro lado, pretende-se investigar os resultados de desempenho desta técnica em sistemas de controle que utilizem os observadores de estado de ordem plena, ou de ordem reduzida. Por meio desta análise, pretendemos contribuir com a especificação de um algoritmo genético otimizado adequado ao projeto de observadores de estado para sistemas de controle multivariável, fazendo-se desta uma alternativa eficiente aos métodos tradicionais presentes na literatura.

A investigação de técnicas que aprimorem a busca dos parâmetros de controle de um observador de estado contribuem de forma bastante significativa para a etapa de implementação desse observador, pois os parâmetros obtidos proporcionam uma rápida convergência, e valores de tempo de acomodação e máximo sobressinal abaixo do especificado. Além disso, os parâmetros são obtidos com limites de magnitude, o que favorece o gasto energético, viabilizando a etapa de implementação. Como exemplo, podemos citar a aplicação desses parâmetros para controle de turbinas eólicas de velocidade variável em conjunto com DFIG (*Double Fed Induction Generator*) (BARROS, 2006).

1.2 OBJETIVOS

Geral

Propor uma técnica de projeto de observadores de estado, baseada em algoritmo genético, que leva à obtenção da resposta temporal do sistema, de modo a atender aos requisitos definidos pelo projetista para o máximo sobressinal e tempo de acomodação.

Específicos

- Implementar um algoritmo genético que busque parâmetros de projeto tanto para observadores de estado de ordem plena, como para observadores de estado de ordem mínima, o qual satisfaça as especificações, previamente fornecidas pelo projetista, para a resposta temporal do sistema.
- Testar diferentes configurações, modificando-se os parâmetros típicos de AG, tais como, por exemplo, tipo de cruzamento, forma de codificação dos indivíduos, mecanismo de mutação, etc, identificando o algoritmo genético mais adequado a esta aplicação.

- Testar diferentes tipos de sistema (como exemplo, sistemas com ordens distintas, sistemas com múltiplas entradas, sistemas com múltiplas saídas), com o algoritmo genético desenvolvido.
- Comparar os parâmetros obtidos pelo AG com outros métodos existentes na literatura atual.

1.3 ORGANIZAÇÃO DO TEXTO

O capítulo 2 apresenta o conceito de observadores de estado, apresentando os tipos de observadores e a modelagem matemática envolvida na definição dos parâmetros de um observador de estado.

No capítulo 3, introduziremos explicações sobre algoritmos genéticos, como a origem, conceitos básicos e apresentaremos uma descrição do algoritmo genético proposto para observador de estado.

No capítulo 4, apresentamos a proposta da dissertação de mestrado considerando a aplicação conjunta de Algoritmos Genéticos com a Teoria de Controle para Observadores de Estado.

No capítulo 5, apresentamos os resultados obtidos do observador AG em ambiente MATLAB.

2 OBSERVADORES DE ESTADO

Em projetos de sistemas de controle, temos como consideração básica, que todas as variáveis de estado sejam acessíveis para medição. Porém, a realidade prática nos mostra que nem sempre as variáveis de estado estão acessíveis para serem medidas. Portanto, é preciso estimar estas variáveis não mensuráveis ou não medidas. Este processo de estimação das variáveis de estado é comumente chamado de observação. Um dispositivo (ou programa de computador) que estima ou observa as variáveis de estado é denominado observador de estado.

Quando um observador de estado estima todas as variáveis de estado do sistema, independentes se estas variáveis estão acessíveis, ou não, este observador é denominado observador de ordem plena. Se somente algumas das variáveis de estado do sistema estão acessíveis para serem medidas, podemos desenvolver um observador de estado que estima somente aquelas que não são acessíveis para medição. Neste caso o observador desenvolvido é denominado observador de estado de ordem reduzida ou observador de estado de ordem mínima. Considere a planta definida por:

$$\dot{x} = Ax + Bu \quad (1)$$

$$y = Cx \quad (2)$$

Onde: x = vetor de estado (vetor n), sendo $x \in \mathbb{R}^n$;

u = vetor de controle (vetor r), sendo $u \in \mathbb{R}^r$;

y = vetor de saída (vetor m), sendo $y \in \mathbb{R}^m$;

A = matriz $n \times n$, com $A \in \mathbb{R}^{n \times n}$;

B = matriz $n \times r$, com $B \in \mathbb{R}^{n \times r}$;

C = matriz $m \times n$, com $C \in \mathbb{R}^{m \times n}$.

O observador é um subsistema reconstrutor do vetor de estado da planta. O modelo matemático é basicamente o mesmo da planta, exceto por incorporar um termo adicional que compensa as incertezas nas matrizes A e B e a ausência do erro inicial. São conhecidos como **erro de estimação** ou **erro de observação** e podem ser definidos pela diferença entre a saída medida e a saída estimada. O erro inicial é a diferença entre o estado inicial e o estado inicial estimado. Portanto, definimos o modelo matemático de um observador como:

$$\dot{\tilde{x}} = A\tilde{x} + Bu + K_e(y - C\tilde{x}) = (A - K_eC)\tilde{x} + Bu + K_ey \quad (3)$$

Onde $\tilde{x}$ é o estado estimado e $C\tilde{x}$ é a saída estimada. As entradas do observador são a saída y e a entrada u . A matriz K_e é denominada matriz de ganho do observador que atua

como um termo de correção que envolve a diferença entre a saída medida y e a saída estimada $C\tilde{x}$. Esse termo corrige continuamente a saída do modelo e aumenta o desempenho do observador. A Figura 1 mostra o diagrama de blocos do sistema e do observador de estado de ordem plena.




Figura 1 - Observador de estado de ordem plena.

2.1 OBSERVADOR DE ESTADO DE ORDEM PLENA

Este tipo de observador possui a mesma ordem da planta. Supondo que a planta seja definida pelas Equações (1) e (2), temos que para encontrarmos o erro de observação, subtraímos a Equação (3) a partir da Equação (1).

$$\dot{x} - \dot{\tilde{x}} = Ax - A\tilde{x} - K_e(Cx - C\tilde{x}) = (A - K_eC)(x - \tilde{x}) \quad (4)$$

Definindo o vetor de erro como $e = x - \tilde{x}$, transformamos a Equação (4) em:

$$\dot{e} = (A - K_eC)e \quad (5)$$

Analisando a Equação (5), notamos que o comportamento dinâmico do vetor de erro é determinado pelos autovalores da matriz $(A - K_eC)$. Se a matriz $(A - K_eC)$ for uma matriz estável, o vetor de erro convergirá para zero, qualquer que seja o vetor de erro inicial $e(0)$. Ou seja, $\tilde{x}(t)$ convergirá para $x(t)$ independente do valor de $x(0)$ e $\tilde{x}(0)$. Se os autovalores da matriz $(A - K_eC)$ forem escolhidos de tal maneira que o comportamento do vetor de erro

seja assintoticamente estável e adequadamente rápido, então qualquer vetor de erro tenderá a zero (a origem) com uma velocidade adequada.

Outra consideração importante é que se a planta for completamente observável, é possível escolher a matriz K_e tal que $(A - K_e C)$ tenha seus autovalores escolhidos arbitrariamente. Para tanto, é preciso verificar a condição necessária e suficiente para observação de estado. Ou seja, a partir das Equações (1) e (2), verificamos que o posto de:

$$[C^* : A^* C^* : \dots : (A^*)^{n-1} C^*] \quad (6)$$

Seja n . Esta é a condição de observabilidade completa do sistema original definido pelas Equações (1) e (2).

Uma vez que tenhamos selecionado os autovalores desejados (ou a equação característica desejada), o observador de estado de ordem plena poderá ser projetado, desde que a planta seja completamente observável. Os autovalores desejados da equação característica devem ser escolhidos de modo que o observador responda, pelos menos, duas a cinco vezes mais rápido que o sistema em malha fechada considerado.

O processo de projeto, portanto, passa a ter dois estágios, sendo o primeiro a determinação da matriz K de realimentação que produzirá a equação característica desejada, e o segundo consiste na determinação da matriz de ganho K_e do observador que produzirá a equação do observador desejada. A Figura 2 apresenta o diagrama de blocos de um sistema de controle realimentado por estado observado.




Figura 2 - Sistema de controle realimentado por estado observado.

Considerando um sistema completamente controlável e observável, definido pelas Equações (1) e (2), temos a lei de controle baseado no estado observado $\tilde{x}$,

$$u = -K\tilde{x} \quad (7)$$

Utilizado para esse controle, produz a equação de estado:

$$\dot{x} = Ax - BK\tilde{x} = (A - BK)x + BK(x - \tilde{x}) \quad (8)$$

Como o erro $e(t)$ é dado por $x(t) - \tilde{x}(t)$, reescrevemos (8) como:

$$\dot{x} = (A - BK)x + BKe \quad (9)$$

Utilizando a Equação (5) do erro do observador e combinando esta com a equação (9), teremos:

$$\begin{bmatrix} \dot{x} \\ \dot{e} \end{bmatrix} = \begin{bmatrix} A - BK & BK \\ 0 & A - K_e C \end{bmatrix} \begin{bmatrix} x \\ e \end{bmatrix} \quad (10)$$

A Equação (10) descreve as dinâmicas do sistema de controle realimentado por estado observado. A equação característica desse sistema é:

$$\begin{bmatrix} sI - A + BK & -BK \\ 0 & sI - A + K_e C \end{bmatrix} = 0 \quad ou \quad (11)$$

$$|sI - A + BK| |sI - A + K_e C| = 0$$

Note que os polos de malha fechada do sistema de controle realimentado por estado observado consistem nos polos decorrentes do projeto por alocação de polos e dos polos decorrentes do projeto isolado do observador. Isso significa que o projeto da alocação de polos e o projeto do observador são independentes entre si. Eles podem ser conduzidos separadamente e combinados para formar o sistema de controle realimentado por estado observado.

Se considerarmos uma planta definida pelas Equações (1) e (2), e supondo que esta planta seja completamente observável, ao aplicarmos uma lei de controle por realimentação de estado observado, teremos que as equações do observador serão dadas por:

$$\dot{\tilde{x}} = (A - K_e C - BK)\tilde{x} + K_e y \quad (12)$$

$$u = -K\tilde{x} \quad (13)$$

Supondo uma condição inicial nula e resolvendo a transformada de Laplace para $\tilde{X}(s)$ da Equação (12), teremos:

$$\tilde{X}(s) = (sI - A + K_e C + BK)^{-1} K_e Y(s) \quad (14)$$

Substituindo $\tilde{X}(s)$ na Equação (13) e realizando a transformada de Laplace, obtemos:

$$U(s) = -K(sI - A + K_e C + BK)^{-1} K_e Y(s) \quad (15)$$

Então, a função transferência $U(s)/Y(s)$ pode ser obtida como:

$$\frac{U(s)}{Y(s)} = -K(sI - A + K_e C + BK)^{-1} K_e \quad (16)$$

A Figura 3 mostra a representação em diagrama de blocos do sistema. Note que a função de transferência $K(sI - A + K_e C + BK)^{-1} K_e$ age como controlador do sistema. Por isso, denominamos esta função de transferência como função de transferência do controlador-observador.




Figura 3 - Diagrama de blocos do sistema com controlador-observador.

É importante destacar que a matriz do controlador-observador $A - K_e C - BK$ pode ser estável ou não, embora que $A - BK$ e $A - K_e C$ sejam escolhidas para serem estáveis.

2.2 OBSERVADOR DE ORDEM REDUZIDA

Temos que na prática, algumas variáveis de estado podem ser medidas com exatidão. Portanto, estas variáveis não precisam ser estimadas ou observadas.

Suponha que um vetor de estado x seja um vetor de dimensão n e que a saída seja um vetor y de dimensão m que pode ser medido. Como as m variáveis de saída são combinações lineares das variáveis de estado, então m variáveis de estado não precisam ser estimadas. Precisamos estimar apenas $n - m$ variáveis de estado. Então, um observador de ordem reduzida se torna um observador de ordem $(n - m)$, que também pode ser denominado como um observador de ordem mínima. A Figura 4 mostra um diagrama de blocos de um sistema com um observador de ordem mínima.




Figura 4 - Sistema de controle realimentado por estado observado de ordem reduzida.

Para apresentar a ideia básica do observador de ordem mínima, vamos considerar que a saída que pode ser medida seja um escalar (ou seja, $m = 1$). Consideramos então, o sistema como descrito pelas Equações (1) e (2), onde o vetor x é particionado em duas partes: x_a (escalar) que é igual a saída y e, portanto, pode ser medida diretamente e x_b (vetor com dimensão $n - 1$) que é a porção não medida do vetor de estado. Desse modo, a equação de estado particionada e a de saída resultam em:

$$\begin{bmatrix} \dot{x}_a \\ \dots \\ \dot{x}_b \end{bmatrix} = \begin{bmatrix} A_{aa} & \vdots & A_{ab} \\ \dots & \dots & \dots \\ A_{ba} & \vdots & A_{bb} \end{bmatrix} \begin{bmatrix} x_a \\ \dots \\ x_b \end{bmatrix} + \begin{bmatrix} B_a \\ \dots \\ B_b \end{bmatrix} u \quad (17)$$

$$y = \begin{bmatrix} 1 & \vdots & 0 \end{bmatrix} \begin{bmatrix} x_a \\ \dots \\ x_b \end{bmatrix} \quad (18)$$

Onde: A_{aa} = escalar;

A_{ab} = matriz $1 \times (n - 1)$;

A_{ba} = matriz $(n - 1) \times 1$;

A_{bb} = matriz $(n - 1) \times (n - 1)$;

B_a = escalar;

B_b = matriz $(n - 1) \times 1$.

A partir da Equação (17), podemos retirar a equação da porção mensurável do estado que resulta em:

$$\begin{aligned} \dot{x}_a &= A_{aa}x_a + A_{ab}x_b + B_a u \quad \text{ou} \\ \dot{x}_a - A_{aa}x_a - B_a u &= A_{ab}x_b \end{aligned} \quad (19)$$

A Equação (19) age como a equação de saída. No projeto de observadores de ordem mínima, consideramos o lado esquerdo da Equação (19) como quantidades conhecidas. Da mesma forma, a partir da equação (17), podemos retirar a equação não mensurável do estado que resulta em:

$$\dot{x}_b = A_{ba}x_a + A_{bb}x_b + B_bu \quad (20)$$

Como as quantidades $A_{ba}x_a$ e B_bu são conhecidas, a Equação (20) descreve as dinâmicas da porção não mensurável do estado.

Quando comparamos a equação de estado do observador de ordem plena que é obtido a partir da Equação (1) ($\dot{x} = Ax + Bu$), temos que a equação de estado do observador de ordem mínima é representada de acordo com a Equação (20). Já equação de saída do observador de ordem plena é dada pela Equação (2) ($y = Cx$), enquanto que, a equação de saída do observador de ordem mínima é obtida pela Equação (19).

O projeto de observadores de ordem mínima pode ser construído a partir do observador de ordem plena ao substituirmos as quantidades da Equação (7) pelas quantidades apresentadas nas Equações (19) e (20) associando cada quantidade com o valor comparado para ordem plena. A Tabela 1 lista as substituições necessárias para escrever a equação do observador de ordem mínima.

Tabela 1. Substituições necessária para escrever a equação do observador de ordem reduzida.

Observador de estado de ordem plena	Observador de estado de ordem mínima
$\tilde{x}$	$\tilde{x}_b$
A	A_{bb}
Bu	$A_{ba}x_a + B_bu$
y	$\dot{x}_a - A_{aa}x_a - B_a u$
C	A_{ab}
K_e (<i>matriz</i> $n \times 1$)	K_e [<i>matriz</i> $(n - 1) \times 1$]

Então, fazendo as substituições necessárias, construímos a equação do observador de ordem mínima como segue:

$$\dot{\tilde{x}}_b = (A_{bb} - K_e A_{ab})\tilde{x}_b + A_{ba}x_a + B_bu + K_e(\dot{x}_a - A_{aa}x_a - B_a u) \quad (21)$$

Onde a matriz K_e do observador de estado é uma matriz $(n - 1) \times 1$.

Na Equação (21), podemos observar que para estimar $\tilde{x}_b$, precisamos diferenciar x_a , o que representa uma dificuldade, pois a diferenciação amplifica ruídos. Portanto, analisando a Equação (19), podemos reescrever a equação do observador de ordem mínima como:

$$\dot{\tilde{x}}_b = (A_{bb} - K_e A_{ab})\tilde{x}_b + A_{ba}x_a + B_b u + K_e A_{ab}x_b \quad (22)$$

Em seguida, obteremos a equação do erro do observador de ordem mínima. Então, subtraindo a Equação (22) da Equação (20), teremos:

$$\dot{x}_b - \dot{\tilde{x}}_b = (A_{bb} - K_e A_{ab})(x_b - \tilde{x}_b) \quad (23)$$

Por definição, temos que $e = x_b - \tilde{x}_b$, o que transforma a Equação (23) em:

$$\dot{e} = (A_{bb} - K_e A_{ab})e \quad (24)$$

Que é a equação do erro do observador de ordem mínima, onde e é um vetor de ordem $(n - 1)$. Portanto, a partir da Equação (24), podemos obter as dinâmicas de erro livremente, seguindo a mesma técnica desenvolvida para o observador de ordem plena. Para isso temos que o posto da matriz:

$$\begin{bmatrix} A_{ab} \\ A_{ab}A_{bb} \\ \vdots \\ A_{ab}A_{bb}^{n-2} \end{bmatrix} \quad (25)$$

Seja $(n - 1)$. Esta é a condição de observabilidade completa aplicada ao observador de ordem mínima. A equação característica do observador de ordem mínima é obtida a partir da Equação (24) como segue:

$$\begin{aligned} |sI - A_{bb} + K_e A_{ab}| &= (s - \mu_1)(s - \mu_2) \dots (s - \mu_{n-1}) = \\ s^{n-1} + \hat{\alpha}_1 s^{n-2} + \dots + \hat{\alpha}_{n-2} s + \hat{\alpha}_{n-1} &= 0 \end{aligned} \quad (26)$$

Onde $\mu_1, \mu_2, \dots, \mu_{n-1}$ são os autovalores desejados do observador de ordem mínima. A matriz de ganho K_e do observador pode ser determinada escolhendo-se primeiro os autovalores desejados do observador de ordem mínima e utilizando-se do procedimento já desenvolvido para o observador de ordem plena com as modificações apropriadas.

Já vimos que para o caso do sistema de controle realimentado por estado observado com observador de ordem plena, temos que os polos de malha fechada consistem nos polos devido ao projeto isolado da alocação de polos e dos polos devidos ao projeto isolado do observador. Para o caso do sistema de controle realimentado por estado observado com observador de

ordem mínima, a mesma conclusão se aplica. Portanto, a equação característica pode ser obtida como:

$$|sI - A + BK||sI - A_{bb} + K_e A_{ab}| = 0 \quad (27)$$

Mais uma vez, temos que os polos de malha fechada do sistema de controle realimentado por estado observado com um observador de ordem mínima compreendem os polos de malha fechada da alocação de polos [autovalores da matriz $(A - BK)$] e os polos de malha fechada devido ao observador de ordem mínima [autovalores da matriz $(A_{bb} - K_e A_{ab})$]. Portanto, o projeto da alocação de polos e o projeto do observador de estado de ordem mínima são independentes entre si.

3 ALGORITMOS GENÉTICOS

Algoritmos Genéticos (AGs) são inspirados no processo de evolução natural, e visam buscar soluções sub-ótimas para problemas cuja complexidade combinatória é elevada. Assim, suas bases surgiram com as teorias de Charles Darwin. Posteriormente, a estas teorias foram adicionados o formalismo matemático, o que permitiu escrever soluções na forma de um algoritmo computacional, o algoritmo genético (MELANIE, 1999; HAUPT, R.; HAUPT, S., 1998).

Os AGs são heurísticas que não têm a garantia de encontrar a solução ótima, porém, são capazes de encontrar boas soluções. A utilização de AG é mais apropriado em problemas intratáveis. Os problemas intratáveis têm o espaço de solução tão amplo que, precisariam de um tempo extraordinariamente longo para percorrê-lo, sendo, portanto considerados sem solução para métodos de busca exaustiva (LINDEN, 2006).

3.1 ORIGEM

O naturalista Charles Robert Darwin (1809 - 1882) desenvolveu seu trabalho em uma viagem a bordo do navio H.M.S Beagle para as Ilhas Galápagos, que durou quase cinco anos e teve início no ano de 1831. Antes de Darwin, outros estudiosos já estavam tentando decifrar o evolucionismo, mas foi ele em seu livro “*A Origem das Espécies*”, publicado em 1859, quem definiu as teorias que são aceitas como supostamente corretas até os dias de hoje. Darwin observou nas Ilhas Galápagos, que animais da mesma espécie tinham pequenas diferenças devido a algumas adaptações dos diferentes ecossistemas em que viviam (HAUPT, R.; HAUPT, S., 1998).

Sua obra defende duas proposições importantes: organismos descendem de ancestrais em comum com algumas modificações e que o principal fator de modificação é a Seleção Natural. Numa definição mais detalhada, a teoria da evolução descreve a disputa dos indivíduos dentro de um mesmo ecossistema devido às limitações de recurso na natureza. Aqueles que forem classificados como mais fortes são os que terão maior chance de proliferar, o que garante a formação de descendentes mais adaptados àqueles ecossistemas.

Baseando-se na teoria da seleção natural, por volta de 1940, inicia-se o desenvolvimento da teoria dos Algoritmos Genéticos. Os pesquisadores buscavam soluções para problemas complexos e tomavam como inspiração a teoria da evolução, visto que, essa

teoria foi concebida a partir da análise de um complexo problema na natureza: a seleção natural (MELANIE, 1999).

Na década de 60, John Holland começa a realizar os primeiros Algoritmos Genéticos. Ele representou os cromossomos por cadeias de 0's e 1's e propôs um modelo heurístico na tentativa de chegar à solução de problemas complexos. Holland em 1975 publicou "*Adaptation in Natural and Artificial Systems*", o primeiro trabalho em AG, considerado na época um grande incentivo para pesquisas sobre o assunto, que vem evoluindo até os dias de hoje com uma grande dimensão de aplicações nas mais diversas áreas (HAUPT, R.; HAUPT, S., 1998).

3.2 GENÉTICA: CONCEITOS BÁSICOS

As características de cada indivíduo estão armazenadas no núcleo de suas células em estruturas denominadas cromossomos, que em conjunto denominam-se genoma. Os cromossomos são os responsáveis pelas características físicas: cor dos pêlos, tamanho, cor dos olhos e também por algumas características psicológicas, dentre outras. São formados em pares, sendo que a quantidade varia de espécie para espécie, nos humanos, por exemplo, são 23 pares em cada célula, ou seja, 46 cromossomos. A unidade básica dos cromossomos são os genes, cada gene é responsável por apenas uma característica física do indivíduo, eles são blocos de sequência de ácido desoxirribonucleico ou Deoxyribonucleic Acid DNA, e tem sua posição determinada no cromossomo, chamada de locus (OTTO, 2004).

Na natureza existem duas maneiras de os seres vivos se reproduzirem: a assexuada e a sexuada. A primeira ocorre em organismos inferiores como os vírus e as bactérias, que fazem cópias de si próprios, não apresenta variações, exceto em caso de mutações. Já na reprodução sexuada, dois organismos formam um novo organismo com a junção de seus materiais genéticos. O novo organismo difere de seus pais, por ter sido criado a partir de metade dos genes de cada um e ainda por alguns eventos durante a meiose (processo de divisão celular): crossover e mutação, apresentados a seguir (OTTO, 2004).

O processo de gerar um novo indivíduo tem como primeira etapa a duplicação dos cromossomos, e posteriormente acontece o crossover ou crossing-over, que é a troca de parte do cromossomo, por outra parte do cromossomo homólogo (cromossomo que forma o par). Esse processo é ilustrado na Figura 5.




Figura 5 - Processo de crossover.

O nome crossover é devido ao cruzamento de um cromossomo sobre o outro para troca de genes, sendo que poderá ocorrer em vários pontos. A Figura 5 ilustra o crossover em apenas um ponto para facilitar o entendimento.

A divisão celular (processo de replicação do DNA) tem complexidade elevada, e com isso, pequenos erros podem vir a ocorrer, gerando modificações no conjunto de genes da população. A esse processo, denominamos de mutações. Existem mutações desfavoráveis, que são eliminadas por meio da seleção natural, e existem as vantajosas, que são proliferadas e aceitas como mudanças adaptativas. E existem também, as mutações neutras, que não influenciam na aptidão dos indivíduos (MELANIE, 1999).

Os Algoritmos Genéticos são inspirados neste processo de evolução natural e são utilizados para resolver problemas de busca e otimização encontrados no mundo real. Segundo Fernandes (2005), os Algoritmos Genéticos buscam a melhor solução para os problemas de otimização, utilizado um processo iterativo de busca da melhor solução para o seu problema. Onde a busca se dá a partir de uma população inicial, que combinando os melhores representantes desta população, obtém uma nova, que passa a substituir a anterior. A cada nova iteração é gerada uma nova população que apresenta novas e melhores soluções para o problema em questão, culminando com a sua convergência (FILLITO, 2008).

3.3 NOMENCLATURA BÁSICA

Os AGs utilizam muitos termos provenientes da biologia. A seguir, temos uma descrição sucinta dos significados que serão explorados pelo algoritmo genético.

Gene: variável de otimização, ou seja, uma codificação dos parâmetros de otimização, ilustrado na Figura 6.

Cromossomo: conjunto de genes, é também chamado de indivíduo, candidato a solução de otimização, ilustrado na Figura 6.




Figura 6 - Genes e cromossomos

População inicial: conjunto de todos os cromossomos (indivíduos) criados aleatoriamente, onde será feita a busca pela solução.

Gerações: populações criadas a partir da população inicial através da aplicação de crossover e mutação.

Pai: indivíduo selecionado para o cruzamento.

Filho: indivíduo criado no cruzamento entre dois pais.

Além desses conceitos, existem outros que são relevantes para o algoritmo genético.

Função de Avaliação: função que avalia cada indivíduo da população atribuindo um valor que mostra o quão distante aquele indivíduo está da solução. É também chamada de função de aptidão ou função fitness.

Critério de Parada: exigência para que o algoritmo encerre. Pode ser número de gerações, tempo de execução ou solução encontrada.

3.4 ESTRATÉGIA DO ALGORITMO GENÉTICO

O primeiro passo para a concepção do algoritmo genético otimizado requer um mapeamento das principais variáveis de entrada, do próprio algoritmo (forma de codificação dos indivíduos, tamanho da população, tipo e taxa de cruzamento, etc.), em parâmetros do observador, que leve a uma resposta temporal que atenda as especificações fornecidas pelo projetista para o máximo sobressinal e tempo de acomodação (OLIVEIRA, 2010, 2012).

Infelizmente, apesar de existirem diversas alternativas para se escolher os parâmetros de um algoritmo genético, o mapeamento destes parâmetros com as características da estratégia de controle que se deseja buscar ainda não foi feito, com base no melhor conhecimento que se tem da literatura especializada. Por outro lado, embora a literatura especializada apresente diversas alternativas para a escolha de certos parâmetros (exemplo: tipo de cruzamento, forma de codificação dos indivíduos, mecanismo de mutação, etc.), nem sempre é fácil comparar os

resultados de aplicações distintas, onde foram utilizados algoritmos realmente diferentes, dada as características próprias da aplicação como, por exemplo, as funções de avaliação utilizadas. Isto dificulta a concepção de um algoritmo genético por parte dos projetistas de sistemas de controle. Esta dificuldade será considerada nesta e nas próximas seções (OLIVEIRA, 2010, 2012).

Como a modelagem analítica das possíveis relações existentes exigiria empreender um esforço bastante elevado, dada às particularidades de cada fluxograma possível e as características próprias do problema de otimização, para avaliar como cada etapa do algoritmo influencia na qualidade das soluções obtidas (valores para o máximo sobressinal e tempo de acomodação) e no esforço computacional necessário (número de gerações), utilizaremos de um único fluxograma e avaliaremos instâncias distintas deste, obtidas a partir de uma combinação de métodos de seleção, tamanhos de população e intervalos de valores para os genes. A Figura 7 apresenta o fluxograma do AG proposto neste trabalho. A seguir, cada bloco da Figura 7 será apresentado com um nível maior de detalhes de funcionamento.

3.4.1 Inicialização

Na fase inicial, é necessário definir o tamanho da população, o esquema de codificação dos dados a serem manipulados pelo algoritmo, o intervalo de valores possíveis para os genes e as taxas de cruzamento e mutação. Esta tarefa requer algumas considerações, que serão feitas a seguir.

O tamanho da população interfere na diversidade e no tempo em que o algoritmo processa uma geração. Se o tamanho da população for subdimensionado, a diversidade da população fica limitada, o que exige mais gerações para que o espaço de busca forneça uma solução. Caso o tamanho da população seja demasiadamente grande, é provável que seja obtida uma solução com baixo número de gerações, mas o tempo de processamento do AG pode ser bastante elevado por geração, tornando lenta a busca por soluções com melhor qualidade.

É relevante destacar que a própria definição dos valores dos genes na composição dos indivíduos também influencia o número de gerações na convergência do algoritmo. Assim, caso os indivíduos tenham genes muito parecidos, a diversidade da população é baixa. Se os valores dos genes forem muitos distantes, então a convergência do AG para uma solução poderia ser retardada.

O trabalho proposta deverá considerar o problema de se dimensionar o tamanho de população que proporcione uma boa relação entre complexidade computacional (número de gerações) e precisão (parâmetros do observador que proporcionem o regime transitório desejado). Para isto, diversos tamanhos de população serão considerados na definição das várias instâncias do algoritmo genético básico. Para cada tamanho de população, diversos intervalos de inicialização para os genes serão examinados na busca pela melhor configuração para o algoritmo.




Figura 7 - Fluxograma que ilustra o funcionamento do AG proposto.

3.4.2 Codificação

A forma de codificação dos dados relaciona o problema de otimização ao AG. No AG proposto neste trabalho, cada indivíduo é uma matriz ganho do observador, K_e , e os ke_{nm} são os genes que constituem o indivíduo. Como os parâmetros do observador podem assumir valores reais, a codificação por valor foi escolhida, permitindo que genes assumam valores deste conjunto.

3.4.3 População

Embora a fase de inicialização possa garantir um formato adequado para os indivíduos na composição da população inicial, durante a execução do algoritmo, é provável que os valores assumidos pelos genes, se tornem elevados, visto que, em termos de estabilidade, observadores com parâmetros, em módulo, maiores permitem um rápido retorno ao estado inicial, logo após o surgimento de alguma perturbação, o que é uma vantagem. Entretanto, para isso são exigidos maiores requisitos em termos do gasto energético, o que na prática poderá inviabilizar a implementação deste observador.

Para se contornar essa dificuldade, pode-se estabelecer um limiar adequado para selecionar os genes que serão manipulados pelos operadores de reprodução, durante o processo de formação de novos indivíduos. Desta forma, quando os indivíduos são criados pelo operador de cruzamento, ou modificados pelo operador de mutação, eles são obrigados a obedecer ao valor máximo imposto pelo limite.

3.4.4 Função de Avaliação

A função de avaliação tem o propósito de relacionar o domínio do problema ao AG, calculando um *score* para cada indivíduo da população corrente. A implementação desta função exige certo cuidado, pois resume todo o conhecimento que se tem do problema, tais como restrições e objetivos (HAUPT, R.; HAUPT, S., 2004).

A primeira etapa para avaliação dos indivíduos é a obtenção da matriz de transição de estados com um sistema realimentado, $\phi(t)$, que será melhor detalhada no capítulo 4. Cada elemento de $\phi(t)$ é considerado como uma função de avaliação para os indivíduos. Portanto, são n^2 funções de avaliação para um sistema de ordem n .

Assim, os genes de cada indivíduo serão avaliados por todas as funções de avaliação, resultando nos valores de sobressinal e tempo de acomodação para cada função. Se todos os valores obtidos para o máximo sobressinal e tempo de acomodação ficarem abaixo dos especificados pelo projetista do controlador, então temos uma solução. Por outro lado, o indivíduo seria descartado caso forneça um sobressinal e/ou tempo de acomodação maior do que o previamente estabelecido para, ao menos, uma função de avaliação.

3.4.5 Método de Seleção

A seleção dos indivíduos para a reprodução afeta diretamente a robustez do algoritmo. Dependendo da forma com que esta for realizada, a convergência para a solução desejada poderá ocorrer com um número menor de gerações, ou poderá exigir mais tempo. Se a seleção escolhe apenas os indivíduos mais aptos, então a nova geração poderá perder algumas características favoráveis que, possivelmente, existiam em indivíduos que foram descartados. Já no caso de uma seleção ineficiente, onde há uma proliferação de características inadequadas, oriundas da presença de muitos indivíduos com baixa aptidão, tende a comprometer a eficácia de gerações futuras. Entre os métodos podemos citar a roleta viciada, a seleção com *ranking*, por torneio e a seleção elitista estão entre os mais utilizados pelos usuários de algoritmos genéticos (HAUPT, R.; HAUPT, S., 2004).

Em nosso trabalho, o método da roleta viciada foi o que mais se destacou em relação aos demais. Este método emprega o princípio da probabilidade de sobrevivência do mais apto, ou seja, que possui a melhor função objetiva associada (DE SOUZA, 2010). Com base nos valores de $f_i(x_i)$, onde x_i é o indivíduo i avaliado entre os n indivíduos amostrados.

Os indivíduos mais aptos são selecionados e duplicados em substituição aos menos aptos. Neste método, a probabilidade p_i do i -ésimo indivíduo da população vir a ser selecionado é dado pela Equação (28).

$$p_i = \frac{f_i}{\sum_{i=1}^n f_i} \quad (28)$$

Neste método, os indivíduos com alta aptidão recebem uma proporção maior na roleta e os indivíduos com baixa aptidão uma porção relativamente menor na roleta. Na Figura 8 estão dispostos 5 pais, A, B, C, D e E, com suas respectivas aptidões (áreas dos setores circulares), para serem selecionados através da roleta e gerarem uma nova população.

Observa-se que o indivíduo A tem maiores chances de ser escolhido ao rodar a roleta (ALCALÁ et al, 2003).




Figura 8 – Seleção de indivíduos através da roleta viciada

O ato de rodar a roleta deve ser completamente aleatório, podendo ser simulado escolhendo-se um número aleatório “ r ” no intervalo de $[0, 1]$ e comparar seu valor com a probabilidade acumulada q_i , considerando $q_0 = 0$, Equação (29). Assim, se $q_{i-1} < r < q_i$ deve-se selecionar o indivíduo x_i .

$$q_i = \sum_{k=0}^i p_k \quad (29)$$

Este método tem a desvantagem de possuir uma alta variância, podendo levar a um grande número de cópias de um bom cromossomo, diminuindo a diversidade da população, podendo causar uma convergência prematura do algoritmo para uma solução não almejada.

Quando a evolução está avançada, em que as aptidões não diferenciam entre si, pode causar uma estagnação do algoritmo, isto é, pouca modificação na seleção dos indivíduos.

Já a seleção elitista visa preservar os melhores cromossomos de uma geração para outra sem alterações, garantindo sempre que a melhor solução encontrada em qualquer uma das gerações seja mantida até o final do processo (DE SOUZA, 2010). A principal vantagem do elitismo é que a convergência é garantida, ou seja, se o máximo global for descoberto, o AG converge para este máximo, entretanto, da mesma forma existe o risco da estagnação em um máximo local.

3.4.6 Reprodução

Uma vez que o processo de seleção foi concluído, os operadores de reprodução, cruzamento e mutação, iniciam o processo de criação de uma nova população. O cruzamento é responsável pela troca de certas partes dos genes envolvidos, de maneira a reter características adequadas no novo indivíduo que está sendo gerado. A probabilidade de cruzamento indica com que frequência o operador de cruzamento ocorre (A.-HAJRI; ABIDO, 2009). A Figura 7 mostra detalhes da implementação, em pseudocódigo, do operador de cruzamento aritmético. O cruzamento aritmético utiliza dois números aleatórios e cria os filhos de acordo com as Equações (30) e (31) (OLIVEIRA, 2010, 2012).

$$newgene1 = prob1 \times gene1 + (1 - prob1) \times gene2 \quad (30)$$

$$newgene2 = (1 - prob2) \times gene1 + prob2 \times gene2 \quad (31)$$

Onde *newgene1* e *newgene2* são os genes criados do 1º e do 2º filho, ou seja, em nosso algoritmo a cada cruzamento aritmético, dois novos indivíduos são gerados e *prob1* e *prob2* são duas probabilidades entre 0 e 1. Cada um dos filhos gerados carrega as características dos dois indivíduos selecionados pela roleta viciada representados na Equação (30) e (31) por *gene1* e *gene2* respectivamente.

Embora o cruzamento seja o principal operador de reprodução, caso este fosse o único, o algoritmo poderia ficar retido na região de entorno de um máximo, ou mínimo local. Para permitir que a busca no espaço de soluções alcance outras áreas (e avalie soluções de melhor qualidade), é necessário utilizar o operador de mutação, que ocasionalmente altera, de maneira aleatória, o valor de alguma parte dos genes (A.-HAJRI; ABIDO, 2009).

O operador de mutação é aleatório e geralmente tem uma probabilidade fixa ao longo de toda a execução do algoritmo. Porém, existem algoritmos que mudam esta característica da mutação no decorrer das gerações, com a finalidade de além de sair de máximos ou mínimos locais, aumentar a diversidade da população quando se percebe uma queda nessa medida. Outra modificação nesse operador foi denominada de mutação dirigida, que consiste em direcionar em quais indivíduos o operador irá atuar, essa inovação pode trazer um tempo de convergência menor para o algoritmo e também evitar altas taxas de similaridade na população, no decorrer das gerações (LI; YE, 2006).

3.4.7 Critério de Parada

Nas execuções de todas as instâncias do algoritmo genético avaliado neste trabalho, existem dois possíveis critérios de parada:

- (i) quando uma solução é encontrada ou,
- (ii) quando o algoritmo atinge o limite de gerações.

4 ESTRATÉGIA DE CONTROLE PROPOSTA

A proposta deste trabalho visa controlar um sistema que é representado pelas equações no espaço de estados

$$\dot{x} = Ax + Bu \quad (32)$$

$$y = Cx + Du \quad (33)$$

Onde o método de controle é baseado em uma realimentação por estado observado que é dada por:

$$u = -K\tilde{x} \quad (34)$$

Como já foi dito anteriormente, a metodologia do projeto precisa de dois estágios, sendo que o primeiro busca a determinação da matriz K que produzirá o comportamento desejado. Esse comportamento desejado é fruto das especificações do sistema, definidas pelo projetista. Tempo de acomodação e máximo sobressinal, são as especificações básicas definidas pelo sistema. A Figura 9 ilustra estas especificações, onde M representa o máximo sobressinal, enquanto que t_s representa o tempo de acomodação. O máximo sobressinal é o valor máximo de pico da curva de resposta, medido a partir do valor Y_∞ , que é o valor final da resposta em regime permanente. O tempo de acomodação é o tempo necessário para que a curva de resposta alcance valores de mais ou menos 2% (tolerância aceitável), e permaneça nessa faixa indefinidamente.




Figura 9 - Curva de resposta temporal a uma entrada em degrau.




Figura 10 – Ganho K no plano complexo

A busca por um matriz K (Figura 10) ideal que atenda as especificações e limitações de projeto pode ser obtida a partir de um algoritmo genético desenvolvido em (OLIVEIRA, 2010, 2012), que supondo que o estado x seja mensurável, é possível reescrever a Equação (32) a partir de uma lei de controle que resolve a Equação (32) como:

$$\dot{x} = (A - BK)x \quad (35)$$

Com isso, a solução da Equação (35) de estado pode ser obtida da seguinte forma:

$$x(t) = \Phi(t)x(0) \quad (36)$$

Onde $\phi(t)$ representa a matriz de transição de estados que é dada como:

$$\Phi(t) = e^{(A-BK)t} = \mathcal{L}^{-1}[(sI - A + BK)^{-1}] \quad (37)$$

A matriz $\Phi(t)$ representa o comportamento temporal do sistema de acordo com os autovalores da matriz $(A - BK)$, ou seja, com a escolha correta da matriz K o sistema possivelmente será estável com os autovalores da matriz $(A - BK)$ no lado esquerdo do plano 's' e, se vier a acontecer distúrbios, o sistema será estabilizado à medida que o tempo t tender ao infinito.

O segundo estágio, que representa a proposta dessa dissertação, consiste na determinação da matriz de ganho K_e do observador que produzirá a equação do observador desejada. A matriz de ganho K_e pode ser determinada a partir da equação do erro do observador como segue

$$\dot{e} = (A - K_e C)e \quad (38)$$

Se a matriz $(A - K_e C)$ for uma matriz estável, o vetor de erro convergirá para zero, qualquer que seja o vetor de erro inicial $e(0)$. Ou seja, $\tilde{x}(t)$ convergirá para $x(t)$ independente do valor de $x(0)$ e $\tilde{x}(0)$. Portanto, a matriz K_e deve ser escolhida de tal maneira que o comportamento do vetor de erro seja assintoticamente estável e adequadamente rápido. Portanto, podemos especificar requisitos de desempenho, como os mostrados pelas Figura 9 e 10, tal qual aplicamos no processo descrito no primeiro estágio. Porém, é importante salientar que nas especificações de desempenho deste estágio, como máximo sobressinal e tempo de acomodação, o sistema deverá responder, pelo menos, duas a cinco vezes mais rápido que o sistema em malha fechada considerado no primeiro estágio.

Sendo assim, temos que a solução da Equação (38), utilizando a mesma abordagem, descrita anteriormente, pode ser encontrada da seguinte forma:

$$e(t) = \phi_e e(0) \quad (39)$$

$$\phi_e(t) = e^{(A - K_e C)t} = \mathcal{L}^{-1}[(sI - A + K_e C)^{-1}] \quad (40)$$

Para um sistema de ordem n , a matriz de transição de erro $\phi_e(t)$ assume a seguinte forma:

$$\phi_e(t) = \begin{bmatrix} \phi_{11}(t) & \phi_{12}(t) & \cdots & \phi_{1n}(t) \\ \phi_{21}(t) & \phi_{22}(t) & \cdots & \phi_{2n}(t) \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{n1}(t) & \phi_{n2}(t) & \cdots & \phi_{nn}(t) \end{bmatrix} \quad (41)$$

Em que todos os elementos de $\phi_e(t)$ são funções de elementos de K_e . Para um sistema com m saídas, a matriz K_e fica:

$$K_e = \begin{bmatrix} Ke_{11} & Ke_{12} & \cdots & Ke_{1m} \\ Ke_{21} & Ke_{22} & \cdots & Ke_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ Ke_{n1} & Ke_{n2} & \cdots & Ke_{nm} \end{bmatrix} \quad (42)$$

O AG tem a tarefa de buscar indivíduos da matriz K_e que satisfaçam as especificações de máximo sobressinal e tempo de acomodação.

Nessa última etapa avaliamos o comportamento que o indivíduo vencedor K_e provoca no sistema, identificando se as especificações de projeto continuam sendo atingidas para o máximo sobressinal e tempo de acomodação, especificados no primeiro estágio. Portanto, a Equação (16) precisa ser resolvida com os valores de K e de K_e .

O procedimento descrito até o presente momento foi utilizado para projetos de observadores de ordem plena. Caso o observador, seja considerado de ordem reduzida ou de

ordem mínima, teremos modificação a partir do segundo estágio. Portanto, a matriz de ganho K_e pode ser determinada a partir da equação do erro do observador de ordem mínima descrita da seguinte forma:

$$\dot{e} = (A_{bb} - K_e A_{ab})e \quad (43)$$

Cuja solução poderá ser obtida da seguinte forma:

$$e(t) = \Phi(t)e(0) \quad (44)$$

$$\Phi(t) = e^{(A_{bb} - K_e A_{ab})t} = \mathcal{L}^{-1}[(sI - A_{bb} + K_e A_{ab})^{-1}] \quad (45)$$

5 RESULTADOS

Como resultados deste trabalho, simulações computacionais foram feitas utilizando a ferramenta Matlab a fim de averiguar e comparar as melhorias de desempenho obtidas com o Algoritmo Genético Proposto. Nas simulações e na execução do AG foram utilizados dois computadores com sistema operacional Windows 7 64 bits com processador Intel® Core™ i5 1.80GHz. Este capítulo apresenta os resultados de desempenho obtidos para vários sistemas.

5.1 SISTEMAS DE ORDEM 2

Dois sistemas de 2ª ordem foram utilizados para simulação. Estes sistemas são completamente observáveis.

Sistema 1:

$$\dot{x} = \begin{bmatrix} -1 & -1 \\ 6.5 & 0 \end{bmatrix} x + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u, \quad y = [1 \quad 0]x \quad (46)$$

Sistema 2:

$$\dot{x} = \begin{bmatrix} 0 & 0.9 \\ -1 & -0.03 \end{bmatrix} x + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u, \quad y = [1 \quad 0]x \quad (47)$$

Em ambos os sistemas foram executados diferentes formas de inicialização para o AG. A Tabela 2 apresenta os modelos de inicialização que foram implementados totalizando 64 formas de inicialização. Além disso, foram testadas configurações distintas para o AG no qual se alterava a taxa de cruzamento, a taxa de mutação e a porcentagem de elitismo. A Tabela 3 apresenta cinco configurações que foram testadas para cada uma das diferentes formas de inicialização, totalizando 320 simulações para cada um dos sistemas.

Tabela 2. Inicializações do AG

População Inicial	Limites de valores	Máximo de gerações
10 indivíduos	10 e -10	10
50 indivíduos	20 e -20	50
100 indivíduos	50 e -50	100
200 indivíduos	100 e -100	200

As especificações de máximo sobressinal e tempo de acomodação foram aplicadas de tal forma a garantirem as mesmas especificações para sistema. Portanto, um tempo de acomodação de 2 segundos e um máximo de sobressinal de 10% foram utilizados como especificações de desempenho.

Tabela 3. Configurações do AG

Configurações	Taxa de cruzamento	Taxa de mutação	Percentual de elitismo
1	0,6	0,01	25%
2	0,6	0,1	25%
3	0,6	0,01	10%
4	0,9	0,01	25%
5	0,9	0,1	10%

5.1.1 Sistema 1

O sistema 1 possui a seguinte função de transferência:

$$G(s) = \frac{-1}{s^2 + s + 6,5} \quad (48)$$

O gráfico do lugar das raízes do sistema 1 é mostrado na Figura 11. Esse sistema não possui zeros, mas os polos em malha fechada são $-0,5 + 2,5i$ e $-0,5 - 2,5i$, todos no semiplano esquerdo caracterizando-o como um sistema de fase mínima. Podemos concluir também que o sistema 1 é do tipo condicionalmente estável, pois o sistema torna-se instável para valores de ganhos superiores a 6,5 ($K > 6,5$). O fato do sistema 1 ser condicionalmente estável, constitui um desafio para estratégia de controle na busca de soluções que permitam ao sistema manter sua estabilidade, além de atingir os índices de desempenho desejados.

Temos ainda que o coeficiente de amortecimentos dos polos a malha fechada é 0,2 ($\zeta = 0,2$) e a frequência natural não-amortecida dos pólos a malha fechada é 2,55 rad/s ($\omega_n = 2,55$). O que caracteriza um sistema subamortecido cujos polos são conjugados complexos.




Figura 11 – Lugar das raízes do Sistema 1

As Figura 12 e Figura 13 apresentam a resposta transitória do sistema 1 para entradas em degrau unitário e impulso unitário. Na resposta transitória ao degrau unitário percebe-se que o sistema 1 não converge para o valor do degrau, e sim para um valor de erro estacionário em torno de 1,15 negativo (Figura 12). O que representa outro desafio para a estratégia de controle deste trabalho fazer com que o sistema reduza ou elimine este erro estacionário.




Figura 12 – Resposta ao Degrau Unitário do Sistema 1

Já para resposta transitória ao impulso unitário (Figura 13), o sistema consegue retornar ao estado inicial atingindo um tempo de estabilização de 10 segundos com sobressinal de menor que 30%.




Figura 13 – Resposta ao Impulso Unitário do Sistema 1

Como podemos observar a partir das análises do gráfico do lugar das raízes (Figura 11) e das respostas transitórias para sinais em degrau unitário (Figura 12) e impulso unitário (Figura 13) percebe-se que o sistema 1 apresenta limitações para desenvolvimento de controladores. Porém a proposta do AG-observador é encontrar uma resposta satisfatória independente das limitações de controle do sistema, pois a condição básica para escolha de um sistema é que esse sistema seja completamente observável.


As Tabelas 4 e 5 apresentam alguns dos valores de matriz de ganho do observador K_e encontrados durante as simulações do AG-observador para o sistema 1. As Tabelas 4 e 5 apresentam também, a geração em que a matriz de ganho do observador foi encontrada, bem como o tempo de execução que o AG-observador levou para encontrar o indivíduo e os índices de desempenho de cada variável de estado. E as Figuras, 14, 15, 16, 17, 18 e 19 apresentam gráficos de resposta temporal à condição inicial destes indivíduos K_e simulados para o observador.

Tabela 4. Matrizes de ganho do observador do Sistema 1

Matriz de Ganho do Observador	$K_e = \begin{bmatrix} 6,6053 \\ -9,3399 \end{bmatrix}$	$K_e = \begin{bmatrix} 5,2181 \\ -5,4194 \end{bmatrix}$	$K_e = \begin{bmatrix} 6,8825 \\ -14,2927 \end{bmatrix}$
Geração	10 ^a	50 ^a	10 ^a
Tempo de simulação	2,3355s	4,1891s	4,6184s
Máximo Sobressinal	$x_1 = 21,7\%$ $x_2 = 127\%$	$x_1 = 24,2\%$ $x_2 = 112\%$	$x_1 = 23\%$ $x_2 = 158\%$
Tempo de acomodação	$x_1 = 1,58s$ $x_2 = 1,88s$	$x_1 = 1,74s$ $x_2 = 1,82s$	$x_1 = 1,26s$ $x_2 = 1,70s$

Tabela 5. Matrizes de ganho do observador do Sistema 1

Matriz de Ganho do Observador	$K_e = \begin{bmatrix} 8,2629 \\ -16,5856 \end{bmatrix}$	$K_e = \begin{bmatrix} 10,8724 \\ -38,5599 \end{bmatrix}$	$K_e = \begin{bmatrix} 15,8098 \\ -69,0811 \end{bmatrix}$
Geração	100 ^a	50 ^a	10 ^a
Tempo de simulação	11,1942s	5,6042s	2,3663s
Máximo Sobressinal	$x_1 = 20,2\%$ $x_2 = 157\%$	$x_1 = 20,2\%$ $x_2 = 240\%$	$x_1 = 17,4\%$ $x_2 = 301\%$
Tempo de acomodação	$x_1 = 1,31s$ $x_2 = 1,62s$	$x_1 = 0,87s$ $x_2 = 0,93s$	$x_1 = 0,72s$ $x_2 = 0,95s$

Figura 14 – Resposta temporal do observador para matriz K_e do Sistema 1




Figura 15 – Resposta temporal do observador para matriz K_e do Sistema 1




Figura 16 – Resposta temporal do observador para matriz K_e do Sistema 1




Figura 17 – Resposta temporal do observador para matriz K_e do Sistema 1




Figura 18 – Resposta temporal do observador para matriz K_e do Sistema 1




Figura 19 – Resposta temporal do observador para matriz K_e do Sistema 1

Importante destacar que em todas as simulações, independente da forma de inicialização (Tabela 3) e da forma de configuração do AG-observador (Tabela 4), não foi possível encontrar um indivíduo (matriz K_e) que atendesse todos os requisitos de sistema pré-estabelecidos para máximo sobressinal (que era de 10%) e para tempo de acomodação (que era de 2 segundos). Isso pode ser verificado observando as Figuras 14, 15, 16, 17, 18 e 19, e as Tabelas 4 e 5 em que o máximo sobressinal para variável x_2 , nunca atende as especificações do sistema. Isso se deve ao fato do sistema 1 ser condicionalmente estável, ou seja, alguns valores de ganho tornam o sistema instável, o que limita e dificulta o espaço de busca do AG em encontrar uma resposta satisfatória que atendesse todos os requisitos especificados.

Seguindo a proposta do trabalho, foram realizadas simulações com o AG-controlador desenvolvido por (OLIVEIRA, 2010, 2012), no qual identificamos e selecionamos indivíduos K da matriz de ganho do controlador (OLIVEIRA, 2010, 2012). A partir dessas matrizes de ganho K foram realizadas simulações com o AG-controlador para observarmos a resposta temporal e se os índices de desempenho especificados (Máximo sobressinal: $M_p = 20\%$; Tempo de acomodação: $t_s = 5s$) eram atingidos. Relembrando que no projeto de

observadores de estado que atuem com controladores, os requisitos de desempenho, deverão ser de duas a cinco vezes menor do que o controlador de tal forma a fazer com que sistema continue atendendo os requisitos de desempenho definidos pelo controlador.

Aplicando a Equação (16) produzimos a função transferência controlador-observador. A resposta transitória desta função controlador-observador pode ser comparada com as outras curvas de resposta transitória (a do AG-controlador e a do AG-observador). As Figuras 20, 21 e 22 apresentam curvas de respostas transitórias do AG-controlador, do AG-observador e do Controlador-Observador.




Figura 20 – Curvas de Resposta Transitória do Sistema 1a

A Tabela 6 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador), utilizadas para gerar as curvas de resposta transitória da Figura 20.

Tabela 6. Matrizes de Ganho K e K_e do Sistema 1a

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [0, 5567 \quad 5, 4222]$	$K_e = \begin{bmatrix} 5,2181 \\ -5,4194 \end{bmatrix}$

Tabela 7. Desempenhos das curvas transitórias do Sistema 1a

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 0,6\%$ $x_2 = 0,7\%$	$x_1 = 1,49s$ $x_2 = 1,79s$
AG-Observador	$x_1 = 16\%$ $x_2 = 73\%$	$x_1 = 1,39s$ $x_2 = 1,37s$
Controlador-Observador	$x_1 = 2,8\%$ $x_2 = 19\%$	$x_1 = 0,80s$ $x_2 = 0,77s$




Figura 21 - Curvas de Resposta Transitória do Sistema 1b.

A Tabela 8 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador), utilizadas para gerar as curvas de resposta transitória da Figura 21.

Tabela 8. Matrizes de Ganho K e K_e do Sistema 1b.

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [2,3630 \quad 4,0459]$	$K_e = \begin{bmatrix} 5,2181 \\ -5,4194 \end{bmatrix}$

Tabela 9. Desempenhos das curvas transitórias do Sistema 1b

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 0,05\%$ $x_2 = 0,03\%$	$x_1 = 1,26s$ $x_2 = 1,71s$
AG-Observador	$x_1 = 16\%$ $x_2 = 73\%$	$x_1 = 1,39s$ $x_2 = 1,37s$
Controlador-Observador	$x_1 = 4,5\%$ $x_2 = 20\%$	$x_1 = 0,93s$ $x_2 = 0,90s$




Figura 22 - Curvas de Resposta Transitória do Sistema 1c.

A Tabela 10 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador), utilizadas para gerar as curvas de resposta transitória da Figura 22.

Tabela 10. Matrizes de Ganho K e K_e do Sistema 1c

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [-1,3624 \quad 6,2939]$	$K_e = \begin{bmatrix} 5,2181 \\ -5,4194 \end{bmatrix}$

Tabela 11. Desempenhos das curvas transitórias do Sistema 1c

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 0,07\%$ $x_2 = 0,05\%$	$x_1 = 1,44s$ $x_2 = 1,73s$
AG-Observador	$x_1 = 16\%$ $x_2 = 73\%$	$x_1 = 1,39s$ $x_2 = 1,37s$
Controlador-Observador	$x_1 = 2,2\%$ $x_2 = 22\%$	$x_1 = 0,73s$ $x_2 = 0,72s$

Analizando as Figuras 20, 21 e 22 e suas respectivas tabelas de desempenhos (Tabelas 7, 9 e 11) percebe-se que o AG-Controlador atende todos os requisitos de desempenho (Máximo sobressinal: $M_p = 20\%$; Tempo de acomodação: $t_s = 5s$), enquanto que o AG-Observador não consegue atingir um dos índices de desempenho que o máximo sobressinal menor que 10% para a variável de estado x_2 . Porém, o tempo de acomodação de 2s é sempre atingido, algo já percebido quando analisamos as Figuras de resposta transitória 14, 15, 16, 17, 18 e 19.

Quando analisamos a função transferência Controlador-Observador percebe-se que a resposta do sistema melhora, ou seja, os índices de desempenho são sempre melhorados. Os tempos de acomodação do sistema ficaram menores que 1s em todas as curvas de controlador-observador quando comparadas, tanto com as curvas do AG-controlador, como com as curvas do AG-observador. Os máximos sobressinais das curvas controlador-observador são melhores quando comparadas somente com o AG-observador, e inclusive, a variável x_1 do sistema atinge os índices de desempenho para máximo sobressinal ($M_p < 10\%$). Porém, a variável x_2 continua com máximo sobressinal acima do especificado.

5.1.2 Sistema 2

O sistema 2 possui a seguinte função de transferência:

$$G(s) = \frac{0,9}{s^2 + 0,03s + 0,9} \quad (49)$$

O gráfico do lugar das raízes do sistema 2 é mostrado na Figura 23. O sistema 2, assim como o sistema 1, não possui zeros, mas os polos em malha fechada são $-0,015 + 0,95i$ e

$-0,015 - 0,95i$, todos no semiplano esquerdo caracterizando-o como um sistema de fase mínima próximos a origem.

Temos ainda que o coeficiente de amortecimentos dos polos a malha fechada é 0,158 ($\zeta = 0,158$) e a frequência natural não-amortecida dos pólos a malha fechada é 0,95 rad/s ($\omega_n = 0,95$). O que caracteriza um sistema subamortecido cujos polos são conjugados complexos.




Figura 23 - Lugar das raízes do Sistema 2

As Figuras 24 e 25 apresentam a resposta transitória do sistema 2 para entradas em degrau unitário e em impulso unitário, respectivamente. Na resposta transitória ao degrau unitário percebe-se que o sistema 2 converge para o valor do degrau em aproximadamente 350 segundos, zerando o erro estacionário, porém com bastante oscilação e atingindo um sobressinal maior que 90%. Já para resposta transitória ao impulso unitário (Figura 25), o sistema apresenta o mesmo comportamento obtido para entrada em degrau. O sistema 2, em relação ao sistema 1, apresenta condições melhores para o desenvolvimento da nossa estratégia de controle, pois não possui valores de ganho que o tornem instável, o que favorece o nosso espaço de busca e de possibilidades de respostas que venham a atender aos requisitos de desempenho.

Outro fator que favorece a estratégia de controle proposta é fato de como os polos do sistema 2 estão próximos a origem (Figura 23), o sistema é bastante estável, apesar de ser

bastante oscilatório, o que contribui significativamente para a estabilidade do sistema e obtenção dos requisitos de sistema.




Figura 24 - Resposta ao Degrau Unitário do Sistema 2




Figura 25 - Resposta ao Impulso Unitário do Sistema 2

As Tabelas 12 e 13 apresentam alguns dos valores de matriz de ganho do observador K_e encontrados durante as simulações do AG para o sistema 2. As tabelas 12 e 13 apresentam também, a geração em que a matriz de ganho do observador foi encontrada, bem como o tempo de execução que o AG levou para encontrar o indivíduo e os índices de desempenho de cada variável de estado. E as Figuras 26, 27, 28, 29, 30 e 31 apresentam gráficos de resposta temporal à condição inicial destes indivíduos K_e simulados para o observador.

Tabela 12. Matrizes de ganho do observador do Sistema 2

Matriz de Ganho do Observador	$K_e = \begin{bmatrix} 3,6192 \\ 1,7774 \end{bmatrix}$	$K_e = \begin{bmatrix} 4,6242 \\ 7,7928 \end{bmatrix}$	$K_e = \begin{bmatrix} 15,2019 \\ 13,3468 \end{bmatrix}$
Geração	4 ^a	4 ^a	3 ^a
Tempo de simulação	0,4183s	0,4407s	0,1992s
Máximo Sobressinal	$x_1 = 0,11\%$ $x_2 = 0,62\%$	$x_1 = 9,19\%$ $x_2 = 69,4\%$	$x_1 = 0,02\%$ $x_2 = 0,3\%$
Tempo de acomodação	$x_1 = 1,55s$ $x_2 = 1,31s$	$x_1 = 1,96s$ $x_2 = 1,94s$	$x_1 = 0,32s$ $x_2 = 0,29s$

Tabela 13. Matrizes de ganho do observador do Sistema 2

Matriz de Ganho do Observador	$K_e = \begin{bmatrix} 36,5698 \\ 34,7737 \end{bmatrix}$	$K_e = \begin{bmatrix} 58,6585 \\ 57,9421 \end{bmatrix}$	$K_e = \begin{bmatrix} 78,2316 \\ 80,5916 \end{bmatrix}$
Geração	3 ^a	1 ^a	3 ^a
Tempo de simulação	0,2742s	0,0541s	0,2473s
Máximo Sobressinal	$x_1 = 0,01\%$ $x_2 = 0,3\%$	$x_1 = 0,03\%$ $x_2 = 1,9\%$	$x_1 = 0,06\%$ $x_2 = 5,11\%$
Tempo de acomodação	$x_1 = 0,12s$ $x_2 = 0,12s$	$x_1 = 0,07s$ $x_2 = 0,81s$	$x_1 = 0,05s$ $x_2 = 1,77s$




Figura 26 – Resposta temporal do observador para matriz K_e do Sistema 2




Figura 27 – Resposta temporal do observador para matriz K_e do Sistema 2




Figura 28 – Resposta temporal do observador para matriz K_e do Sistema 2




Figura 29 – Resposta temporal do observador para matriz K_e do Sistema 2




Figura 30 – Resposta temporal do observador para matriz K_e do Sistema 2




Figura 31 – Resposta temporal do observador para matriz K_e do Sistema 2

Importante destacar que em todas as simulações, independente da forma de inicialização (Tabela 3) e da forma de configuração do AG (Tabela 4), sempre foi possível encontrar um indivíduo (matriz K_e) que atendesse todos os requisitos de sistema pré-estabelecidos para máximo sobressinal (que era de 10%) e para tempo de acomodação (que era de 2 segundos). Isso pode ser verificado observando as Figuras 26, 27, 28, 29, 30 e 31 e as tabelas 12 e 13 em que tanto o máximo sobressinal como os tempos de acomodação atendem os requisitos do sistema. Como o sistema 2 possui pólos complexos conjugados próximos a origem, é sempre estável para qualquer valores de ganho em malha fechada, temos que a possibilidade de respostas que atendem aos requisitos de sistema é simples de ser atingida.

Seguindo a proposta do trabalho, foram realizadas simulações com o AG-controlador desenvolvido por (OLIVEIRA, 2010, 2012), no qual identificamos e selecionamos indivíduos K da matriz de ganho do controlador (OLIVEIRA, 2010, 2012). A partir dessas matrizes de ganho K foram realizadas simulações com o AG-controlador para observarmos a resposta temporal e se os índices de desempenho especificados (Máximo sobressinal: $M_p = 10\%$; Tempo de acomodação: $t_s = 2s$) eram atingidos.

Aplicando a Equação (16) produzimos a função transferência controlador-observador. A resposta transitória desta função controlador-observador pode ser comparada com as outras curvas de resposta transitória (a do AG-controlador e a do AG-observador). As Figuras 32, 33 e 34 apresentam curvas de respostas transitórias do AG-controlador, do AG-observador e do Controlador-Observador.




Figura 32 - Curvas de Resposta Transitória do Sistema 2a

A Tabela 14 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 32.

Tabela 14. Matrizes de Ganho K e K_e do Sistema 2a

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [3,2248 \quad 3,2377]$	$K_e = \begin{bmatrix} 58,6585 \\ 57,9421 \end{bmatrix}$

Tabela 15. Desempenhos das curvas transitórias do Sistema 2a

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 7\%$ $x_2 = 95\%$	$x_1 = 2,39s$ $x_2 = 2,50s$
AG-Observador	$x_1 = 0,06\%$ $x_2 = 4,5\%$	$x_1 = 0,07s$ $x_2 = 0,89s$
Controlador-Observador	$x_1 = 0,11\%$ $x_2 = 9,3\%$	$x_1 = 0,07s$ $x_2 = 0,62s$




Figura 33 - Curvas de Resposta Transitória do Sistema 2b

A Tabela 16 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 33.

Tabela 16. Matrizes de Ganho K e K_e do Sistema 2b

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [3,2248 \quad 3,2377]$	$K_e = \begin{bmatrix} 78,2316 \\ 80,5916 \end{bmatrix}$

Tabela 17. Desempenhos das curvas transitórias do Sistema 2b

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 7\%$ $x_2 = 95\%$	$x_1 = 2,39s$ $x_2 = 2,50s$
AG-Observador	$x_1 = 0,07\%$ $x_2 = 7\%$	$x_1 = 0,05s$ $x_2 = 1,06s$
Controlador-Observador	$x_1 = 0,10\%$ $x_2 = 10,5\%$	$x_1 = 0,05s$ $x_2 = 0,62s$




Figura 34 - Curvas de Resposta Transitória do Sistema 2c

A Tabela 18 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 34.

Tabela 18. Matrizes de Ganho K e K_e do Sistema 2c

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [3,9746 \quad 3,7346]$	$K_e = \begin{bmatrix} 58,6585 \\ 57,9421 \end{bmatrix}$

Tabela 19. Desempenhos das curvas transitórias do Sistema 3c

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 6\%$ $x_2 = 99\%$	$x_1 = 2,50s$ $x_2 = 2,50s$
AG-Observador	$x_1 = 0,06\%$ $x_2 = 4,5\%$	$x_1 = 0,07s$ $x_2 = 0,89s$
Controlador-Observador	$x_1 = 0,12\%$ $x_2 = 10,5\%$	$x_1 = 0,07s$ $x_2 = 0,59s$

Analizando as Figuras 32, 33 e 34 e suas respectivas tabelas de desempenho (Tabelas 15, 17 e 19) percebe-se que o AG-Controlador não atende todos requisitos de desempenho (Máximo sobressinal: $M_p = 10\%$; Tempo de acomodação: $t_s = 2s$), especificamente a variável de estado x_2 , em que tanto o máximo sobressinal (maior que 10%) quanto o tempo de acomodação (maior que 2s) não são atingidos. Por outro lado o AG-Observador consegue atingir os índices de desempenho para máximo sobressinal (menor que 10%) e para tempo de acomodação (menor que 2s).

Quando analisamos a função transferência Controlador-Observador percebe-se que a resposta do sistema melhora, ou seja, os índices de desempenho para qualquer umas variáveis de estado são sempre atingidos. Os tempos de acomodação do sistema ficaram menores que 1s em todas as curvas de controlador-observador (Tabelas 15, 17 e 19) quando comparadas tanto com as curvas do AG-controlador como com as curvas do AG-observador. Os máximos sobressinais das curvas controlador-observador também encontram-se dentro dos requisitos do sistema.

Comparando os dois sistemas de 2ª ordem, no qual apresentavam dinâmicas bem distintas, percebe-se que integração do observador com o controlador, em ambos os sistemas, contribuíram para melhoria dos requisitos dos sistemas.

5.2 SISTEMAS DE ORDEM 3

Dois sistemas de 3ª ordem foram utilizados para simulação. Estes sistemas são completamente observáveis.

Sistema 3:

$$\dot{x} = \begin{bmatrix} -5 & 10 & 0 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} x + \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} u, \quad y = [1 \quad 0 \quad 0]x \quad (50)$$

Sistema 4:

$$\dot{x} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ -10 & -5 & -6 \end{bmatrix} x + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} u, \quad y = [1 \quad 0 \quad 0]x \quad (51)$$

Em ambos os sistemas foram executados diferentes formas de inicialização para o AG. A Tabela 2 apresenta os modelos de inicialização que foram implementados totalizando 64 formas de inicialização. Além disso, foram testadas configurações distintas para o AG no qual se alterava a taxa de cruzamento, a taxa de mutação e a porcentagem de elitismo. A Tabela 3 apresenta cinco configurações que foram testadas para cada uma das diferentes formas de inicialização, totalizando 320 simulações para cada um dos sistemas.

As especificações de máximo sobressinal e tempo de acomodação foram aplicadas de tal forma a garantirem as mesmas especificações para sistema. Portanto, um tempo de acomodação de 2 segundos e um máximo de sobressinal de 10% foram utilizados como especificações de desempenho.

5.2.1 – Sistema 3

O sistema 3 possui a seguinte função de transferência:

$$G(s) = \frac{10s + 10}{s^3 + 6s^2 + 5s + 10} \quad (52)$$

O gráfico do lugar das raízes do sistema 3 é mostrado na Figura 35. O sistema 3 possui um zero em -1 e três polos: um no eixo real em -5,4 e dois pólos complexos conjugados em $-0,29 + 1,33i$ e $-0,29 - 1,33i$, todos no semiplano esquerdo caracterizando-o como um sistema de fase mínima. Podemos concluir também que o sistema 3 se mantém estável quando o ganho K tende ao infinito.




Figura 35 – Lugar da raízes do Sistema 3

As Figuras 36, 37 e 38 apresentam a resposta transitória do sistema 3 para entradas em degrau unitário, impulso unitário e rampa unitária respectivamente. Na resposta transitória ao degrau unitário (Figura 36) percebe-se que o sistema 1 converge para o valor do degrau em aproximadamente 15 segundos com um máximo sobressinal acima de 150%.




Figura 36 – Resposta ao Degrau unitário do Sistema 3

Comportamento idêntico ao do degrau unitário ocorre para resposta transitória ao impulso unitário (Figura 37). O sistema 3 consegue retornar ao estado inicial atingindo um tempo de estabilização de 14 segundos com sobressinal de maior que 150%.




Figura 37 – Resposta ao Impulso Unitário do Sistema 3

Quanto a rampa unitária (Figura 38), percebe-se que o sistema 3 atinge a estabilidade para um tempo superior a 30 minutos.




Figura 38 – Resposta a Rampa unitária do Sistema 3

A Tabela 20 apresenta alguns dos valores de matriz de ganho do observador K_e encontrados durante as simulações do AG para o sistema 3. A Tabela 20 apresenta também, a geração em que a matriz de ganho do observador foi encontrada, bem como o tempo de execução que o AG levou para encontrar o indivíduo e os índices de desempenho de cada variável de estado dos indivíduos encontrados. E as Figuras 39, 40, 41 e 42 apresentam gráficos de resposta temporal à condição inicial destes indivíduos K_e simulados para o observador.

Tabela 20. Matrizes de ganho do observador do Sistema 3

Matriz de Ganho do Observador	$K_e = \begin{bmatrix} 8,4099 \\ 6,5906 \\ 7,5117 \end{bmatrix}$	$K_e = \begin{bmatrix} 7,6188 \\ 5,6891 \\ 6,6961 \end{bmatrix}$	$K_e = \begin{bmatrix} 20,3889 \\ 16,9109 \\ 18,0346 \end{bmatrix}$	$K_e = \begin{bmatrix} 24,0705 \\ 20,8579 \\ 21,7704 \end{bmatrix}$
Geração	6 ^a	12 ^a	44 ^a	5 ^a
Tempo de simulação	0,5795s	2,6451s	508,2670s	3,5459s
Máximo Sobressinal	$x_1 = 1,62\%$ $x_2 = 3,34\%$ $x_3 = 2,21\%$	$x_1 = 1,24\%$ $x_2 = 2,51\%$ $x_3 = 2,62\%$	$x_1 = 0,49\%$ $x_2 = 1,84\%$ $x_3 = 2,55\%$	$x_1 = 0,59\%$ $x_2 = 2,44\%$ $x_3 = 2,02\%$
Tempo de acomodação	$x_1 = 0,68s$ $x_2 = 0,65s$ $x_3 = 0,54s$	$x_1 = 0,69s$ $x_2 = 0,67s$ $x_3 = 0,68s$	$x_1 = 0,21s$ $x_2 = 0,34s$ $x_3 = 0,44s$	$x_1 = 0,17s$ $x_2 = 0,33s$ $x_3 = 0,29s$




Figura 39 - Resposta temporal do observador para matriz K_e do Sistema 3




Figura 40 - Resposta temporal do observador para matriz K_e do Sistema 3




Figura 41 - Resposta temporal do observador para matriz K_e do Sistema 3




Figura 42 - Resposta temporal do observador para matriz K_e do Sistema 3

Importante destacar que em todas as simulações, independente da forma de inicialização (Tabela 3) e da forma de configuração do AG (Tabela 4), sempre foi possível encontrar um indivíduo (matriz K_e) que atendesse todos os requisitos de sistema pré-estabelecidos para máximo sobressinal (que era de 10%) e para tempo de acomodação (que era de 2 segundos). Isso pode ser verificado observando as Figuras 39, 40, 41 e 42 e a Tabela 20 em que tanto o máximo sobressinal como os tempos de acomodação atendem os requisitos do sistema. Como o sistema 3 é sempre estável para qualquer valores de ganho em malha fechada, temos que a possibilidade de respostas que atendem aos requisitos de sistema é simples de ser atingida.

Seguindo a proposta do trabalho, foram realizadas simulações com o AG-controlador desenvolvido por (OLIVEIRA, 2010, 2012), no qual identificamos e selecionamos indivíduos K da matriz de ganho do controlador (OLIVEIRA, 2010, 2012). A partir dessas matrizes de ganho K foram realizadas simulações com o AG-controlador para observarmos a resposta temporal e se os índices de desempenho especificados (Máximo sobressinal: $M_p = 10\%$; Tempo de acomodação: $t_s = 2s$) eram atingidos.

Aplicando a Equação (16) produzimos a função transferência controlador-observador. A resposta transitória desta função controlador-observador pode ser comparada com as outras curvas de resposta transitória (a do AG-controlador e a do AG-observador). As Figuras 43, 44 e 45 apresentam curvas de respostas transitórias do AG-controlador, do AG-observador e do Controlador-Observador.




Figura 43 – Curva de Resposta Transitória do Sistema 3a

A Tabela 21 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 43 – Curva de Resposta Transitória do Sistema 3a.

Tabela 21. Matrizes de Ganho K e K_e do Sistema 3a

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [-0,6676 \quad 9,8896 \quad 6,2118]$	$K_e = \begin{bmatrix} 7,6188 \\ 5,6891 \\ 6,6961 \end{bmatrix}$

Tabela 22. Desempenhos das curvas transitórias do Sistema 3a

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 19\%$	$x_1 = 3,49s$
	$x_2 = 11\%$	$x_2 = 2,79s$
	$x_3 = 1,4\%$	$x_2 = 2,72s$
AG-Observador	$x_1 = 2,5\%$	$x_1 = 0,61s$
	$x_2 = 6,3\%$	$x_2 = 0,54s$
	$x_3 = 6,4\%$	$x_2 = 0,55s$
Controlador-Observador	$x_1 = 0,08\%$	$x_1 = 0,31s$
	$x_2 = 4,5\%$	$x_2 = 0,33s$
	$x_3 = 4,6\%$	$x_2 = 0,33s$




Figura 44 - Curva de Resposta Transitória do Sistema 3b

A Tabela 23 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 44.

Tabela 23. Matrizes de Ganho K e K_e do Sistema 3b

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [-1,7311 \quad 9,9465 \quad 6,8224]$	$K_e = \begin{bmatrix} 24,0705 \\ 20,8579 \\ 21,7704 \end{bmatrix}$

Tabela 24. Desempenhos das curvas transitórias do Sistema 3b

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 23,3\%$	$x_1 = 2,99s$
	$x_2 = 13,4\%$	$x_2 = 2,49s$
	$x_3 = 0,16\%$	$x_2 = 2,03s$
AG-Observador	$x_1 = 1,2\%$	$x_1 = 0,38s$
	$x_2 = 5,4\%$	$x_2 = 0,37s$
	$x_3 = 5\%$	$x_2 = 0,39s$
Controlador-Observador	$x_1 = 0,6\%$	$x_1 = 0,17s$
	$x_2 = 7\%$	$x_2 = 0,24s$
	$x_3 = 6,6\%$	$x_2 = 0,26s$




Figura 45 - Curva de Resposta Transitória do Sistema 3c

A Tabela 25 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 45.

Tabela 25. Matrizes de Ganho K e K_e do Sistema 3c

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [-1,7311 \quad 9,9465 \quad 6,8224]$	$K_e = \begin{bmatrix} 7,6188 \\ 5,6891 \\ 6,6961 \end{bmatrix}$

Tabela 26. Desempenhos das curvas transitórias do Sistema 3c

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 23,3\%$	$x_1 = 2,99s$
	$x_2 = 13,4\%$	$x_2 = 2,49s$
	$x_3 = 0,16\%$	$x_2 = 2,03s$
AG-Observador	$x_1 = 2,5\%$	$x_1 = 0,61s$
	$x_2 = 6,3\%$	$x_2 = 0,54s$
	$x_3 = 6,4\%$	$x_2 = 0,55s$
Controlador-Observador	$x_1 = 0\%$	$x_1 = 0,33s$
	$x_2 = 3,03\%$	$x_2 = 0,32s$
	$x_3 = 3,1\%$	$x_2 = 0,32s$

Analisando as Figuras 43, 44 e 45 e suas respectivas tabelas de desempenho (Tabelas 22, 24 e 26) percebe-se que o AG-Controlador não atende todos requisitos de desempenho (Máximo sobressinal: $M_p = 10\%$; Tempo de acomodação: $t_s = 2s$), especificamente as variáveis de estado x_1 e x_2 , em que tanto o máximo sobressinal (maior que 10%) quanto o tempo de acomodação (maior que 2s) não são atingidos. Por outro lado o AG-Observador consegue atingir os índices de desempenho para máximo sobressinal (menor que 10%) e para tempo de acomodação (menor que 2s).

Quando analisamos a função transferência Controlador-Observador percebe-se que a resposta do sistema melhora, ou seja, os índices de desempenho para qualquer umas variáveis de estado são sempre atingidos. Os tempos de acomodação do sistema ficaram menores que 1s em todas as curvas de controlador-observador (Tabelas 22, 24 e 26) quando comparadas tanto com as curvas do AG-controlador como com as curvas do AG-observador. Os máximos sobressinais das curvas controlador-observador também encontram-se dentro dos requisitos do sistema.

5.2.2 – Sistema 4

O sistema 4 possui a seguinte função de transferência:

$$G(s) = \frac{1}{s^3 + 6s^2 + 5s + 10} \quad (53)$$

O gráfico do lugar das raízes do sistema 4 é mostrado na Figura 46. O sistema 4 não possui zeros, mas possui três polos: um no eixo real em -5,4 e dois pólos complexos conjugados em $-0,29 + 1,33i$ e $-0,29 - 1,33i$, todos no semiplano esquerdo caracterizando-o como um sistema de fase mínima. Podemos concluir também que o sistema 4 é do tipo condicionalmente estável, pois o sistema torna-se instável para valores de ganhos superiores a 20 ($K > 20$).




Figura 46 – Lugar das raízes do Sistema 4

As Figuras 47, 48 e 49 apresentam a resposta transitória do sistema 4 para entradas em degrau unitário, impulso unitário e rampa unitária respectivamente. Na resposta transitória ao degrau unitário percebe-se que o sistema 4 não converge para o valor do degrau apresentando um erro estacionário de 0,9 e um tempo de acomodação de aproximadamente 14 segundos.




Figura 47 – Resposta ao Degrau unitário do Sistema 4

Já para resposta transitória ao impulso unitário (Figura 48), o sistema 4 apresenta um tempo de acomodação de 14 segundos e um máximo sobressinal menor que 10%.




Figura 48 – Resposta ao Impulso unitário do Sistema 4

Quanto resposta transitória a rampa unitária (Figura 49), o sistema 4 apresenta erro estacionário.




Figura 49 – Resposta a Rampa unitária do Sistema 4

A Tabela 27 apresenta alguns dos valores de matriz de ganho do observador K_e encontrados durante as simulações do AG para o sistema 4. A Tabela 27 apresenta também, a geração em que a matriz de ganho do observador foi encontrada, bem como o tempo de

execução que o AG levou para encontrar o indivíduo e os índices de desempenho de cada variável de estado dos indivíduos encontrados. E as Figuras 50, 51, 52 e 53 apresentam gráficos de resposta temporal à condição inicial destes indivíduos K_e simulados para o observador.

Tabela 27. Matrizes de ganho do observador do Sistema 3

Matriz de Ganho do Observador	$K_e = \begin{bmatrix} 11,3315 \\ 11,8900 \\ -12,5328 \end{bmatrix}$	$K_e = \begin{bmatrix} 10,0270 \\ 9,6770 \\ -9,5749 \end{bmatrix}$	$K_e = \begin{bmatrix} 43,5847 \\ 42,7872 \\ 25,2312 \end{bmatrix}$	$K_e = \begin{bmatrix} 43,4507 \\ 46,9287 \\ -6,0753 \end{bmatrix}$
Geração	26 ^a	15 ^a	2 ^a	37 ^a
Tempo de simulação	75,9482s	95,0661s	3,51s	75,9282s
Máximo Sobressinal	$x_1 = 0,02\%$ $x_2 = 0,54\%$ $x_3 = 0\%$	$x_1 = 0,05\%$ $x_2 = 0,66\%$ $x_3 = 2,77\%$	$x_1 = 0\%$ $x_2 = 0,07\%$ $x_3 = 4,77\%$	$x_1 = 0\%$ $x_2 = 2,35\%$ $x_3 = 1,20\%$
Tempo de acomodação	$x_1 = 0,43s$ $x_2 = 0,33s$ $x_3 = 0,78s$	$x_1 = 0,5s$ $x_2 = 0,46s$ $x_3 = 0,61s$	$x_1 = 0,1s$ $x_2 = 0,15s$ $x_3 = 0,44s$	$x_1 = 0,1s$ $x_2 = 1,08s$ $x_3 = 1,13s$




Figura 50 - Resposta temporal do observador para matriz K_e do Sistema 4




Figura 51 - Resposta temporal do observador para matriz K_e do Sistema 4




Figura 52 - Resposta temporal do observador para matriz K_e do Sistema 4




Figura 53 - Resposta temporal do observador para matriz K_e do Sistema 4

Importante destacar que em todas as simulações, independente da forma de inicialização (Tabela 3) e da forma de configuração do AG (Tabela 4), sempre foi possível encontrar um indivíduo (matriz K_e) que atendesse todos os requisitos de sistema pré-estabelecidos para máximo sobressinal (que era de 10%) e para tempo de acomodação (que era de 2 segundos). Isso pode ser verificado observando as Figuras 50, 51, 52 e 53 e a Tabela 27 em que tanto o máximo sobressinal como os tempos de acomodação atendem os requisitos do sistema. Mesmo com o sistema 4 é sendo condicionalmente estável, foram obtidos resultados distintos quando comparados ao sistema 1 de 2ª ordem que também era condicionalmente estável.

Seguindo a proposta do trabalho, foram realizadas simulações com o AG-controlador desenvolvido por (OLIVEIRA, 2010, 2012), no qual identificamos e selecionamos indivíduos K da matriz de ganho do controlador (OLIVEIRA, 2010, 2012). A partir dessas matrizes de ganho K foram realizadas simulações com o AG-controlador para observarmos a resposta temporal e se os índices de desempenho especificados (Máximo sobressinal: $M_p = 10\%$; Tempo de acomodação: $t_s = 2s$) eram atingidos.

Aplicando a Equação (16) produzimos a função transferência controlador-observador. A resposta transitória desta função controlador-observador pode ser comparada com as outras curvas de resposta transitória (a do AG-controlador e a do AG-observador). As Figuras 54, 55 e 56 apresentam curvas de respostas transitórias do AG-controlador, do AG-observador e do Controlador-Observador.




Figura 54 - Curva de Resposta Transitória do Sistema 4a

A Tabela 28 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 54. Figura 43 – Curva de Resposta Transitória do Sistema 3a.

Tabela 28. Matrizes de Ganho K e K_e do Sistema 4a

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [17,1035 \quad 16,2448 \quad 2,7139]$	$K_e = \begin{bmatrix} 43,4507 \\ 46,9287 \\ -6,0753 \end{bmatrix}$

Tabela 29. Desempenhos das curvas transitórias do Sistema 4a

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 19,8\%$	$x_1 = 3,42s$
	$x_2 = 118\%$	$x_2 = 3,95s$
	$x_3 = 438\%$	$x_2 = 4,48s$
AG-Observador	$x_1 = 0,02\%$	$x_1 = 0,10s$
	$x_2 = 2,9\%$	$x_2 = 0,63s$
	$x_3 = 0,6\%$	$x_2 = 0,55s$
Controlador-Observador	$x_1 = 0,15\%$	$x_1 = 0,10s$
	$x_2 = 7,6\%$	$x_2 = 0,61s$
	$x_3 = 0,4\%$	$x_2 = 0,90s$




Figura 55 - Curva de Resposta Transitória do Sistema 4b

A Tabela 30 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 55.

Tabela 30. Matrizes de Ganho K e K_e do Sistema 4b

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [20,8308 \quad 16,4617 \quad 4,7605]$	$K_e = \begin{bmatrix} 43,4507 \\ 46,9287 \\ -6,0753 \end{bmatrix}$

Tabela 31. Desempenhos das curvas transitórias do Sistema 4b

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 19,8\%$	$x_1 = 5,02s$
	$x_2 = 117\%$	$x_2 = 5,64s$
	$x_3 = 409\%$	$x_2 = 6,26s$
AG-Observador	$x_1 = 0,02\%$	$x_1 = 0,10s$
	$x_2 = 2,9\%$	$x_2 = 0,63s$
	$x_3 = 0,6\%$	$x_2 = 0,55s$
Controlador-Observador	$x_1 = 0,17\%$	$x_1 = 0,10s$
	$x_2 = 8,3\%$	$x_2 = 0,73s$
	$x_3 = 7,2\%$	$x_2 = 1,0s$




Figura 56 - Curva de Resposta Transitória do Sistema 4c

A Tabela 32 apresenta a matriz de ganho do controlador (obtida do AG-Controlador) e a matriz de ganho do observador (obtida do AG-Observador) utilizadas para gerar as curvas de resposta transitória da Figura 56.

Tabela 32. Matrizes de Ganho K e K_e do Sistema 4c

Matriz de Ganho do Controlador	Matriz de Ganho do Observador
$K = [28,1762 \quad 28,7715 \quad 8,8361]$	$K_e = \begin{bmatrix} 43,4507 \\ 46,9287 \\ -6,0753 \end{bmatrix}$

Tabela 33. Desempenhos das curvas transitórias do Sistema 4c

Tipos de Curvas	Máximo Sobressinal M_p	Tempo de Acomodação T_s
AG-Controlador	$x_1 = 18\%$	$x_1 = 4,12s$
	$x_2 = 94\%$	$x_2 = 4,66s$
	$x_3 = 409\%$	$x_2 = 5,19s$
AG-Observador	$x_1 = 0,02\%$	$x_1 = 0,10s$
	$x_2 = 2,9\%$	$x_2 = 0,63s$
	$x_3 = 0,6\%$	$x_2 = 0,55s$
Controlador-Observador	$x_1 = 0,21\%$	$x_1 = 0,10s$
	$x_2 = 10,3\%$	$x_2 = 0,74s$
	$x_3 = 30,1\%$	$x_2 = 1,0s$

Analisando as Figuras 54, 55 e 56 e suas respectivas tabelas de desempenho (Tabelas 29, 31 e 33) percebe-se que o AG-Controlador não atende os requisitos de desempenho (Máximo sobressinal: $M_p = 10\%$; Tempo de acomodação: $t_s = 2s$). Por outro lado o AG-Observador consegue atingir os índices de desempenho para máximo sobressinal (menor que 10%) e para tempo de acomodação (menor que 2s).

Quando analisamos a função transferência Controlador-Observador percebe-se que a resposta do sistema melhora, ou seja, os índices de desempenho para qualquer umas variáveis de estado são sempre atingidos. Os tempos de acomodação do sistema ficaram menores que 1s em todas as curvas de controlador-observador (Tabelas 29, 31 e 33) quando comparadas tanto com as curvas do AG-controlador como com as curvas do AG-observador. Os máximos sobressinais das curvas controlador-observador também encontram-se dentro dos requisitos do sistema.

6 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

A proposta deste trabalho consistia em desenvolver um algoritmo genético que pudesse controlar um sistema em espaço de estado a partir do conceito de observadores de estado. No processo de construção deste algoritmo genético foi implementado, inicialmente, um AG para um controlador conforme OLIVEIRA, 2010, porém desenvolvido totalmente em ambiente MATLAB no qual chamamos de AG-Controlador. Este AG apresentou resultados satisfatórios, tanto no que diz respeito às especificações de projeto (máximo sobressinal e tempo de acomodação), quanto com as performances de sistema (tempo de execução).

Partindo do princípio que se para um controlador, o AG-Controlador construído se mostrou satisfatório, foi desenvolvido um outro AG para realizar o mesmo controle a partir de um observador de estado, no caso o AG-Observador. Nos dois sistemas de segunda ordem simulados pelo AG, observou-se comportamentos bem distintos. No sistema 1, em todas as simulações realizadas como o AG-Observador, não foi possível encontrar resultados que satisfizessem todas as especificações do projeto. Além disso, o desempenho do programa, em muitas ocasiões, não conseguia finalizar o processo.

A favor das simulações, tem-se que quando o programa conseguia executar, a performance era satisfatória (ver os tempos de simulação nas Tabelas 4 e 5). Já no sistema 2, em praticamente todas as simulações, o AG-observador conseguia encontrar uma resposta satisfatória (que atendia os requisitos de desempenho do sistema para máximo sobressinal e tempo de acomodação). E, além disso, a performance era bastante satisfatória. (ver os tempos de simulação nas Tabelas 12 e 13).

Porém, quando construímos as curvas para o AG-Controlador, para o AG-Observador e para o controle envolvendo o controlador-observador (Figuras 20, 21 e 22 referentes ao sistema 1 e as Figuras 32, 33 e 34 referentes ao sistema 2) percebe-se que a estratégia de controle proposta neste trabalho apresentou resultados satisfatórios, principalmente quando analisamos os dados de desempenho do controle envolvendo o controlador-observador (Tabelas 7, 9 e 11 referentes ao Sistema 1 e Tabelas 15, 17 e 19 referentes ao Sistema 2) em que os requisitos de sistema sempre eram atingidos, comprovando a eficiência do algoritmo genético proposto.

Para os dois sistemas de 3ª ordem (Sistemas 3 e 4) foram obtidos os melhores resultados para o AG-Observador. Nas Tabelas 20 e 27, referentes aos índices de desempenho dos sistemas 3 e 4 respectivamente, observa-se que tanto o máximo sobressinal, como o tempo de

acomodação são atingidos. E vale salientar que no sistema 4, quando analisamos o gráfico do lugar da raízes (Figura 46), o mesmo é condicionalmente estável, semelhante ao sistema 1 de 2ª ordem, cuja os resultados para este sistema não foram satisfatórios. E quando comparamos as curvas do AG-Controlador, do AG-Observador e a do controlador-observador (Figuras 43, 44, 45 do sistema 3 e Figuras 54, 55 e 56 do sistema 4), percebe-se que o AG-Observador atende bem os requisitos de desempenho do sistema, e que o controle realizado pelo controlador-observador também atende os parâmetros especificados para o desempenho dos sistemas.

Quanto aos parâmetros de inicialização tanto para o AG-controlador, como para o AG-observador, percebe-se que o tamanho da população influenciou mais na performance (tempo de execução) do que na solução encontrada. Pois quando o AG era utilizado, independente do tamanho da população, o AG encontrava indivíduos que atendiam os requisitos especificados, alterando apenas o tempo de execução da resposta encontrada. Quanto aos valores máximos e mínimos definidos para os genes dos indivíduos, percebemos que tanto o AG-Controlador, como o AG-Observador sofreram influência pela definição desses valores máximos e mínimos, o que já era esperado, pois cada sistema possui uma dinâmica própria e, conseqüentemente, valores de ganho específicos para poderem atingir os mesmos requisitos de desempenho.

Quanto aos fatores de reprodução (cruzamento, elitismo e mutação), verificou-se que o fator mais que mais contribuiu para a convergência do AG foi a taxa de cruzamento, pois quanto maior era a taxa de cruzamento do AG, melhor a eficiência do AG em encontrar uma resposta satisfatória. Tanto no AG-Controlador, como no AG-Observador, uma taxa de cruzamento de 90% forneceram as melhores performances no que diz respeito ao tempo de execução. Quanto ao elitismo, verificou-se que quanto maior era a taxa de elitismo, menor era a diversidade de indivíduos que passavam para geração seguinte, ou seja, houve simulações em que se formavam uma população de superindivíduos, fazendo com o AG não convergisse para uma solução satisfatória. Mesmo assim, na maioria das simulações, o fato da taxa de elitismo ser de 10%, 25% ou até mesmo 50%, pouco influenciou na performance do AG. Quanto à taxa de mutação, não houve influência significativa desta, quando se executava o AG com uma taxa de 1% ou com uma taxa de 10%.

Tendo em vista os problemas encontrados no AG para observador, deve-se investigar quais as razões para desempenhos tão distintos entre o AG-controlador e o AG-observador, especialmente para o Sistema 1 de 2ª ordem. Vale salientar que o AG-controlador foi

desenvolvido a partir da condição de controlabilidade completa dos sistemas utilizados, e que o AG-observador foi desenvolvido a partir da condição de observabilidade completa.

Outra investigação importante seria a avaliação de desempenho, tanto do AG-controlador, como do AG-observador, para sistema de ordem superior a 5, pois para sistemas de ordem elevada temos um espaço de busca muito mais amplo de soluções à serem encontradas. E nesse aspecto, o AG proposto, seja controlador ou observador, poderia ser testado para avaliarmos os resultados que seriam obtidos, bem como, o esforço computacional que seria desempenhado.

Observadores de ordem reduzida, ou de ordem mínima também merecem uma comparação quanto aos resultados e desempenhos que seriam obtidos em comparação com os resultados e desempenho obtidos com os observadores de ordem plena.

Outra proposta para trabalhos futuros poderia ser a comparação dos resultados obtidos com o observador AG com outros tipos de observadores, como Regulador Linear Quadrático Gaussiano (LQG, *Linear Quadratic Gaussian*) e, ainda, o controle estocástico baseado no Filtro de Kalman (FERREIRA, 2004). Ou ainda, o desenvolvimento de observadores a partir da lógica Fuzzy.

REFERÊNCIAS

ALANIS, Alma Y. et al. Real-time recurrent neural state estimation. **Neural Networks, IEEE Transactions on**, v. 22, n. 3, p. 497-505, 2011.

ALCALÁ, R, BENITEZ, J. M.,CASILLAS, J., CORDÓN, O., PÉREZ, R., **Fuzzy Control of HVAC Systems Optimized by Genetic Algorithms**. *Applied Intelligence*, v.18 n.2, p.155-177, March-April 2003.

AL-HAJRI, M.; ABIDO, M. Assessment of genetic algorithm selection, crossover and mutation techniques in reactive power optimization. In: **Evolutionary Computation, 2009. CEC'09. IEEE Congress on**. [S.l.: s.n.], 2009. p. 1005 –1011.

BARROS, L. S. **Uma Estratégia de Controle Para o Melhoramento do Comportamento Dinâmico de Máquinas de Indução Duplamente Alimentadas Operando Como Geradores Eólicos**. Tese (Doutorado) – Universidade Federal de Campina Grande, Campina Grande, 2006.

BENTO, E. P.; KAGAN, N. Algoritmos genéticos e variantes na solução de problemas de configuração de redes de distribuição. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 19, n. 3, p. 302-315, 2008.

BERCI, César Daltoé; BOTTURA, Celso Pascoli. Observador inteligente adaptativo neural não baseado em modelo para sistemas não lineares. In:**Proceedings of 7th Brazilian Conference on Dynamics, Control and Applications. Presidente Prudente, Brasil**. 2008. p. 209-215.

BERCI, César Daltoé; BOTTURA, Celso Pascoli. Controle não linear genético do pendulo invertido. **DINCON 2010**, 2010.

CERQUEIRA, M.M. **Observadores de Estado para Sistemas de Medição Indireta e Controle RLQD-GA**. Dissertação (Mestrado) – Universidade Federal do Maranhão, São Luís, 2010. CHANGYING, Li et al. Fuzzy adaptive observer and filter backstepping control for nonlinear systems. In: **American Control Conference, 2009. ACC'09. IEEE**, 2009. p. 4290-4295.

DE SOUZA, Celso Correia et al. Uso de algoritmos genéticos como ferramenta auxiliar no processo decisório em atividades de gestão agroindustrial. **revista. gepec**, v. 85903, p. 000, 2010.

DORF, R. C.; BISHOP, R. H. **Sistemas de Controle Modernos**. 11. ed. [S.l.]: LTC Editora, 2009. ISBN 9788521617143.

FERNANDES, Anita Maria da Rocha. **Inteligência Artificial**: noções gerais. 2º imp. Florianópolis: VisualBooks, 2005.

FILITTO, Danilo. Algoritmos Genéticos: Uma Visão Explanatória. **Revista Multidisciplinar da UNIESP. São Paulo**, n. 06, 2008. FERREIRA, C. C. T. **Alocação de Auto-Estrutura Utilizando Controle Robusto LQG/LTR e Computação Evolutiva**. Dissertação (Mestrado), Universidade Federal do Maranhão, São Luís, 2004.

HAUPT, R. L.; HAUPT, S. E. **Practical Genetic Algorithms**. 2ª. ed. Hoboken, New Jersey: Wiley, 1998.

HAUPT, R. L.; HAUPT, S. E. **Practical Genetic Algorithms**. John Wiley and Sons, 2004.

HILAIRET, M.; BETHOUX, O.; AUGER, F. Fault-tolerant speed measurement for the control of a DC-motor. 2007.

JABBOUR, Z. et al. Speed estimation comparison between full order state observer & Kalman filter for a haptic interface. In: **Industrial Electronics, 2009. ISIE 2009. IEEE International Symposium on**. IEEE, 2009. p. 1482-1487.

JANARTHANAN, K.; PRAKASH, J. Fuzzy Kalman Filter Based Simultaneous State and Fault Parameter Estimation Scheme with an Application to a Continuous Stirred Tank Reactor. In: **India Conference, 2006 Annual IEEE**. IEEE, 2006. p. 1-3.

KWAKERNAAK, H.; SIVAN, R. **Linear Optimal Control Systems**. United States of America: John Wiley Sons, Inc, 1972.

LI, N.; YE, F. Optimal design of discrete structure with directed mutation genetic algorithms. In: **Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress on**. [S.l.: s.n.], 2006.

LINDEN, R. **Algoritmos Genéticos: Uma Importante Ferramenta da Inteligência Computacional**. Rio de Janeiro: Brasport, 2006.

LOH, Wei Hong; KUANG, Ye Chow; OOI, M. P. Hardware design of neural network system state observer. In: **Instrumentation and Measurement Technology Conference, 2009. I2MTC'09. IEEE**. IEEE, 2009. p. 1063-1068.

MATLAB. **The Language of Technical Computing**. [S.l.]: The Mathworks, 2008.

MELANIE, M. **An Introduction to Genetic Algorithm**. Cambridge, Massachusetts: Bradford Book, 1999.

MIASAKI, Celso T.; ROMERO, Rubén A. ESTUDO DE UMA METAHEURÍSTICA UTILIZADA NA ALOCAÇÃO DE DISPOSITIVOS DE COMPENSAÇÃO SÉRIE NO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA. **XXXVII Simpósio Brasileiro de Pesquisa Operacional – SBPO: Pesquisa Operacional e Desenvolvimento Sustentável**, 37., 2005, Gramado. **Anais...** . Rio de Janeiro: Sobrapo, 2005. p. 1325 - 1336. Disponível em: <<http://www.din.uem.br/sbpo/sbpo2005/pdf/arq0104.pdf>>. Acesso em: 15 ago. 2013.

MIASAKI, Celso Tadao; ROMERO, Ruben. Um algoritmo genético especializado aplicado ao planejamento da expansão do sistema de transmissão com alocação de dispositivos de compensação série. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 18, n. 2, p. 210-222, 2007.

MIRANDA, Rafael de Carvalho; PINHO, Alexandre Ferreira de; MONTEVECHI, José Arnaldo Barra (Ed.). ANÁLISE DE SIGNIFICÂNCIA DOS PARÂMETROS DE UM ALGORITMO GENÉTICO ATRAVÉS DO PLANEJAMENTO DE EXPERIMENTOS. **Cadernos do Ime: Série Estatística**, Rio de Janeiro, v. 31, p.7-19, dez. 2011. ISSN 1413-9022. Semestral. Disponível em: <<http://www.ime.uerj.br/cadernos/cadest>>. Acesso em: 15 out. 2012.

MIT SANTISUK, Chowarit; OHISHI, Kiyoshi; KATSURA, Seiichiro. Estimation of action/reaction forces for the bilateral control using Kalman filter. **Industrial Electronics, IEEE Transactions on**, v. 59, n. 11, p. 4383-4393, 2012.

NISE, N. S. **Engenharia de Sistemas de Controle**. 5ª edição. ed. [S.l.]: LTC Editora, 2009. ISBN 8521617046.

OGATA, K. **Engenharia de Controle Moderno**. 5ª edição. ed. São Paulo: Pearson Prentice Hall, 201003.

OLIVEIRA, P. S. **Algoritmos Genéticos Aplicados ao Projeto de Controle com Realimentação de Estados**. Dissertação (mestrado) – Universidade Federal Rural do Semi-Árido, Mossoró, 2010.

OLIVEIRA, P. S.; SILVEIRA JÚNIOR, L. G. Q.; BARROS, L. S. **Projeto de Sistema de Controle Multivariável Baseado em Algoritmo Genético Otimizado**. 2012.

OTTO, P. **Genética humana e clínica**. [S.l.]: Editora Roca, 2004. ISBN 9788572414944.

PEREIRA, Andre Luiz Viana. **UTILIZAÇÃO DE ALGORITMOS GENÉTICOS PARA SOLUÇÃO DE PROBLEMAS DE ÁRVORE GERADORA MÍNIMA GENERALIZADA. UM ESTUDO DE CASO NA IRRIGAÇÃO**. 2011. 43 f. TCC (Graduação) - Curso de Ciências da Computação, Departamento de Ciências Exatas e Naturais, Universidade Federal Rural do Semiárido, Mossoró, 2011.

PORTER, La Moyne L. et al. Genetic adaptive observers. In: **American Control Conference, Proceedings of the 1995**. IEEE, 1995. p. 1847-1851.

SANTOS, Joelan AL et al. Algoritmo genético modificado para minimização de funções. **VIII ERMAC: Encontro Regional de Matemática Aplicada e Computacional**. 8., 2008, Natal. Disponível em <http://www.dimap.ufrn.br/~sbmac/ermac2008/Anais/Resumos%20Estendidos/Algoritmo%20genetico_Joelan.pdf>. Acesso em: 15 ago. 2013.

SIMON, Dan. Kalman filtering with state constraints: a survey of linear and nonlinear algorithms. **IET Control Theory & Applications**, v. 4, n. 8, p. 1303-1318, 2010.

SIVANANDAM, S. N. and DEEPA, S. N. **Introduction to Genetic Algorithms**. Springer. 2008. WANG, G. et al. Optimization of controller parameters based on the improved genetic algorithms. In: **Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress on**. [S.l.: s.n.], 2006. v. 1, p. 3695 – 3698.

WU, Tzu-Sung; YU, Wen-Shyong. Fuzzy Adaptive Output-Feedback Control Design for Nonlinear Dynamic Systems with Output Delay. In: **Fuzzy Systems, 2006 IEEE International Conference on**. IEEE, 2006. p. 1016-1022.

YI, Jianbo; HUANG, Qi. Fault detection and isolation based on optimal fault-tolerant observers for linear system. In: **Electrical and Control Engineering (ICECE), 2010 International Conference on**. IEEE, 2010. p. 982-985.