

CONTROLE LQR INTELIGENTE PARA GERADORES EÓLICOS DFIG

JOÃO VIANA DA FONSECA NETO, IVANILDO SILVA ABREU, FÁBIO NOGUEIRA DA SILVA*, JOSÉ CARLOS TELES CAMPOS, VANDILBERTO PEREIRA PINTO†

**Departamento de Engenharia Elétrica da Universidade Federal do Maranhão, São Luís, MA 65.080-040 Brasil*

†*Departamento de Engenharia Elétrica da Universidade Federal do Ceará, Fortaleza, CE 60.455-760 Brasil*

Emails: jviana@dee.ufma.br, ivanildoabreu@yahoo.com.br, fdasilva@hotmail.com, teles@ufc.br

Abstract— The Intelligent Control approach, proposed in this paper, is a tuning method based on Artificial Intelligence paradigms to select the weighing matrices and to solve the Algebraic Riccati Equation (ARE) associated with the Linear Quadratic Regulator (LQR) problem. The intelligent design procedure is applied in a doubly fed induction generator (DFIG) of a Eolic plant, LQR intelligent control design performance is evaluated as problem solver to compute the optimal gains, as well as, to measure performance of the LQR intelligent method as computer aid design support. The genetic algorithm is in charge of eigenstructure assignment and a neural network to compute the ARE solution in order to guarantee the LQR's robustness of gain and phase margins, inherent features of LQR design. The tuning is promoted by the ARE parameters variations, that are coordinated by a multivariable genetic algorithm dedicated to the eigenvalues and eigenvectors assignment.

Keywords— Recurrent Neural Networks, Genetic algorithms, State Space Controllers, Linear Quadratic Regulator Design, Algebraic Riccati Equation, Intelligent Control, Doubly Fed Induction Generator.

Resumo— A abordagem de controle Inteligente, proposta neste artigo, é um método para a sintonia que está fundamentado em paradigmas de inteligência artificial para seleção das matrizes de ponderação e para solução equação algébrica de Riccati (ARE) do problema do Regulador Linear Quadrático (LQR). O procedimento de projeto para LQR inteligente é aplicado em geradores de indução duplamente alimentado (DFIG) de plantas eólicas, o desempenho do projeto do LQR inteligente é avaliado como *problem-solver* para determinação dos ganhos ótimos, como também, para medir o desempenho do método proposto como uma ferramenta para apoio ao projeto de sistemas de controle. O algoritmo genético é responsável pela alocação da autoestrutura e a rede neural garante a robustez das margens de ganho e de fase, propriedades inerentes do controle LQR, por meio da solução definida positiva da ARE. Desta forma, a sintonia é realizada por variações paramétricas na ARE que são coordenadas por um algoritmo genético e dedicado a alocação de autovalores e autovetores.

Palavras-chave— Controle LQR, Rede Neural Recorrente, Algoritmos Genéticos, Controle Inteligente, Equação Algébrica de Riccati, Gerador de Indução Duplamente Alimentado

1 Introdução

As atividades de pesquisa e desenvolvimento voltadas para geração de energia tem importância significativa para minimização dos danos ambientais e promoção do bem-estar social. As fontes convencionais de geração de energia elétrica são as usinas hidrelétricas, termoeletricas e nucleares. Outras fontes de energia, como a energia solar, eólica, biomassa e energia das marés, são classificadas como fontes alternativas de energia. As fontes alternativas de energia mostram seu potencial de aplicação em face de duas grandes questões: a questão da eletrificação de áreas isoladas e a questão da esgotabilidade das fontes convencionais.

O apelo social e ecológico para o desenvolvimento de sistemas de energia alternativa foi salientado no parágrafo anterior. Agora, a viabilidade técnica para o desenvolvimento de pesquisa para estes sistemas de energia é tema dos próximos parágrafos.

A principal contribuição consiste em mostrar a viabilidade de integrar as abordagens de inteligência artificial, tais como: algoritmos genéticos e

redes neuronais, para síntese de sistemas de controle ótimo do tipo LQR. A seleção das matrizes de ponderação é realizada por algoritmo genético e solução da ARE é dada por uma rede neuronal recorrente. Desta forma, o GA contribui para impor uma lei de controle que aloca a autoestrutura e rede neuronal que contribui para a computação dos ganhos, evitando problemas com inversão de matrizes.

A importância do desenvolvimento de pesquisa voltada para síntese de sistemas de controle que estão fundamentadas no projeto LQR, envolve os mais variados segmentos das atividades tais como setor industrial, utilidade pública, geração de energia, (Myoen-Song Choi, 1996), atenuação de ruídos auditivos, devido a perturbações externas dos automóveis e outros (José Paulo F. et al., 2004), controle de máquinas de corrente contínua e controle de processos, (Zhou, 1995). A utilização do projeto LQR tem-se mostrado uma alternativa em aplicações a sistemas eólicos, enfatizando as tecnologias de geração eólica que adotam os geradores de indução duplamente alimentados (DFIG), (Pinto, 2007).

O artigo está estruturado em seções organizadas da seguinte maneira: Na Secção 3 apresenta-se o método LQR Inteligente que utiliza um algoritmo genético na determinação das matrizes de ponderação e a solução da equação algébrica de *Riccati* é resolvida por uma rede neural artificial recorrente que fornece uma solução simétrica e definida positiva. Na Secção 4 mostra-se o modelo do Gerador DFIG e da turbina eólica, as equações do gerador de indução e dos conversores de potência. Na Secção 5 apresenta-se a síntese dos controlador LQR inteligente para o controle de um plante eólica, exibimos as matrizes selecionadas pelo algoritmo genético e o ganho ótimo que depende da solução da ARE. Na Secção 6 são apresentadas as conclusões, comentários e tendências do projeto LQR inteligente.

2 Geradores Eólicos DFIG

A energia eólica pode ser convertida em energia elétrica através de aerogeradores, que são sistemas que captam a energia do vento através das hélices, transformando-a em energia mecânica que então é convertida em energia elétrica através de um gerador.

Os geradores de indução com rotor bobinado para aplicações em sistemas eólicos podem ser encontrados em dois tipos básicos de configuração. Uma em que o escorregamento ou torque é controlado através da eletrônica de potência no circuito do rotor, caracterizado pela variação da resistência rotórica. A outra tecnologia é a conexão de um circuito de extração de potência pelo rotor conhecido como *Double fed generator* (DFIG) (Rosas, n.d.). Para maiores detalhes, veja as referências, (Nunes, 2003), (Marques, 2003) e (Hansen, 2001).

A Fig.1 apresenta um diagrama geral das conexões da turbina com gerador que adota o gerador com rotor bobinado, onde um dos conversores é conectado à rede e o outro é conectado aos enrolamentos do rotor, sendo que os dois conversores são interligados através de um circuito capacitivo e com controle PWM. Para o conjunto gerador e conversores de potência existem várias concepções para interligação dos geradores de indução duplamente alimentados às turbinas eólicas.

O conversor interligado ao gerador controla a velocidade do rotor e a potência reativa injetada ou consumida pelo gerador através do estator. Já o conversor interligado à rede controla a tensão no barramento CC e a potência ativa que o rotor troca com a rede. A configuração que utiliza o DFIG possui como umas das principais vantagens sobre as demais tecnologias, a utilização de conversores de frequência da ordem de trinta por cento da potência nominal da turbina, reduzindo substancialmente o seu custo de instalação (Pinheiro, 2004).




Figura 1: Gerador de Indução Duplamente Alimentado.

Segundo (Marques, 2003), as topologias mais utilizadas para geração eólica com velocidade variável são as que utilizam o DFIG e Gerador síncrono, mas dentre os fatores mais importantes a serem considerados são o custo e as propriedades dinâmicas de cada esquema (Nunes, 2003).

O princípio de funcionamento do DFIG pode ser dado em maiores detalhes em (Hansen, 2003). Pode ser explicado por meio do escorregamento $s = \frac{\omega_s - \omega_m}{\omega_s}$ e do fluxo de potência. Quando o DFIG encontra-se na velocidade super-síncrona ($s < 0$) a potência será fornecida à rede simultaneamente pelo rotor através dos conversores e pelo estator. Deste modo ($P_{rotor} > 0$) indica o fornecimento de potência. Já quando o DFIG encontra-se na velocidade sub-síncrona ($s > 0$) o fluxo da potência será da rede para o rotor. Desta forma ($P_{rotor} < 0$) indica que o rotor está absorvendo potência da rede. Em ambos os casos (velocidade super-síncrona e sub-síncronas) o estator fornece potência à rede.

3 LQR Inteligente

O desenvolvimento de dois métodos de inteligência artificial para resolver o problema do controlador LQR são apresentados. Estes desenvolvimentos são resultados de pesquisas no LQR realizadas usando um algoritmo genético, (Ferreira, 2004), na determinação das matrizes de ponderação Q e R do projeto LQR e a solução da equação algébrica de *Riccati* via rede neural recorrente, (Nogueira Fábio, 2006), (Guang Wu, 1998). Na Fig. 2 ilustra-se o diagrama básico do LQR inteligente como uma abordagem para projeto e implementação em tempo real de sistemas de controle ótimo.

O problema do Regulador Linear Quadrático é apresentado sob o ponto de vista da natureza das matrizes de ponderações Q do estado e R do

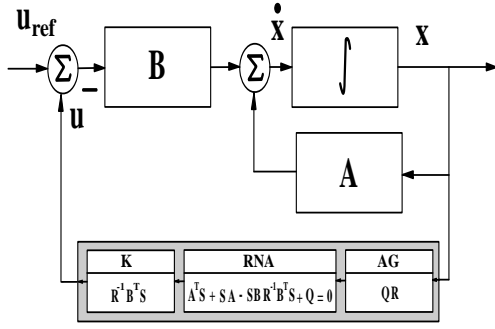


Figura 2: Diagrama de LQR Inteligente para fins de projeto.

controle de forma a minimizar um índice de desempenho, alocar a autoestrutura especificada de modo a garantir estabilidade e robustez ao sistema de controle.

3.1 Abordagem Clássica

O conteúdo da abordagem clássica contempla a formulação e solução do problema LQR, como também, o método de Schur para solução da equação algébrica de *Riccati*. Estes métodos são apresentados para fins de comparações e análise com a abordagem inteligente. Desta forma, pode-se justificar o desenvolvimento de novos métodos para resolver dificuldades provenientes da abordagem clássica, tais como: a busca das matrizes de ponderação e justificar a necessidade da utilização de RNA para solução da ARE.

3.1.1 A Formulação Clássica do LQR

A metodologia de controle do LQR clássica pode ser visualizada como uma aplicação particular do problema de otimização. Ele é caracterizado pela busca do vetor de entrada u que minimiza um funcional $J(\cdot)$ com restrições para o modelo do sistema.

Uma das vantagens da metodologia LQR é a margem de estabilidade garantida, margem de fase de 60 graus e margem de ganho infinita, possuindo portanto, a qualidade de robustez de estabilidade.

O LQR é formulado por meio de um índice de desempenho quadrático e tem como restrições a equação de estado linear invariante no tempo,

$$J(t_o) = \frac{1}{2} \int_{t_o}^T [x^T Q x + u^T R u] dt \quad (1)$$

$$\text{s.a} \quad \dot{x} = Ax + Bu \quad (2)$$

sendo $x \in R^n$ e $u \in R^m$, o par A, B é controlável, o par A, C é observável, $Q \geq 0$ and $R > 0$.

Todas simétricas. $Q \in R^{n \times n}$ e $R \in R^{m \times m}$ são matrizes definidas e semi-definidas positivas, respectivamente.

Os métodos de cálculo variacional, (Athans, 1966), são utilizados para resolver o problema de otimização que é estabelecida na estrutura de otimização, equações (1) e (2). Estes métodos fornecem a lei de controle que minimiza o índice J e satisfaz as restrições \dot{x} da estrutura de otimização,

$$u = Kx. \quad (3)$$

sendo $K = -R^{-1}B^T P$ o ganho do controlador. Este ganho depende da solução P da equação algébrica de Riccati,

$$A^T P + PA - PBR^{-1}B^T P + Q = 0, \quad (4)$$

3.1.2 A Equação Algébrica de Riccati-LQR

A equação contínua de *Riccati* pode ser resolvida por meio da redução da matriz Hamiltoniana, pesquisas pioneiras neste método podemos ser encontrados em, (Laub, 1979).

$$H = \begin{bmatrix} A & -BR^{-1}B^T \\ -Q & -A^T \end{bmatrix} \quad (5)$$

para uma forma quasi-triangular, usando transformações de similaridade ortogonais e sendo denominada forma real de *Schur*. Existe uma matriz ortogonal U , que transforma a matriz Hamiltoniana H na forma real de *Schur*

$$T = W^T H W = \begin{bmatrix} T_{11} & T_{12} \\ 0 & T_{22} \end{bmatrix} \quad (6)$$

sendo que os blocos T_{11} e T_{22} são matrizes superiores quasi-triangulares. A matriz W é particionada em quatro blocos com dimensão $n \times n$. S e a matriz W_{11} são matrizes não singulares e a solução da ARE é positiva definida,

$$P = W_{21} W_{11}^{-1} \quad (7)$$

Os autovalores de T_{11} são o *spectrum* de malha fechada da matriz $(A - BR^{-1}B^T P)$. A região polar do sistema ótimo de malha fechada é devida a relação $(A - BR^{-1}B^T P) = W_{11} T_{11} W_{11}^{-1}$.

3.2 Abordagem Inteligente

A abordagem inteligente é formulada em duas estruturas de otimização que fornecem a solução da ARE. A primeira, fornece as matrizes de ponderação Q e R de estado e controle respectivamente por meio de um algoritmo genético e a segunda a uma rede neural artificial recorrente fornece a solução P da ARE.

3.2.1 Modelo Neural-ARE

O problema reformulado para a síntese do LQR pode ser considerada como um problema de otimização irrestrita. De modo que dadas as matrizes A , B , Q , and R , deseja-se achar as matrizes P and L de modo a minimizar uma função energia,

$$\min_{P,L} \xi(PSP - A^T P - PA - Q + LL^T - P) \quad (8)$$

sendo $S = BR^{-1}B^T$. Se a função de ativação, $\xi_{ij} : \mathbb{R} \rightarrow \mathbb{R}$, é uma função convexa limitada inferiormente, verifica-se que a soma da ARE com a fatoração de *Cholesky* é expressa na forma escalar como segue:

$$\sum_{k=1}^n \sum_{l=1}^n p_{ik} s_{kl} p_{lj} - \sum_{k=1}^n (a_{ki} p_{kj} + p_{ik} a_{kj}) - q_{ij} \quad (9)$$

$$+ \sum_{k=1}^{\min\{i,j\}} l_{ik} l_{jk} - p_{ij}$$

A seguir apresentamos as equações dinâmicas que representam a rede neuronal recorrente.

Para $i, j = 1, \dots, n$;

$$\frac{dp_{ij}}{dt} = -\eta_v \left\{ \sum_{k=1}^n \sum_{l=1}^n [p_{ik} s_{kl} u_{lj} + u_{ik} s_{kl} p_{lj}] \right. \quad (10)$$

$$\left. - \sum_{k=1}^n [a_{ik} u_{kj} + u_{ik} a_{jk}] - y_{ij} \right\}$$

$$\frac{dl_{ij}}{dt} = -\eta_z \sum_{k=j}^n y_{ik} l_{kj}, \quad i \geq j \quad (11)$$

$$u_{ij} = f_{ij} \left[\sum_{k=1}^n \sum_{l=1}^n p_{ik} s_{kl} p_{lj} \right. \quad (12)$$

$$\left. - \sum_{k=1}^n [a_{ki} p_{kj} + p_{ik} a_{kj}] + q_{ij} \right]$$

$$y_{ij} = f_{ij} \left[\sum_{k=1}^{\min\{i,j\}} l_{ik} l_{jk} - p_{ij} \right], \quad (13)$$

escritas na forma matricial,

$$\frac{dP}{dt} = -\eta_v [PSU + USP - AU - UA^T - Y] \quad (14)$$

$$\frac{dL}{dt} = -\eta_z YL \quad (15)$$

$$U = F[PSP - A^T P - PA + Q] \quad (16)$$

$$Y = F[LL^T - P] \quad (17)$$

sendo $U = [u_{ij}] \in \mathbb{R}^{n \times n}$, $P = [p_{ij}] \in \mathbb{R}^{n \times n}$ e $Y = [y_{ij}] \in \mathbb{R}^{n \times n}$, são matrizes quadradas dos estados de ativação, $L = [l_{ij}] \in \mathbb{R}^{n \times n}$ uma matriz triangular inferior dos estados de ativação. $P(0) = P(0)^T$, $P(0) \neq 0$, $\eta_v > 0$ e $\eta_z > 0$, parâmetros do projeto. $F = f_{ij}$ é uma matriz simétrica dos estados de ativação, logo se F é simétrica, P , U e Y também serão simétricas. Essas condições de simetria são utilizadas para a redução do número de neurônios usados para a construção da rede.

A arquitetura da rede neuronal recorrente é composta de quatro camadas conectadas bidirecionalmente, sendo P a camada de saída, U a camada de entrada e Y e L duas camadas ocultas que fazem a interconexão entre as camadas P e U . As camadas P , U e Y , consistem de matrizes quadradas de neurônios ($n \times n$) e L é uma matriz triangular. A matriz P representa a solução da ARE e a matriz L representa o fator de *Cholesky*, apresentadas na Eq. (8).

3.2.2 Modelo QR-Genético

A livre escolha das matrizes de ponderação do projeto LQR, são as variáveis do projeto que são usadas para ajustar o ganho do controlador ótimo. O problema considera a dificuldade de sua determinação e a importância no contexto do desenvolvimento desta metodologia é introduzido em (Ferreira, 2003). O foco principal são os métodos de busca das matrizes de ponderação que formam o índice de desempenho J . A estrutura de otimização para busca das matrizes de ponderações,

$$\min_{Q,R} \sum_{i=1}^n p_i s_i(Q, R) \quad (18)$$

s.a

$$s_i(Q, R) \leq 1, \quad i = 1, \dots, n$$

$$\lambda_{ei} \leq \lambda_{ci}(Q, R) \leq \lambda_{di}, \quad i = 1, \dots, n$$

sendo p_i os pesos a i -ésima sensibilidade s_i/ϵ_i normalizada com relação a i -ésima especificação de projeto $\epsilon_i > 0$.

4 Modelo Gerador-Turbina

Após a apresentação do motor na Secção 2, apresentaremos aqui o modelo gerador-turbina, mais precisamente o modelo linearizado, visto deste modo podemos utilizar a teoria de sistemas lineares para realizar a análise da dinâmica, estabilidade, controlabilidade e observabilidade, resposta em frequência e robustez do sistema não linear. O modelo linearizado assume a seguinte forma,

$$\Delta \dot{x} = A\Delta x + B\Delta u \quad (19)$$

$$\Delta y = C\Delta x \quad (20)$$

sendo Δx e Δu vetores de estado e entrada, respectivamente, que são $\Delta x = [\Delta i_{dr} \ \Delta i_{qr} \ \Delta \omega_r \ \Delta i_d \ \Delta i_q \ \Delta V_{dc}]^T$ e $\Delta u = [\Delta v_{dr} \ \Delta v_{qr} \ \Delta T_e \ \Delta v_d \ \Delta v_q]^T$. A matriz A de estados é constituída por matrizes de bloco $A_r^{3 \times 3}$ e $A_s^{3 \times 3}$ representam o lado do rotor e o lado do estator, respectivamente. A matriz de controle B é constituída pelas matrizes de bloco $B_r^{3 \times 2}$ e $B_s^{3 \times 2}$. As matrizes da Eq. (19) de estado,

$$A_r = \begin{bmatrix} -\frac{R_r}{L_{rr}\sigma} & s_0\omega_0 & 0 \\ -s_0\omega_0 & -\frac{R_r}{L_{rr}\sigma} & 0 \\ 0 & 0 & \mu \end{bmatrix}$$

$$B_r = \begin{bmatrix} -\frac{1}{L_{rr}\sigma} & 0 & 0 \\ 0 & -\frac{1}{L_{rr}\sigma} & 0 \\ 0 & 0 & -\frac{1}{2H} \end{bmatrix}$$

$$A_s = \begin{bmatrix} -\frac{R}{L} & \omega_0 & 0 \\ -\omega_0 & -\frac{R}{L} & 0 \\ -\frac{\nu_{d0}}{CV_{cc0}} & -\frac{\nu_{q0}}{CV_{cc0}} & \frac{\nu_{d0}i_{d0} + \nu_{q0}i_{q0}}{CV_{cc0}^2} \end{bmatrix}$$

e

$$B_s = \begin{bmatrix} \frac{1}{L} & \omega_0 \\ 0 & \frac{1}{L} \\ -\frac{i_{d0}}{CV_{cc0}} & -\frac{i_{q0}}{CV_{cc0}} \end{bmatrix}$$

sendo o coeficiente μ definido abaixo

$$\mu = -\frac{\frac{1}{2}\rho A \nu^3 C_p(\lambda, \beta)}{2H\omega_r^2} + \frac{\frac{1}{2}\rho A \nu^3}{2H\omega_r} \cdot \frac{dC_p(\lambda, \beta)}{d\lambda} \cdot \frac{R_p}{\nu} \quad (21)$$

5 Projeto Intel-LQR

Nesta Secção o método LQR, conforme delineado na Secção 3, é aplicado ao modelo de um gerador DFIG, Fig. 3. Este método é constituído pelo estágio de busca das matrizes de ponderação via GA e pela determinação do ganho óptimo do controlador utilizando uma RNA recorrente. Verifica-se que os fundamentos do LQR inteligente encontram-se em computação evolutiva, sendo essa abordagem incorporada as metodologias LQR, LQG e LQG/LTR para resolver problemas relacionadas com heurísticas e de controle em tempo real.

As subsecções estão organizadas em uma seqüência para a realização do projeto LQR inteligente. O levantamento do modelo linearizado gerador-turbina é o primeiro passo para o projeto. O segundo passo é seleção das matrizes de ponderação por um algoritmo genético que garante a alocação da autestutura. O terceiro passo é solução da equação de *Riccati* que garante a robustez do controlador.

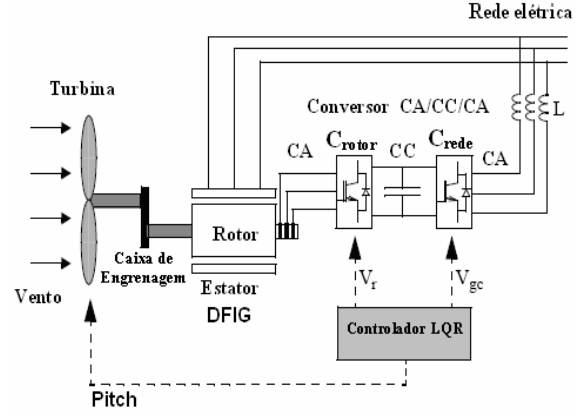


Figura 3: Esquema do gerador de indução com o controlador LQR.

5.1 Modelo Completo

O modelo completo e os parâmetros da turbina eólica do DFIG e do inversor que são substituídos nas matrizes, Eqs. (19) e (20), encontram-se no trabalho de (Pinto, 2007). Desta forma, as matrizes da equação de estado para o sistema linearizado em um ponto de operação são:

$$A = \begin{bmatrix} -39.4 & 0.39 & 0 & | & 0 & 0 & 0 \\ -0.27 & -55.7 & 0 & | & 0 & 0 & 0 \\ 0 & 0 & -21.9 & | & 0 & 0 & 0 \\ \hline 0 & 0 & 0 & | & -24.5 & 0.63 & 19.8 \\ 0 & 0 & 0 & | & -1.27 & -18.0 & 0.72 \\ 0 & 0 & 0 & | & -6.91 & -0.08 & -1.78 \end{bmatrix}$$

A matriz de controle,

$$B = \begin{bmatrix} -12.46 & 0 & 0 & | & 0 & 0 \\ 0 & -12.46 & 0 & | & 0 & 0 \\ 0 & 0 & -2.19 & | & 0 & 0 \\ \hline 0 & 0 & 0 & | & 5.71 & 0 \\ 0 & 0 & 0 & | & 0 & 5.71 \\ 0 & 0 & 0 & | & -0.71 & 0 \end{bmatrix}$$

Detalhes a respeito da montagem da matriz de saída C podem ser observados em (Pinto, 2007),

$$C = \begin{bmatrix} 3.14 & 0 & 0 & 0 & 0 & 0 \\ 0 & 4.51 & 0 & 0 & 0 & 0 \\ 0 & 0 & -10.02 & 0 & 0 & 0 \\ 0 & 0 & 0 & -42.66 & 0 & 0 \\ 0 & 0 & 0 & 0 & 3.29 & 0 \\ 0 & 0 & 0 & 0 & 0 & -3.06 \end{bmatrix}$$

Como o sistema em questão é um sistema MIMO, a análise via diagrama de Bode se torna inviável, para contornar esse problema é feito a decomposição em valores singulares, de modo que possamos deste modo avaliar o comportamento do sistema no domínio da frequências.

A resposta em frequência dos valores singulares, Fig. 4. Nesta figura apresenta-se os maiores

e menores valores singulares em dB em função da frequência em rad/sec do sistema base e sem controlador e com o LQR.

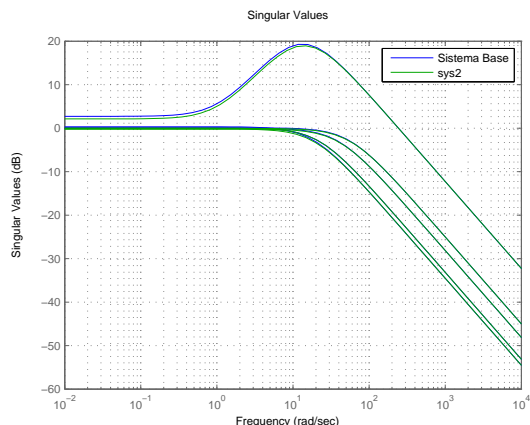


Figura 4: Valores Singulares da Planta Eólica de 6ª Ordem.

Os autovalores do sistema teste -39.42 , -55.74 , $-13.37 \pm j2.60$, -17.68 e -21.95 mostram que o sistema é estável. Uma melhor avaliação do comportamento dinâmico do sistema é realizada por meio da resposta ao impulso, Fig. 5 para o sistema.




Figura 5: Resposta ao Impulso do Sistema de 6ª Ordem.

5.2 Sintonia dos Ganhos

A proposta do LQR inteligente, Secção 3, é aplicada para ajuste dos ganhos no controle do ângulo de passo.

5.2.1 Seleção das Matrizes Q e R

As matrizes de ponderação Q do estado e R do controle foram aqui geradas por um algoritmo ge-

nético, baseada na estrutura formulada na Secção 3.2.2. Foram escolhidas vinte gerações, apresentadas na Fig. 6, mostrando a sensibilidade final para cada população de indivíduos.

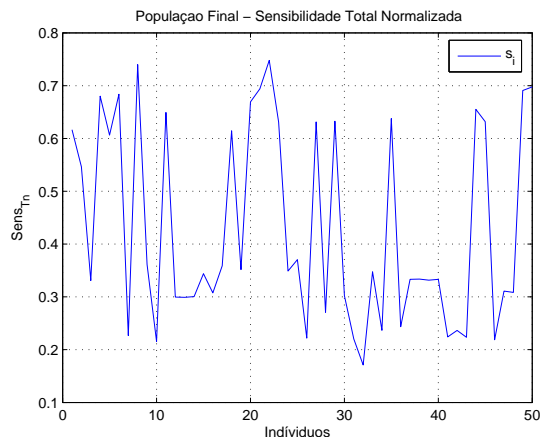


Figura 6: Sensibilidade Total Normalizada para a População Final.

$$Q_{LQR} = \begin{bmatrix} 2.59 & 0.34 & 1.13 & 0.55 & 0.35 & 1.83 \\ 0.34 & 4.39 & 1.42 & 0.29 & 1.59 & 4.57 \\ 1.13 & 1.42 & 3.49 & 5.00 & 0.39 & 0.36 \\ 0.55 & 0.29 & 5.00 & 11.15 & 0.33 & 0.36 \\ 0.35 & 1.59 & 0.39 & 0.33 & 12.34 & 0.29 \\ 1.83 & 4.57 & 0.36 & 0.36 & 0.29 & 14.93 \end{bmatrix} \quad (22)$$

$$R_{LQR} = \begin{bmatrix} 6.53 & 0.13 & 0.11 & 0.16 & 0.12 \\ 0.13 & 6.93 & 0.15 & 0.0832 & 0.13 \\ 0.11 & 0.15 & 7.45 & 0.12 & 0.15 \\ 0.16 & 0.08 & 0.12 & 9.68 & 0.13 \\ 0.12 & 0.13 & 0.15 & 0.13 & 10.56 \end{bmatrix} \quad (23)$$

No algoritmo genético algumas estratégias são usadas para realizar a seleção dos indivíduos no processo evolutivo. Essas estratégias são expressas pelas funções de *fitness*, *crossover* e *mutação*. Essas funções podem ser reformuladas dependendo do problema e das especificações do projeto. Essas funções influenciam na dinâmica da determinação das matrizes de ponderação Q e R . Nestes experimentos foram usados a função de *fitness* que pontua cada indivíduo a partir das especificações. Estudos sobre a utilização da função de *fitness* usando o método elitista, que mantém os melhores indivíduos no decorrer das gerações pode ser uma alternativa interessante para implementação.

5.2.2 Solução Schur-ARE

As matrizes de ponderação Q e R selecionadas pelo AG são constantes contidas na estrutura da ARE, Eq. (4), que é resolvida pelo método de *Schur*. A determinação dos ganhos do controle ótimo envolve uma série de operações complexas,

tais como a solução da equação algébrica de *Riccati*, Eq. (7),

$$K_{schur} = \begin{bmatrix} -0.062 & -0.005 & -0.034 & -0.011 & -0.013 & -0.076 \\ -0.005 & -0.070 & -0.032 & 0.004 & -0.040 & -0.134 \\ -0.004 & -0.004 & -0.022 & -0.029 & -0.005 & -0.020 \\ -0.000 & -0.007 & 0.047 & 0.180 & -0.002 & -0.244 \\ 0.004 & 0.012 & 0.006 & -0.001 & 0.180 & 0.012 \end{bmatrix}$$

Os autovalores do sistema com controlador LQR são: -56.62 , -40.20 , -22.00 , -18.67 e $-13.98 \pm j1.86$,

A análise no domínio da frequência é realizada em termos da decomposição dos valores singulares. As matrizes da decomposição de valores singular $A - BK = U_{svd} S_{svd} V_{svd}^T$ do sistema dinâmico com o controlador LQR, os elementos da matriz S de valores singulares são 56.66 , 40.22 , 33.52 , 21.99 , 19.12 e 5.79 .

5.2.3 Solução Neuronal-ARE

O algoritmo que implementa a solução neuronal da equação de *Riccati*, consiste na implementação da estrutura de otimização, Eq. (8), que minimiza a função energia. Os ganhos do LQR utilizando a RNA,

$$K_{RNA} = \begin{bmatrix} -0.062 & -0.005 & -0.034 & -0.011 & -0.013 & -0.076 \\ -0.005 & -0.070 & -0.032 & 0.004 & -0.040 & -0.134 \\ -0.004 & -0.004 & -0.022 & -0.029 & -0.005 & -0.020 \\ -0.000 & -0.007 & 0.047 & 0.180 & -0.002 & -0.244 \\ 0.004 & 0.012 & 0.006 & -0.001 & 0.180 & 0.012 \end{bmatrix}$$

Os ganhos calculados tanto pelo método de *Schur* e pela RNA, foram próximos, sendo os da RNA mais estáveis, não é percebido visto que a diferença das soluções está na precisão decimal a partir da oitava casa decimal.

Observou-se que de acordo com os autovalores do sistema e a diagonal das matrizes Q e R influenciam diretamente no desempenho e na convergência da RNA, deste modo, os valores das matrizes Q e R podem ser reduzidos ou aumentados uniformemente, melhorando assim a solução da ARE.

Os ajustes das constantes η_z e η_v representam com que rapidez o algoritmo convergirá ou divergirá e o quão boa uma solução pode ser. A análise de resultados da solução *Neuronal-ARE*, são baseadas no comportamento da camada de saída considerando a entrada e as camadas ocultas. A função de ativação usada pelos neurônios, foi a função de saturação linear simétrica, $f(x) = \{-1$ se $x \leq -1$, x , $-1 < x < 1$ e 1 se $x \geq 1\}$, $\eta_v = 10000$, $\eta_z = 14000$, $\Delta T = 9.0 \cdot 10^{-4}$ e $N_{amostra} = 200$. As condições iniciais foram as matrizes identidades, $L = P = I_{3 \times 3}$. As matrizes Q e R usadas são as (22) e (23).

A análise de convergência leva a dois aspectos da solução de *Riccati*, o primeiro a respeito da

existência de uma solução única, e o segundo, está focalizado na velocidade da rede neural atingir o valor da solução em estado estacionário. A análise de convergência está centrada em dois tipos de resultados, o primeiro está relacionado com o melhor ajuste das constantes η_v e η_z e o segundo começa a escolha da melhor condição inicial, e um outro ponto que deve ser considerado é o número de iterações usadas para computar a solução de *Riccati*. Como o número de iterações são crescentes, uma melhor solução é alcançada com grande esforço computacional. A Fig. 7 mostra a superfície da função energia versus ajuste dos parâmetros η_v e η_z




Figura 7: Superfície da Energia para variação dos Parâmetros - $\eta_v = 1450-1540$; $\eta_z = 1000000-1600000$;




Figura 8: Norma do Infinito da ARE para variação parâmetros - $\eta_v = 1000-1500$; $\eta_z = 10000-200000$;

As superfícies apresentadas, Figs. 7 e 8 mostram o quanto a variação paramétrica influencia no comportamento da solução da ARE e de modo a guiar quais os valores dos parâmetros devemos

escolher para dado sistema, de modo a produzir um controle mais robusto.

6 Conclusão

Apresentou-se uma metodologia para sintonia e síntese de sistemas de controle ótimo que tem por base algoritmos genéticos e redes neurais artificiais. Uma planta eólica de sexta ordem foi utilizada para avaliar a metodologia do LQR inteligente, esta planta foi representada por um modelo no espaço de estados para o DFIG e seus conversores de potência.

As matrizes de ponderação de estado e de controle selecionadas pelo algoritmo genético são usadas como parâmetros da equação algébrica de *Riccati* e computadas pela rede neuronal recorrente. Foram feitas variações paramétricas na RNA para mostrar a variação da solução da ARE e a análise de convergência e comparadas com o método de *Schur*. Para a análise de desempenho em termos de solução para o problema de controle, foram realizadas análises de estabilidade, resposta em frequência do sistema realimentado e decomposição de valores singulares.

A metodologia proposta mostrou que soluções computacionais inteligentes podem ser uma alternativa promissora para o projeto e controle de sistemas em tempo real.

Agradecimentos

Este trabalho contou com o apoio da UFMA, UFC, FAPEMA, CNPq, CAPES.

Referências

- Athans, Michael e Falb, L. P. (1966). *OPTIMAL CONTROL- An Introduction to the Theory and Its Applications*, McGRAW-Hill Book Company , United States of America.
- Guang Wu e J. W. (1998). A multilayer recurrent neural network for solving continuous-time algebraic Riccati equation, *Neural network* **11**(1998): 939–950.
- Nogueira, Fábio, Abreu, Ivanildo, Fonseca Neto, João Viana , Barros, Allan Kardec e Fonseca, Orlando. (2006). Solução da equação algébrica de Riccati via rede neural recorrente para o projeto do regulador linear quadrático, *XVI Congresso Brasileiro de Automática* .
- Ferreira, Carlos. C. T. (2004). Alocação de autoestrutura utilizando controle robusto LQG/LTR e computação evolutiva, *Dissertação de Mestrado, UFMA* .
- Ferreira, Carlos C. T., Fonseca Neto, João Viana e Fernando A. Torrico. (2003). Alocação de autoestrutura via controle LQG/LTR e computação evolutiva, *VI Simpósio brasileiro de Automação Inteligente* .
- Zhou, C., J.R. Whiteley, E.A. Misawa, K.A.M. Gasem (1995). Application of enhanced LQG/LTR for distillation control, *Control Systems Magazine, IEEE* **15**(4): 56–63.
- Hansen, A. D., Jauch, C. Sorensen, P. Iov e F., Blaabjerg (2003). *Dynamic wind turbine models in power system simulation tool*, Riso national Laboratory.
- Hansen, A. Helle e L. Blaabjerg (2001). Conceptual survey of generators and power electronics for wind turbines, *Riso national Laboratory* **8**: 5–91.
- José Paulo F., G., Edson S., B., Jean Marcos S., R. and Lizete Maria C. F., G. (.2004). Active Noise attenuation Using LQG/LTR Control, *Control Systems Magazine, IEEE* pp. 1 – 4.
- Laub, A. J. (1979). A schur method for solving algebraic riccati equations, *IEEE Transactions on Automatic Control* **24**(6): 913–921.
- Myoen-Song Choi, J.-W. L. e K. L. (1996). An auxiliary lqg/ltr robust controller design for co-generation plants young-moon park, *Energy Conversion, IEEE Transactions on* **1**(2): 407 – 413.
- Marques, J. Pinheiro, H. Grundling, H. A, Pinheiro, J. R. e Hey, H. L. (2003). Survey on Variable-Speed Wind Turbine System, *Congresso Brasileiro de Eletrônica de Potência, Ceará* .
- Nunes, M. (2003). Avaliação do comportamento de aerogeradores de velocidade fixa e variável integrados em redes elétricas fracas, *Tese de Doutorado Pós Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina* .
- Pinheiro, E. L. R. (2004). *Análise do Comportamento Dinâmico de Usinas Eólicas de Velocidade variável Utilizando ATP Draw*, Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal de Minas Gerais.
- Pinto, V. P. (2007). *Modelagem e Simulação de uma Planta Eólica Controlada por um Regulador Linear Quadrático Conectada ao Sistema de Distribuição de Energia Elétrica*, PhD thesis, Universidade Federal do Ceará.
- Rosas, P. A C. Estanqueiro, A. (n.d.). Guia de projeto elétrico de centrais eólicas, volume 1: Projeto elétrico e impacto de centrais eólicas na rede elétrica.