

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-8756-PRP/228

**REDES NEURAIIS NO MODELAMENTO E CONTROLE
DE TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

QUARTO RELATÓRIO

Luis Filipe de Faria Pereira Wiltgen Barbosa
Gerson Otto Ludwig

**FAPESP – PROCESSO 98/06050-8
DOUTORADO DR-II
Área de Engenharia Nuclear / Fusão Controlada
PERÍODO: setembro de 2001 a março de 2002**

INPE
São José dos Campos
2002

**REDES NEURAIS NO MODELAMENTO E CONTROLE
DE TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

QUARTO RELATÓRIO

Luis Filipe de F .P.W.Barbosa

Gerson Otto Ludwig

FAPESP - PROCESSO 98/06050-8

DOUTORADO DR-II

Área de Engenharia Nuclear / Fusão Controlada

PERÍODO: setembro de 2001 a março de 2002

INPE
São José dos Campos
2002

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

**REDES NEURAIS NO MODELAMENTO E CONTROLE
DE TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

QUARTO RELATÓRIO

Luis Filipe de F .P.W.Barbosa
Gerson Otto Ludwig

**FAPESP - PROCESSO 98/06050-8
DOUTORADO DR-II
Área de Engenharia Nuclear / Fusão Controlada
PERÍODO: setembro de 2001 a março de 2002**

INPE

São José dos Campos

2002

Proposta e Relatório de Projeto (PRP)

**REDES NEURAIS NO MODELAMENTO E CONTROLE DE
TOKAMAKS – APLICAÇÃO AO ETE
(EXPERIMENTO TOKAMAK ESFÉRICO)**

QUARTO RELATÓRIO

Luis Filipe de F.P.W. Barbosa¹
Gerson Otto Ludwig²

1 Bolsista da FAPESP e estudante de doutorado do Departamento de Engenharia Eletrônica do Instituto Tecnológico da Aeronáutica - ITA - Engenheiro Eletricista do Projeto Tokamak ETE no Laboratório Associado de Plasma - Centro de Tecnologias Associadas - LAP / CTE / INPE

2 Pesquisador do Laboratório Associado de Plasma - Centro de Tecnologias Associadas - LAP / CTE / INPE e orientador de tese

**Relatório apresentado a FAPESP, referente a bolsa de Doutorado DR-II
Área de Engenharia Nuclear / Fusão Controlada
setembro de 2001 à março 2002**

RESUMO

Este projeto de pesquisa compreende o projeto e a utilização de Redes Neurais Artificiais (RNA) na reconstrução magnética do equilíbrio do plasma de tokamaks, obtidos através de sondas magnéticas inseridas no interior da câmara de vácuo, que fornecerão informações sobre a posição da coluna de plasma para o sistema de controle do campo magnético vertical. O sistema de controle do campo magnético vertical deverá comandar os amplificadores de alta potência que deverão atuar sobre as bobinas magnéticas de controle de equilíbrio e conformação com o intuito de reposicionar a coluna de plasma do Experimento Tokamak Esférico (ETE), em operação desde novembro de 2000, no Laboratório Associado de Plasma (LAP) do Instituto Nacional de Pesquisas Espaciais (INPE) em São José dos Campos, São Paulo.

Para testar os conceitos envolvidos no projeto de RNA no controle da posição do plasma em tokamaks, foi projetado e construído um sistema de Levitação Magnética (MagLev). Este sistema permite simular o comportamento não-linear controlado por um controlador neural.

SUMÁRIO

1 - Introdução	1
2 - Teoria de Controle Clássico e Estudo da Estabilidade Aplicadas ao Levitador Magnético (MagLev)	3
2.1 - Conceitos e Técnicas da Teoria de Controle Clássico	3
2.2 - Lugar Geométrico das Raízes e Análise da Estabilidade no Domínio do Tempo e da Freqüência	6
2.3 - Projeto do Controlador para o MagLev	9
2.3.1 - Técnicas de Compensação para Projetos de Controladores	9
2.3.2 - Controlador Projetado para o MagLev	15
3 - Simulação Computacional de Redes Neurais Artificiais (RNA)	21
3.1 - Técnica de Modelamento de RNA Utilizando o Programa MatLab	21
3.2 - Algoritmo Back-Propagation Original e suas Derivações	24
3.3 - Comparação entre as Derivações do Algoritmo Back-Propagation	29
3.4 - Simulação Computacional de RNA para o Controle do Plasma no ETE	37
4 - Conclusões e Perspectivas	39
Referências Bibliográficas	40
Apêndice A - Tabela de Medidas de Campo Magnético no MagLev	43
Apêndice B - Tabelas de Controle Clássico	44
Apêndice C - Listagem dos Programas Utilizados para a Simulação das RNA na Linguagem do Programa MatLab	45
Apêndice D - Tabelas de Treinamento, Validação e Teste da RNA para o ETE	46

RESUMO

Este projeto de pesquisa compreende o projeto e a utilização de Redes Neurais Artificiais (RNA) na reconstrução magnética do equilíbrio do plasma de tokamaks, obtidos através de sondas magnéticas inseridas no interior da câmara de vácuo, que fornecerão informações sobre a posição da coluna de plasma para o sistema de controle do campo magnético vertical. O sistema de controle do campo magnético vertical deverá comandar os amplificadores de alta potência que deverão atuar sobre as bobinas magnéticas de controle de equilíbrio e conformação com o intuito de reposicionar a coluna de plasma do Experimento Tokamak Esférico (ETE), em operação desde novembro de 2000, no Laboratório Associado de Plasma (LAP) do Instituto Nacional de Pesquisas Espaciais (INPE) em São José dos Campos, São Paulo.

Para testar os conceitos envolvidos no projeto de RNA no controle da posição do plasma em tokamaks, foi projetado e construído um sistema de Levitação Magnética (MagLev). Este sistema permite simular o comportamento não-linear controlado por um controlador neural.

SUMÁRIO

1 - Introdução	1
2 - Teoria de Controle Clássico e Estudo da Estabilidade Aplicadas ao Levitador Magnético (MagLev)	3
2.1 - Conceitos e Técnicas da Teoria de Controle Clássico	3
2.2 - Lugar Geométrico das Raízes e Análise da Estabilidade no Domínio do Tempo e da Frequência	6
2.3 - Projeto do Controlador para o MagLev	9
2.3.1 - Técnicas de Compensação para Projetos de Controladores	9
2.3.2 - Controlador Projetado para o MagLev	15
3 - Simulação Computacional de Redes Neurais Artificiais (RNA)	21
3.1 - Técnica de Modelamento de RNA Utilizando o Programa MatLab	21
3.2 - Algoritmo Back-Propagation Original e suas Derivações	24
3.3 - Comparação entre as Derivações do Algoritmo Back-Propagation	29
3.4 - Simulação Computacional de RNA para o Controle do Plasma no ETE	37
4 - Conclusões e Perspectivas	39
Referências Bibliográficas	40
Apêndice A - Tabela de Medidas de Campo Magnético no MagLev	43
Apêndice B - Tabelas de Controle Clássico	44
Apêndice C - Listagem dos Programas Utilizados para a Simulação das RNA na Linguagem do Programa MatLab	45
Apêndice D - Tabelas de Treinamento, Validação e Teste da RNA para o ETE	46
Apêndice E - Prestação de Contas da Reserva Técnica	47

1. Introdução

Este relatório é referente aos primeiros seis meses do quarto período da bolsa de doutorado da FAPESP (setembro de 2001 à março de 2002).

Durante este período foi realizada uma análise do comportamento de estabilidade do Levitador Magnético (MagLev) utilizando técnicas de controle clássico. Foi estudado o comportamento do MagLev no domínio do tempo e da frequência. Durante este período também foram realizadas medidas de campo magnético na região de levitação magnética do MagLev (Apêndice A). Ainda neste período, foram realizadas simulações computacionais de Redes Neurais Artificiais (RNA) utilizando o programa MATLAB. Com este programa foram realizadas simulações, treinamentos, validações e testes de RNA para o controle do tokamak ETE, utilizando as simulações de equilíbrio de plasmas realizadas no programa TOPEOL, que simulam as primeiras descargas com plasma do ETE e que foram apresentadas no relatório passado (Terceiro Relatório). Antes de escolher o melhor método de treinamento de RNA, foi feita uma comparação entre os tipos de modificações/derivações do algoritmo de treinamento *Back-Propagation*. Foram observados oito diferentes tipos de derivações do algoritmo, comparando suas vantagens e desvantagens em treinamento de RNA. Neste mês (março 2002) finalmente foi possível obter uma cotação de preço para o hardware neural, compatível com o orçamento de reserva técnica que vinha sendo acumulado durante estes períodos, para a aquisição deste equipamento.

O tokamak ETE é uma máquina destinada ao estudo da física de plasmas para a fusão termonuclear controlada, que está em operação desde novembro de 2000 no Laboratório Associado de Plasmas (LAP) no Instituto Nacional de Pesquisas Espaciais (INPE) na cidade de São José dos Campos - SP.

Durante o período da bolsa, haverá um maior aprofundamento e a descrição detalhada do sistema de controle da posição do plasma em tokamaks utilizando a técnica de Redes Neurais Artificiais e sua aplicação no tokamak ETE.

No decorrer deste relatório, tem-se:

No capítulo II é apresentado o estudo do comportamento do sistema de Levitação Magnética sob o ponto de vista de controle clássico. São relembrados os conceitos e critérios de estabilidades, construção e análise do Lugar Geométrico das Raízes, os efeitos dos movimentos e inclusões de Pólos e Zeros. É feita uma análise de compensadores para controladores automáticos e o projeto de um controlador deste tipo para o MagLev.

No capítulo III são apresentadas as simulações computacionais de RNA utilizando o programa MATLAB. São apresentadas as técnicas de modelamento de RNA no MATLAB e os tipos de derivações do algoritmo *Back-Propagation*. São apresentados os resultados das comparações entre as derivações do algoritmo *Back-Propagation*, mostrando qual tem o melhor tempo de treinamento e melhor precisão de saída, para RNA do tipo Feedforward e Multi-Camadas. São observadas também, as simulações, treinamento, validação e testes das RNA para conjuntos de entrada-saída-alvo das simulações do equilíbrio de plasma no ETE para os primeiros sinais de disparo utilizando o programa TOPEOL.

No capítulo IV são apresentadas conclusões e perspectivas futuras para a conclusão do projeto de pesquisa.

No apêndice A tem-se a tabela de medida de campo magnético para as posições de levitação da casca esférica no MagLev.

No apêndice B tem-se as tabelas de Controle Clássico, mostrando a estabilidade relacionada com o lugar geométrico das raízes entre outras.

No apêndice C tem-se as tabelas de simulação de equilíbrio de plasma no ETE utilizadas nas simulações de RNA .

No apêndice D tem-se a listagem dos programas utilizados nas simulações de RNA com o programa MATLAB.

2. Teoria de Controle Clássico e Estudo de Estabilidade Aplicadas ao Levitador Magnético (MagLev)

2.1. Conceitos e Técnicas de Teoria de Controle Clássico^[01-08]

No início do funcionamento do Levitador Magnético^[01-03] foi utilizado um sistema de controle bastante simples (Figura 1), baseado na realimentação dos sensores de posição sem a colocação de um compensador tradicional (avanço de fase, atraso de fase ou avanço-atraso). Como já era esperado, o sistema apresentava um comportamento instável. A instabilidade do sistema foi estudada com o auxílio da teoria de controle clássico, a fim de mostrar a complexidade em se projetar um controlador para atuar em um sistema não-linear simples, como é o caso do MagLev.

A seguir serão lembrados alguns conceitos da teoria de controle clássica e a aplicação desta teoria no caso do controlador automático para o MagLev. Ficará claro no decorrer deste capítulo a dificuldade em se projetar um sistema de controle não-linear de ordem elevada, quando comparado a um projeto que utiliza um controlador neural, capaz de empregar as técnicas de controle de redes neurais artificiais.

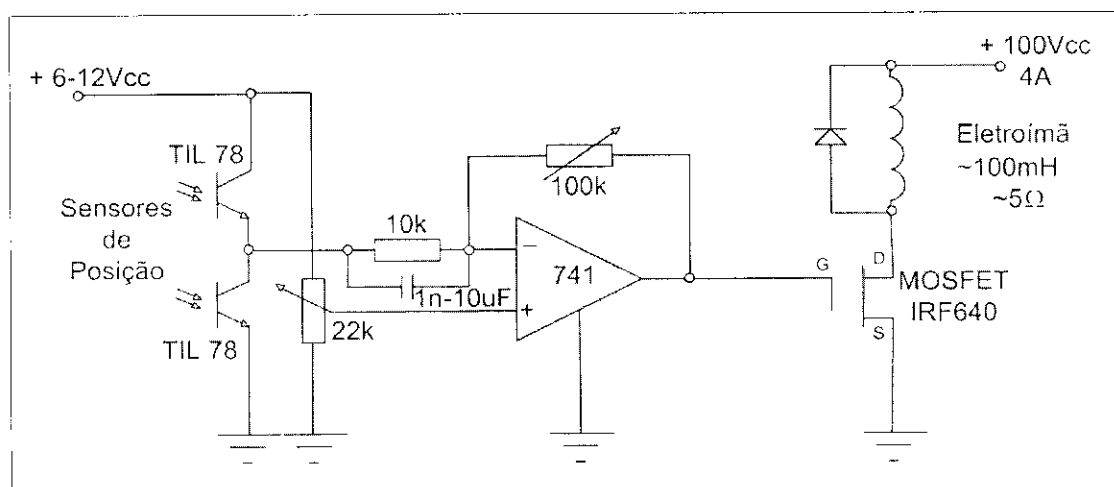


Fig.1 - Sistema de controle do MagLev sem compensador e com regiões de instabilidades

Para projetar um sistema de controle é necessário prever o comportamento dinâmico do sistema, a partir do conhecimento dos efeitos físicos envolvidos. A característica mais importante do comportamento dinâmico de um sistema de controle é a estabilidade absoluta, que diz se o sistema é estável ou instável.

Um sistema é estável quando, aplicada uma perturbação, o mesmo retorna ao estado de equilíbrio inicial na saída. Um sistema é instável quando a saída diverge sem limite, a partir do seu estado de equilíbrio anterior à aplicação de uma perturbação.

A teoria de controle clássico surge das especificações ou requisitos de desempenho do sistema a ser controlado. Geralmente estão relacionados com a precisão relativa, estabilidade relativa e velocidade de resposta.

A partir do modelamento do efeito físico em equações dinâmicas é possível iniciar o estudo de estabilidade. Quando o sistema é não-linear pode-se linearizar as equações dinâmicas do sistema, para um ponto ou faixa operacional, através da utilização da expansão em séries. Aplicando a transformada de Laplace nas equações linearizadas é possível construir o diagrama de blocos do sistema. Com este diagrama

do sistema pode-se obter a equação característica do sistema. Com esta equação é possível utilizar o método do Lugar Geométrico das Raízes (LGR) para verificar a estabilidade do sistema, através da posição dos pólos e zeros no plano complexo $G(s)$. Desta forma, é possível então obter a resposta transitória ou em frequência. Observa-se que através da verificação das posições dos pólos e zeros pode-se dizer se o sistema é ou não estável. Caso o sistema não seja estável é possível modificar o LGR com a inclusão ou cancelamento de pólos e zeros, utilizando compensadores projetados para satisfazer as especificações de desempenho do sistema.

O desempenho de um sistema no domínio do tempo é dividido em análise do desempenho transitório e estacionário. O desempenho transitório de um sistema de controle é a parte mais crítica e geralmente é caracterizado para uma entrada do tipo função degrau unitário. Para caracterizar a resposta transitória de um sistema são utilizados critérios típicos de desempenho, tais como, nível de sobressinal (*overshoot*), tempo de atraso (*delay time*), tempo de subida (*rise time*) e tempo de acomodação (*settling time*). A Figura 2 ilustra uma resposta a uma função do tipo degrau unitário, e os critérios de desempenho.




Fig.2 - Critérios de desempenho de um sistema de controle

Os critérios de desempenho são definidos como:

- Sobressinal máximo - é definido como o maior desvio da saída para a entrada da função degrau unitário durante o transitório. O sobressinal máximo também é utilizado para medir a estabilidade relativa do sistema;
- Tempo de atraso (T_d) - é definido como sendo o tempo necessário para a resposta ao degrau unitário atingir 50% do seu valor final;
- Tempo de subida (T_s) - é definido como sendo o tempo necessário para a resposta ao degrau unitário suba de 10-90% do seu valor final;
- Tempo de acomodação (T_a) - é definido como sendo o tempo necessário para a resposta ao degrau unitário decrescer e permanecer dentro de uma faixa específica do seu valor final, representado em porcentagem este valor é tipicamente 5%.

O desenvolvimento da teoria de controle linear permite o estudo do desempenho de sistemas de controle a partir da função de transferência e da equação característica, dada por:

$$\frac{C(s)}{R(s)} = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (01)$$

A equação característica é:

$$\Delta = s^2 + 2\zeta\omega_n s + \omega_n^2 = 0 \quad (02)$$

Para $R(s) = 1/s$:

$$C(s) = \frac{\omega_n^2}{s(s^2 + 2\zeta\omega_n s + \omega_n^2)} \quad (03)$$

A transformada inversa de Laplace em $C(s)$ é:

$$c(t) = 1 + \frac{e^{-\zeta\omega_n t}}{\sqrt{1-\zeta^2}} \operatorname{sen} \left[\omega_n \sqrt{1-\zeta^2} t - \tan^{-1} \frac{\sqrt{1-\zeta^2}}{-\zeta} \right] \quad t \geq 0 \quad (04)$$

As raízes são:

$$s_1, s_2 = -\zeta\omega_n \pm j\omega_n \sqrt{1-\zeta^2} = -\alpha \pm j\omega \quad (05)$$

O significado físico destas constantes é definido como sendo:

α é a constante responsável pelo controle da taxa de subida e decaimento da resposta temporal, $\alpha = \zeta\omega_n$. Como α controla o amortecimento do sistema é conhecida como a "constante de amortecimento" ou "fator de amortecimento", que representa a parte real das raízes;

ζ é a constante que classifica o tipo de amortecimento do sistema (ver Apêndice B), conforme o tipo de raízes do sistema. Observa-se que para raízes reais iguais e idênticas o sistema é criticamente amortecido e $\zeta = 1$. ζ é chamado de "taxa de amortecimento", que na verdade é a relação entre o fator de amortecimento real e o fator de amortecimento quando o amortecimento é crítico. Observa-se que $\zeta = \cos\theta$;

ω_n é definido como sendo a "frequência natural não-amortecida" do sistema. ω_n é a distância radial das raízes até a origem do plano complexo $G(s)$, como pode ser visto no Apêndice B;

ω é definida como sendo uma frequência condicional dada por $\omega = \omega_n \sqrt{1-\zeta^2}$. Esta frequência condicional representa a parte imaginária das raízes;

A partir destas diretrizes de controle e critérios de desempenho é possível então aplicar as técnicas da teoria de controle, tais como, o LGR e os métodos de análise de estabilidade.

2.2. Lugar Geométrico das Raízes e Análise da Estabilidade no Domínio do Tempo e da Freqüência^[04-13]

A característica básica da resposta transitória de um sistema de malha fechada é determinada a partir da localização dos pólos. Na verdade o interesse está na possibilidade de ajustar os pólos e zeros de uma malha aberta, de forma a posicionar os pólos de malha fechada nos locais desejados no plano complexo $G(s)$.

Os pólos de malha fechada são as raízes da equação característica. Para calcular e determinar os pólos é necessário fatorar o polinômio característico. Um método simples de fazê-lo, e que é extensamente utilizado na engenharia de controle, é a utilização do método do Lugar Geométrico das Raízes ou *Root Locus*.^[09-12] Com este método as raízes são colocadas em um plano complexo $G(s)$.

A função de transferência de malha fechada é dada por:

$$\frac{C(s)}{R(s)} = \frac{G(s)}{1 + G(s)H(s)} \quad (06)$$

Para se obter a equação característica a partir da Eq.06, iguala-se o denominador do membro a direita a zero, de forma que:

$$1 + G(s)H(s) = 0 \quad (07)$$

ou

$$G(s)H(s) = -1 \quad (08)$$

As raízes da equação característica, as quais correspondem a um determinado valor de ganho K , podem ser escritas da seguinte forma:

$$1 + \frac{K(s + z_1)(s + z_2).....(s + z_m)}{(s + p_1)(s + p_2).....(s + p_n)} = 0 \quad (09)$$

onde:

z - são zeros estão localizados no numerador;

p - são pólos estão localizados no denominador.

$$1 + K \frac{\text{zeros}}{\text{pólos}} \quad (10)$$

Na Figura 3 pode-se observar o LGR para a Eq.02, quando ω_n se mantém constante e ζ varia de $-\infty$ a $+\infty$.




Fig.3 - LGR para $\Delta = s^2 + 2\zeta\omega_n s + \omega_n^2 = 0$

Para obter a estabilidade em sistemas que são instáveis, utilizando LGR deve-se adicionar pólos e/ou zeros, de forma que o LGR se modifique. Ao adicionar um pólo a uma função $G(s)H(s)$ o efeito observado é o deslocamento do lugar geométrico das raízes originais em direção do semiplano direito do plano complexo. O que geralmente tende a piorar a estabilidade relativa do sistema. Ao adicionar um zero a uma função $G(s)H(s)$ o efeito observado é o deslocamento do lugar geométrico das raízes originais em direção do semiplano esquerdo. O que geralmente melhora a estabilidade relativa de um sistema (ver efeitos de pólos e zeros no Apêndice B).

A análise da estabilidade de sistemas de controle lineares ou linearizados pode ser obtida pelo estudo das posições das raízes, ou por outros métodos, invariantes no tempo, tais como, *Crítério de Routh-Hurwitz* (algébrico), *Crítério de Nyquist* (semigráfico) e *Diagrama de Bode* (gráfico). Existe também o *Crítério de Estabilidade de Lyapunov* (gráfico) para sistemas não-lineares de qualquer ordem e variantes no tempo.

Em um breve resumo serão explicados estes métodos, assim como foi feito para o método do LGR.

- *Crítério de Routh-Hurwitz*^[13] é um método para determinação da posição dos zeros de um polinômio com coeficientes reais constantes em relação aos semiplanos direito e esquerdo do plano complexo s , sem determinar explicitamente estes zeros. Pode ser aplicado em sistemas lineares com várias entradas e várias saídas.

Para que não hajam raízes com parte real positiva é necessário observar se todos os coeficientes do polinômio tem o mesmo sinal, e que nenhum dos seus coeficientes sejam nulos, mesmo assim, isto não garante que o polinômio não tenha um zero no semiplano direito do plano complexo s . O método é algébrico e trabalha com a construção e análise de uma tabulação (tabulação de *Routh*) que contém os coeficientes do polinômio. Através da investigação dos sinais dos elementos da primeira coluna da tabela é possível determinar a estabilidade do sistema. Se todos os elementos da primeira coluna da tabulação de *Routh* tem o mesmo sinal isto significa que todas as raízes do polinômio estão no semiplano esquerdo do plano complexo s . Se houver a troca de sinais nos elementos da primeira coluna, o número de troca de sinais indica o número de raízes com parte real positiva, indicando que o sistema é instável.

- *Crítério de Nyquist*^[04,07-08] é um método no domínio da frequência que fornece informação sobre a estabilidade absoluta do sistema de controle, indica o grau de estabilidade, e mostra como a estabilidade do sistema pode vir a ser melhorada. Este método também pode ser modificado para sistemas não-lineares. O critério de *Nyquist* representa sistemas lineares ou linearizados invariantes no tempo. A estabilidade é obtida ao analisar os envoltimentos das raízes pela curva de *Nyquist* no plano complexo s (ver Apêndice B) princípio de agrupamento e curva de *Nyquist*.

O critério de *Nyquist* pode ser expresso como:

$$Z = N + P \quad (11)$$

onde:

Z = número de zeros de $1-G(s)H(s)$ no semiplano direito do plano complexo s ;

N = número de envoltimentos no sentido horário do ponto $-1 + j0$;

P = número de pólos de $G(s)H(s)$ no semiplano direito do plano complexo s .

Para um sistema estável, onde P não é zero (pólos no semiplano direito), $Z = 0$ ou $N = -P$, isto significa que o sistema de controle precisa ter P envoltimentos no sentido anti-horário do ponto $-1 + j0$. Se $G(s)H(s)$ não possui nenhum pólo no semiplano direito do plano complexo s , é preciso que $Z = N$ para que haja estabilidade.

- O Diagrama de *Bode*^[04, 07-08] é composto por dois gráficos. O gráfico logaritmo da função de transferência e o gráfico relacionando ângulo e fase, onde ambos são gerados contra a frequência em escala logarítmica.

Existe uma relação entre a taxa de amortecimento ζ e as assíntotas representadas no diagrama de *Bode* (ver curvas do diagrama de *Bode* no Apêndice B) A observação das inclinações das assíntotas mostra o fator de amortecimento do sistema, que mostra se o sistema é ou não estável.

- O Critério de estabilidade de *Lyapunov*,^[07] conhecido também como o segundo método de *Lyapunov*. Aplicado em sistemas não-lineares de qualquer ordem, com este critério pode-se determinar a estabilidade do sistema sem resolver as equações de estado. Este método gráfico adota uma região esférica (ver gráfico de *Lyapunov* no Apêndice B) que engloba um determinado estado de equilíbrio de um sistema. Como pode ser visto na Eq.12,

$$\|X - X_e\| \leq k \quad (12)$$

sendo

$$f(X_e, t) = 0 \quad (13)$$

onde $\|X - X_e\|$ é chamada de norma Euclidiana e definida como sendo:

$$\|X - X_e\| = \left[(x_1 - x_{1e})^2 + (x_2 - x_{2e})^2 + \dots + (x_n - x_{ne})^2 \right]^{1/2} \quad (14)$$

Fazendo $S(\delta)$ consistir de todos os pontos tais que:

$$\|X_0 - X_e\| \leq \delta \quad (15)$$

onde $X_0 = \phi(t; X_0, t_0)$, de maneira que $S(e)$ para o conjunto de todos os pontos seja:

$$\|\phi(t; X_0, t_0) - X_e\| \leq e \quad \text{para todo } t \geq t_0 \quad (16)$$

Um estado de equilíbrio X_e é dito estável se para cada $S(e)$ há um $S(\delta)$, tal que as trajetórias que partem de $S(\delta)$ não saem de $S(e)$, quando t aumenta indefinidamente. Assim sendo, inicialmente deve-se escolher a região $S(e)$, de forma que para cada $S(e)$ deve existir uma região $S(\delta)$ tal que as trajetórias que saem de $S(\delta)$ não abandonem $S(e)$ quando t aumenta (ver estas regiões em gráfico de *Lyapunov* no Apêndice B).

Estas técnicas de análise de estabilidade de sistemas de controle visam auxiliar no projeto de construção de controladores automáticos que utilizam as técnicas de compensação, embutidas nos controladores tradicionais baseados em integração e derivação. Conhecidos como controlador Proporcional Derivativo (PD), Proporcional Integral (PI) e o Proporcional Integral Derivativo (PID). A seguir serão apresentados estes controladores, os tipos de compensadores, e a utilização destes no projeto do controlador do MagLev.

2.3. Projeto do Controlador para o MagLev^[01-08, 14-20]

2.3.1 - Técnicas de Compensação para Projetos de Controladores^[04-08, 15,17]

Em geral a dinâmica de um sistema controlado pode ser representada pelo diagrama de blocos. Este diagrama permite visualizar o sistema como um todo, mostrando a entrada, saída, as perturbações e as dependências das partes que compõem o sistema. No Apêndice B podem ser observadas as configurações típicas para as posições dos controladores no diagrama de blocos.

O tipo de controlador mais comum é o de "*controle proporcional*", ou seja, utiliza-se uma constante proporcional que relaciona o sinal de saída com o sinal de entrada. Este tipo de controlador utiliza operações algébricas simples como adição e subtração, além de ser capaz de derivar ou integrar um sinal no tempo. Para tanto pode-se utilizar somadores, amplificadores, atenuadores, diferenciadores e integradores. Cabe ao projetista do controlador analisar o desempenho do sistema a ser controlado, a fim de escolher quais destes componentes devem ser empregados no controlador.

Como foi dito anteriormente, os controladores mais utilizados na prática são, *Controlador Proporcional-Derivativo* (PD), *Controlador Proporcional-Integral* (PI) e o *Controlador Proporcional-Integral-Derivativo* (PID).

• *Controlador Proporcional-Derivativo* (PD)

Função de transferência do controlador PD é:

$$G_c(s) = K_p + K_D s \quad (17)$$

A Figura 4, ilustra o diagrama de blocos de um sistema de controle utilizando uma controlador do tipo PD.

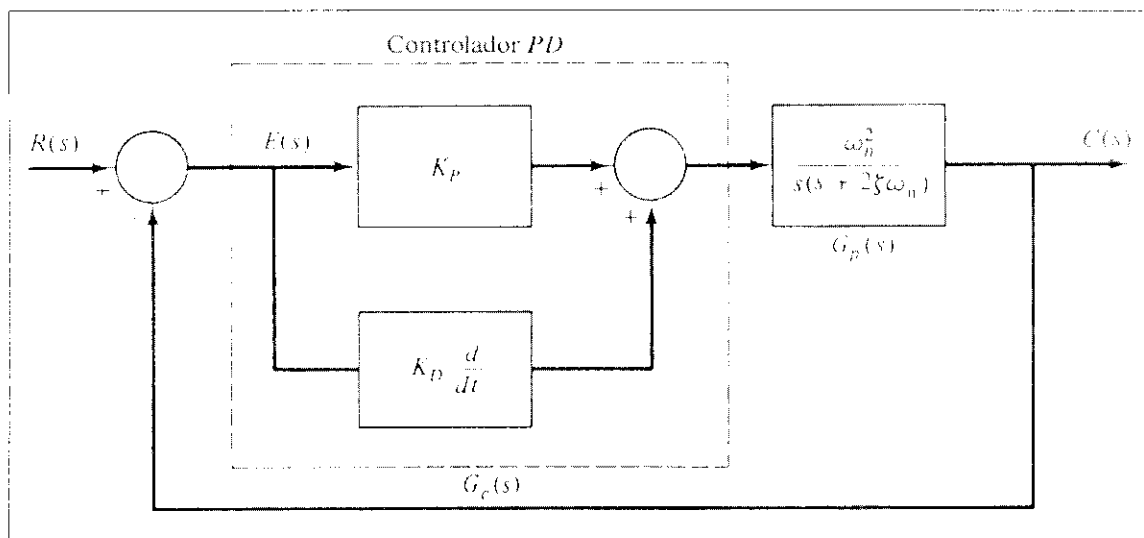


Fig.4 - Controlador PD

O comportamento do controle derivativo é equivalente à adição de um zero simples em $s = -K_p/K_D$ na função de transferência.

O controle derivativo funciona como um controle antecipativo, atuando no controle do erro em regime estacionário toda vez que o erro variar no tempo.

- *Controlador Proporcional-Integral (PI)*

Função de transferência do controlador PI é:

$$G_c(s) = K_p + \frac{K_I}{s} \quad (18)$$

A Figura 5 ilustra o diagrama de blocos de um sistema de controle utilizando uma controlador do tipo PI.

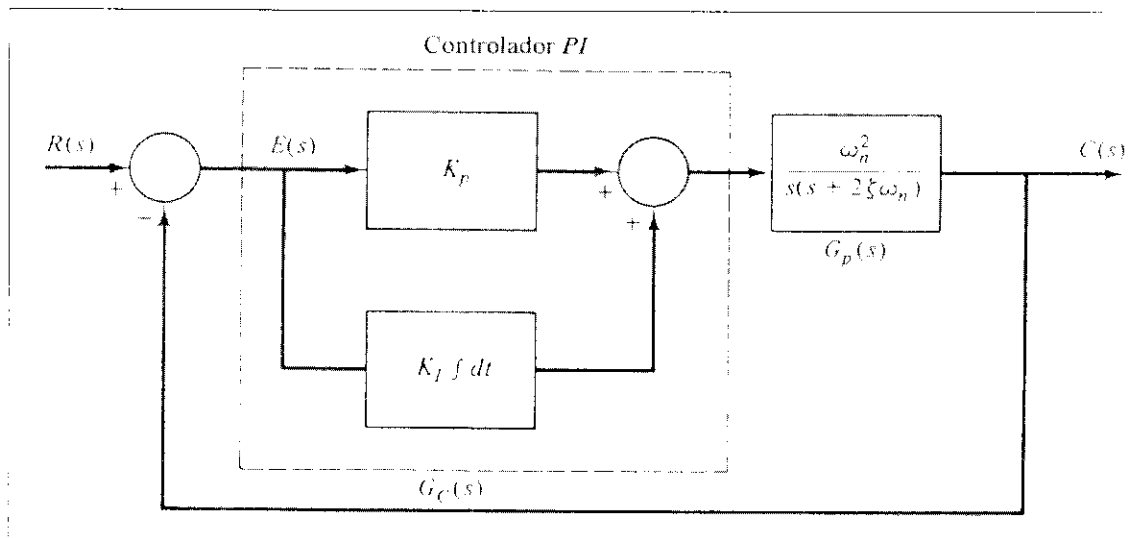


Fig.5 - Controlador PI

O controlador proporcional integral equivale à adição de um zero em $s = K_I/K_p$ e um pólo em $s=0$. O efeito óbvio deste tipo de controlador é que o mesmo aumenta o sistema em uma ordem. Isto faz com que este tipo de controlador possa reduzir a zero o erro estacionário do sistema, se o mesmo for constante para o sistema quando estável.

• *Controlador Proporcional-Integral-Derivativo (PID)*

Função de transferência do controlador PID é:

$$G_c(s) = K_p + K_D s + \frac{K_I}{s} \quad (19)$$

A Figura 6 ilustra o diagrama de blocos de um sistema de controle utilizando um controlador do tipo PID.

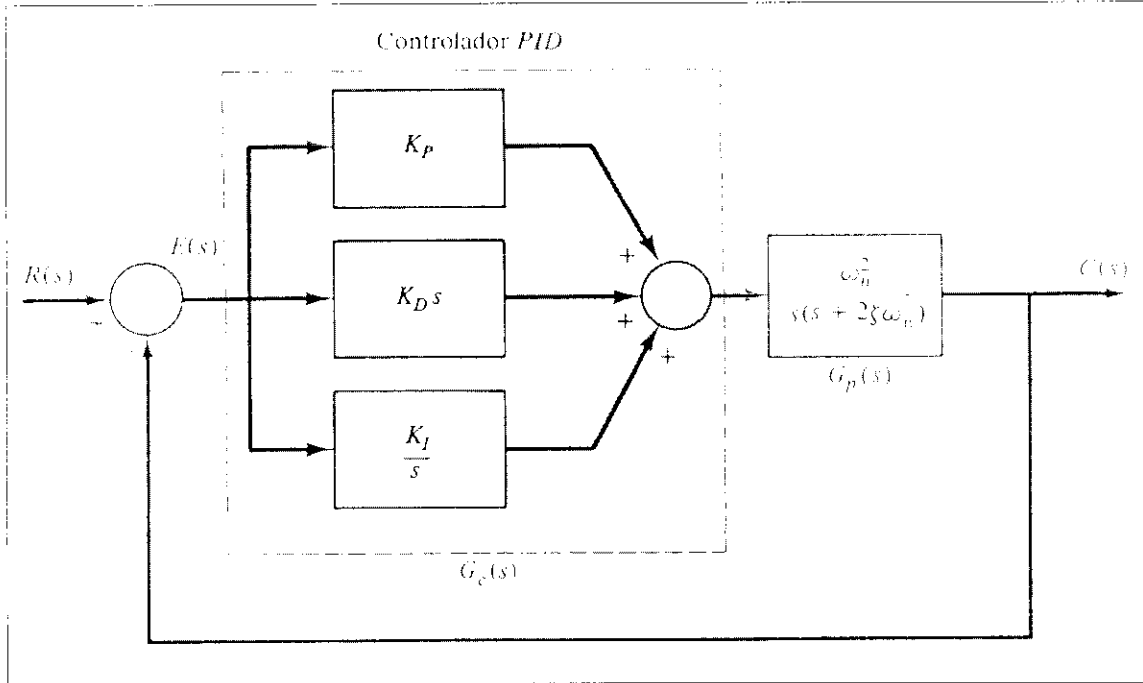


Fig.6 - Controlador PID

A grande vantagem deste tipo de controlador é que ele combina as propriedades dos controladores Integral e Derivativo, proporcionando a utilização de suas vantagens na estabilidade do sistema a ser controlado. Entretanto os valores escolhidos para as constantes K_D , K_p e K_I , também chamadas de parâmetros do controlador, devem ser tais que não tornem o sistema suscetível a instabilidades.

Os controladores dos tipos PD, PI e PID são considerados como a forma mais simples entre os controladores que utilizam operações de integração e derivação para compensar sistemas de controle. Em geral pode-se considerar o projeto de controladores como um problema de filtragem ou projeto de filtros. Para descrever este tipo de controlador é necessário conhecer o LGR, e assim utilizar os pólos e zeros da função de transferência para estabilizar o sistema.

Para um controlador PD a função de transferência tem um zero em $s = -K_p/K_D$;

Para um controlador PI a função de transferência tem um pólo em $s=0$ e um zero em $s = K_I/K_p$;

Para um controlador PID a função de transferência tem um pólo em $s=0$ e dois zeros obtidos da função $K_D s^2 + K_p s + K_I$.

Do ponto de vista de filtragem, o controlador do tipo PD é um filtro Passa-Alta, o controlador do tipo PI é um filtro Passa-Baixa e o controlador do tipo PID é um filtro Banda-Passante ou Banda-Atenuada, dependendo dos parâmetros do controlador.

O Filtro Passa-Alta é frequentemente referido como sendo um controlador de "Avanço de Fase", pois é introduzida uma fase positiva no sistema de controle.

O Filtro Passa-Baixa é frequentemente referido como sendo um controlador de "Atraso de Fase" (redução de ganho), pois é introduzida uma fase negativa no sistema de controle.

O Filtro Banda-Passante é frequentemente referido como sendo um controlador de "Avanço-Atraso de Fase", pois explora as características de introdução de uma fase positiva e uma negativa no sistema de controle.

A grande vantagem de utilizar estes tipos de compensadores (Avanço de Fase, Atraso de Fase e Avanço-Atraso de Fase) em controladores está no fato que os elementos atuantes no circuito são componentes elétricos passivos (resistores e capacitores).

A função de transferência de compensadores dos tipos Avanço de Fase e Atraso de Fase é:

$$G_c(s) = \frac{s + Z}{s + P} \quad (20)$$

$P > Z$ - Filtro Passa-Alta controlador de Avanço de Fase;

$P < Z$ - Filtro Passa-Baixa controlador de Atraso de Fase.

• Controlador de Avanço de Fase

Para controladores de avanço de fase a função de transferência do circuito é obtida quando se supõe que a impedância da fonte vista pelos terminais do circuito é zero e a impedância da carga na saída é infinita, conforme pode ser observado na Figura 7.




Fig.7 - Circuito compensador Avanço de Fase

Observando a Figura 7 é possível obter a função de transferência deste tipo de compensador, como pode ser visto a seguir:

$$\frac{E_2(s)}{E_1(s)} = \frac{R_2 + R_1 R_2 C s}{R_1 + R_2 + R_1 R_2 C s} = \frac{R_2}{R_1 + R_2} \cdot \frac{1 + R_1 C s}{1 + \frac{R_1 R_2}{R_1 + R_2} C s} \quad (21)$$

utilizando:

$$a = \frac{R_1 + R_2}{R_2} \quad a > 1 \quad (22)$$

e

$$T = \frac{R_1 R_2}{R_1 + R_2} C \quad (23)$$

$$G_C(s) = \frac{E_2(s)}{E_1(s)} = \frac{s + aTs}{s + Ts} \quad a > 1 \quad (24)$$

Assim sendo, para esta função de transferência tem-se um zero real em $s = -1/aT$ e um pólo real em $s = -1/T$, conforme a Figura 8.




Fig.8 - Localização do pólo e do zero de um compensador de Avanço de Fase

• Controlador de Atraso de Fase

Para controladores de atraso de fase a função de transferência do circuito é obtida da mesma forma que para o controlador de avanço de fase, conforme pode ser observado na Figura 9.




Fig.9 - Circuito compensador Atraso de Fase

Observando a Figura 9 é possível obter a função de transferência deste tipo de compensador, como pode ser visto a seguir:

$$\frac{E_2(s)}{E_1(s)} = \frac{1 + R_2Cs}{1 + (R_1 + R_2)Cs} \quad (25)$$

utilizando:

$$aT = R_2C \quad (26)$$

e

$$a = \frac{R_2}{R_1 + R_2} \quad a < 1 \quad (27)$$

$$G_c(s) = \frac{E_2(s)}{E_1(s)} = \frac{1 + aTs}{1 + Ts} \quad a < 1 \quad (28)$$

Assim sendo, para esta função de transferência tem-se um zero real em $s = -1/aT$ e um pólo real em $s = -1/T$, conforme a Figura 10.




Fig.10 - Localização do pólo e do zero de um compensador de Atraso de Fase

- *Controlador de Avanço-Atraso de Fase*

Para controladores de atraso de fase a função de transferência do circuito é obtida da mesma forma que para o controlador de avanço de fase, conforme pode ser observado na Figura 11.




Fig.11 - Circuito compensador Avanço-Atraso de Fase

Observando a Figura 11 é possível obter a função de transferência deste tipo de compensador, como pode ser visto a seguir:

$$\frac{E_2(s)}{E_1(s)} = \frac{(1 + R_1 C_1 s)(1 + R_2 C_2 s)}{1 + (R_1 C_1 + R_1 C_2 + R_2 C_2)s + R_1 R_2 C_1 C_2 s^2} \quad (29)$$

utilizando:

$$aT_1 = R_1 C_1 \quad (30)$$

$$bT_2 = R_2 C_2 \quad (31)$$

$$T_1 T_2 = R_1 R_2 C_1 C_2 \quad (32)$$

tem-se:

$$G_c(s) = \frac{E_2(s)}{E_1(s)} = \left(\frac{1 + aT_1 s}{1 + T_1 s} \right) \left(\frac{1 + bT_2 s}{1 + T_2 s} \right) \quad a > 1 \text{ e } b < 1 \quad (33)$$

avanço atraso

2.3.2 - Controlador Projetado para o MagLev^[01-08, 15, 17]

O controlador projetado para o MagLev é um controlador do tipo Atraso de Fase. Este tipo de controlador foi escolhido conforme a análise de estabilidade do sistema, onde foi executado apenas o método do LGR, descrito anteriormente, para a análise da estabilidade segundo a teoria clássica de controle.

A seguir serão executados os passos de projetos de controladores automáticos, para uma malha fechada de controle não-linear, como é o caso do MagLev.

A partindo da análise física do sistema do MagLev obtém-se as equações dinâmicas deste sistema. Ao observar a força magnética exercida sobre a casca esférica de metal utilizada no MagLev, tem-se:

$$f = \frac{i^2}{2} \frac{dL}{dx} \quad (34)$$

A seguir, vai-se determinar a dependência da indutância elétrica do eletroímã com a distância relativa da casca esférica ao núcleo do eletroímã. É possível notar que:

$$L = L_1 + \frac{L_0 x_0}{x} \quad L_1 \rightarrow x = \infty \quad (35)$$

Na Figura 12, a indutância é máxima quando a casca esférica está encostada no eletroímã ($x=0$). Ao afastar a casca esférica do eletroímã o que se observa é que a indutância tem um discreto decréscimo ($\sim 1mH$). Os valores de L para a eq.35 são:

$$L=93mH; L_1=92mH \text{ e } L_0=L(0) - L_1(\infty)=1mH \quad (36)$$




Fig.12 - A relação entre a distância da casca esférica ao eletroímã e o valor da indutância elétrica da bobina do eletroímã

L_0 é uma constante do sistema e x_0 é na verdade o ponto de operação para a levitação magnética da casca esférica. É possível então fazer a substituição da eq.35 na eq.34, conforme se segue

$$f = \frac{1}{2} L_0 x_0 \left(\frac{i}{x} \right)^2 \quad (37)$$

Adotando

$$C = \frac{1}{2} L_0 x_0 \quad (38)$$

tem-se

$$f = C \left(\frac{i}{x} \right)^2 \quad (39)$$

A eq.39 representa a força eletromagnética sobre a casca esférica. A equação diferencial do circuito elétrico do sistema é dada por

$$e = Ri + \frac{d(Li)}{dt} \quad (40)$$

Como x está muito próximo de x_0 , a indutância L pode ser considerada constante sem afetar muito a precisão do sistema. Então a equação do circuito elétrico do sistema é

$$e = Ri + L \frac{di}{dt} \quad (41)$$

onde

e é a tensão elétrica aplicada à bobina do eletroímã,
 R é a resistência elétrica da bobina do eletroímã,
 i é a corrente elétrica aplicada na bobina do eletroímã,
 L é a indutância elétrica da bobina do eletroímã.

A equação do movimento mecânico do sistema para a influência da força gravitacional sobre a casca esférica é dada por

$$m \frac{dx^2}{dt} = mg - f \quad (42)$$

onde

m é a massa da casca esférica,
 g é a força gravitacional,
 f é a força eletromagnética.

Assim sendo, as equações 39, 41 e 42 formam o conjunto das equações dinâmicas do sistema.

Como o sistema dinâmico do MagLev é não-linear, para a aplicação da teoria de controle linear é necessário linearizar as equações dinâmicas do sistema para um ponto operacional previamente conhecido. As equações linearizadas descrevem as variações do ponto de operação obtidas através dos termos lineares da expansão em séries de *Taylor*. As variações do ponto de operação deste sistema são sempre indicadas pelo índice zero e as outras variações da vizinhança pelo índice 1. As equações linearizadas são

$$f_1 = \frac{2Ci_0}{x_0^2} i_1 - \frac{2Ci_0^2}{x_0^3} x_1 \quad (43)$$

$$e = Ri_1 + L \frac{di_1}{dt} \quad (44)$$

$$m \frac{d^2 x_1}{dt^2} = -f_1 \quad (45)$$

isto quando

$$f_0 = mg = C \left(\frac{i_0}{x_0} \right)^2 \quad (46)$$

Aplicando a transformada de Laplace nas equações 43, 44 e 45, tem-se

$$F_1(s) = 2C \frac{i_0}{x_0^2} \left[I_1(s) - \frac{i_0}{x_0} x_1(s) \right] \quad (47)$$

Adotando

$$k + 2C \frac{i_0}{x_0^2} \quad (48)$$

tem-se

$$F_1(s) = k \left[I_1(s) - \frac{i_0}{x_0} x_1(s) \right] \tag{49}$$

$$E_1(s) = (R + Ls) I_1(s) \tag{50}$$

$$mS^2 x_1(s) = -F_1(s) \tag{51}$$

Com as equações 49, 50 e 51 é possível construir o diagrama de blocos do sistema de levitação magnética, conforme pode ser visto na Figura 13.

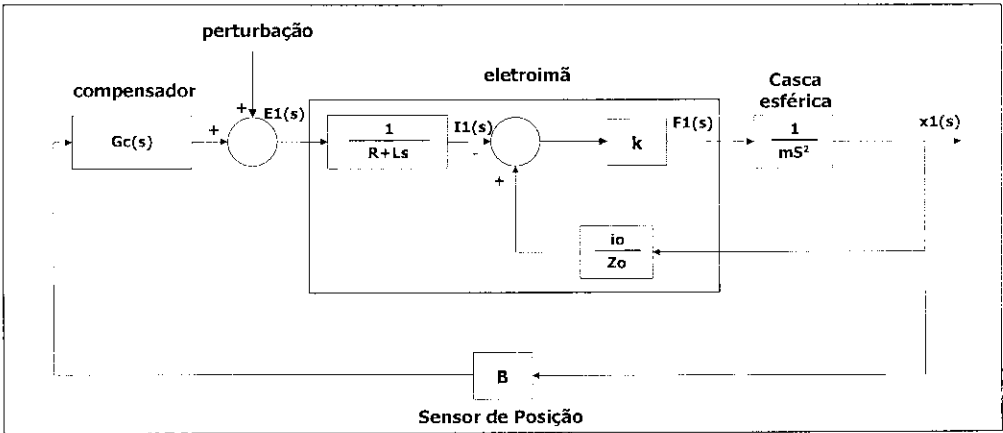


Fig.13- Diagrama de Blocos do sistema de Levitação Magnética

Utilizando o Diagrama de Blocos é possível extrair a equação característica dos sistema de controle para o MagLev.

$$G(s) = x_0 L m S^3 + x_0 R m S^2 - k i_0 L S - k i_0 R + G_c(s) k x_0 B = 0 \tag{52}$$

Como o sistema é instável é necessário analisar o LGR para projetar um controlador específico para este MagLev. Desta forma será necessário calcular o LGR utilizando o programa MATLAB e a Tabela 1.

Tabela 1 - Parâmetros do MagLev

x_0	0,05 m
i_0	4 A
m	0,001 kg
R	5,2 Ω
L	93 mH
C	25 μ N.m ² /A ²
k	0,08 N/A
B	1200 v/m

Reorganizando a eq.52, tem-se:

$$G(s) = 1 + \frac{G_c(s)kx_0B}{x_0LmS^3 + x_0RmS^2 - ki_0LS - ki_0R} = 0 \quad (53)$$

Substituindo os parâmetros da Tabela 1 na eq.53, tem-se:

$$G(s) = 1 + \frac{4.8G_c(s)}{5\mu S^3 + 260\mu S^2 - 30mS - 1,7} = 0 \quad (54)$$

Na Figura 14 observa-se o LGR calculados utilizando o MATLAB.

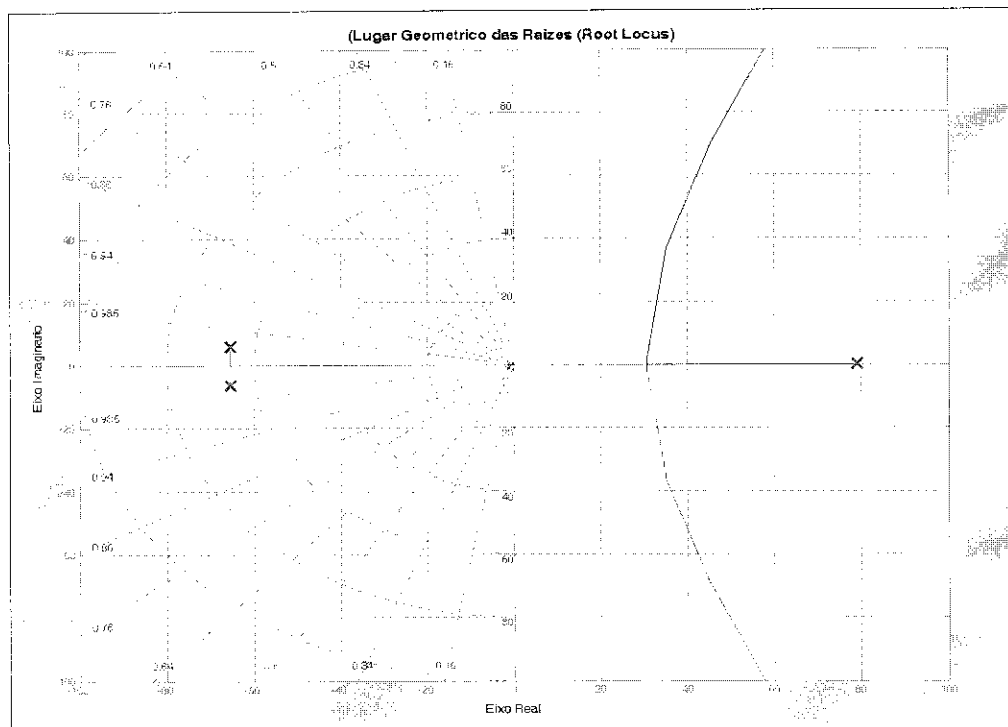


Fig.14 - Lugar Geométrico das Raízes para o MagLev sem compensação

Observa-se que o sistema possui um pólo no semiplano direito em 78,83 e um par de pólos complexos conjugado no semiplano esquerdo em $-65,42 \pm j5,84$.

A técnica de compensação de controle adotada para o MagLev foi a utilização de um compensador do tipo Atraso de Fase. Através de simulação computacional com o MATLAB foi possível escolher o melhor compensador de Atraso de Fase para o sistema, que foi:

$$G_c(s) = k \frac{s + 200}{s + 20} \quad (55)$$

A equação característica do sistema com o compensador permite gerar outro LGR para o sistema com compensação, conforme mostra a Figura 15.

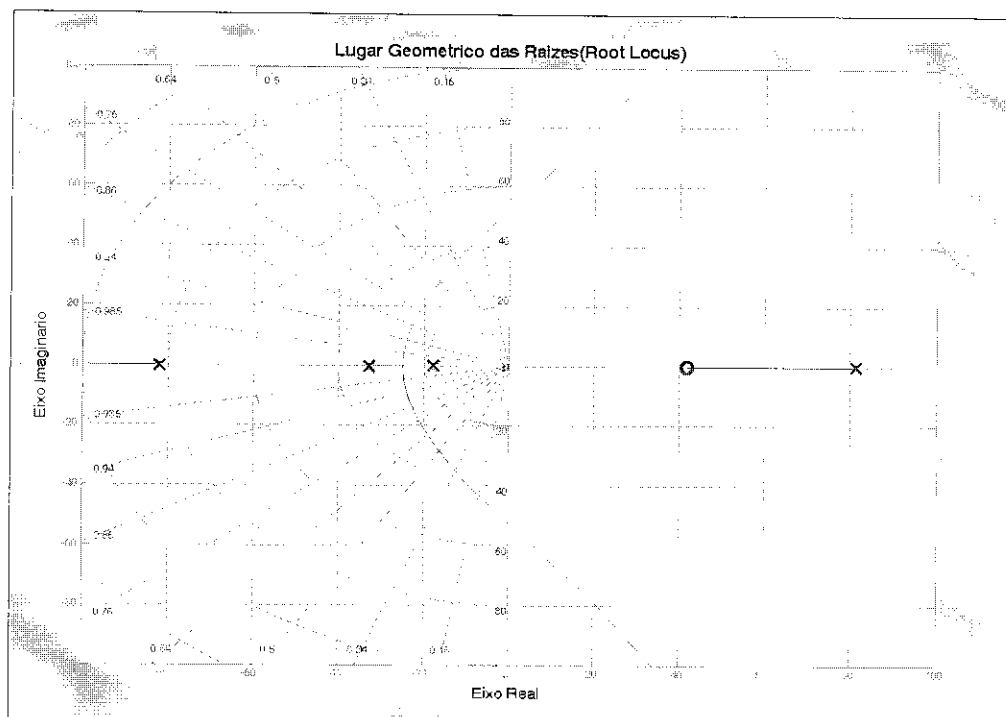


Fig.15 - Lugar Geométrico das Raízes para o MagLev com compensação

Observando o LGR modificado pelo compensador, pode-se notar que a principal diferença está no fato que a curva foi atraída para o semiplano esquerdo estabilizando o sistema para o ponto de operação. O sistema possui um pólo no semiplano direito em 78,83, três pólos no semiplano esquerdo em -81,85, -33,03 e -18,23, além do zero introduzido no semiplano direito em 41,67.

Resta agora a implementação física deste compensador no circuito de controle para mostrar os resultados obtidos na compensação com controlador automático, que serão apresentados em outro relatório.

3. Simulação Computacional de Redes Neurais Artificiais (RNA)

3.1. Técnica de Modelamento de RNA Utilizando o

Programa MATLAB^[21-22]

Existem várias formas de simular RNA em computadores, desde o desenvolvimento completo de um programa específico, escrito em linguagem C++ Fortran, entre outras, ou utilizar pacotes de programas comerciais, desenvolvidos para simulação computacional de RNA. Dentre estes pacotes existe o programa MATLAB (**MATrix LABoratory**), que é um sistema baseado em matrizes, utilizado para cálculos matemáticos aplicados a engenharia. Todos os dados utilizados pelo MATLAB são matrizes, e o programa funciona como uma espécie de linguagem desenvolvida para a manipulação de matrizes. O MATLAB possui um grande número de sub-rotinas chamadas *toolbox*, utilizadas para determinados comandos específicos e para a obtenção de saídas gráficas. Entre os vários *toolbox* existentes para o MATLAB, existe um para a simulação de RNA^[21].

Neste *toolbox* estão incluídas as principais teorias de RNA, tipos de algoritmos de treinamento, funções de transferências, tipos de arquiteturas, entre outros.

A seguir serão discriminados alguns comandos e a forma com que estes comandos são escritos para a simulação da RNA utilizando este programa.

Inicialmente, observa-se na Figura 16 uma ilustração do funcionamento básico de uma RNA. A Figura 17 mostra a representação gráfica do modelamento matemático computacional utilizado pelo MATLAB para representar um neurônio simples.

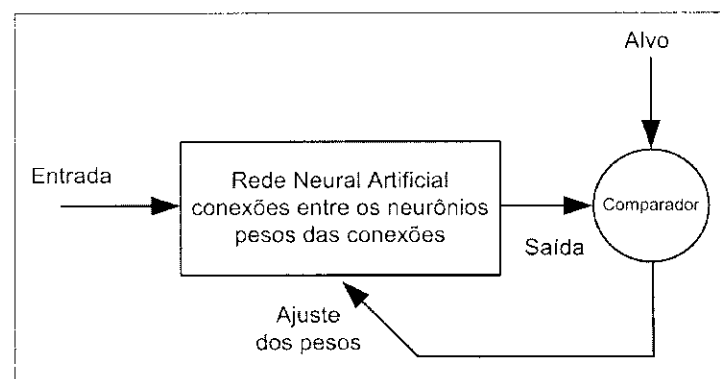


Fig.16 - Esquema básico simplificado de uma RNA

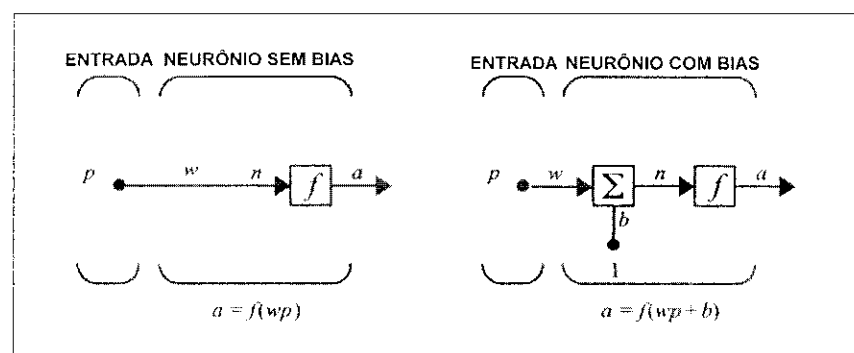


Fig.17 - Representação computacional de um neurônio no MATLAB

As funções de transferências (ativação) típicas para RNA estão disponíveis no MATLAB, e os comandos específicos para cada uma delas estão escritos na Figura 18.




Fig.18 - Representação computacional das Funções de Transferência no MATLAB

Para um neurônio com um entrada do tipo vetor R com P elementos, deve-se configurar cada elemento individual P do vetor R da seguinte forma:

$$P_1, P_2, \dots, P_R \tag{56}$$

que são multiplicados pelos pesos

$$w_{1,1}, w_{1,2}, \dots, w_{1,R} \tag{57}$$

Os quais depois de somados dão origem a matriz W_P , com uma coluna, como pode ser visto na Figura 19.




Fig.19 - Representação de uma entrada do tipo vetor no MATLAB

Para dois ou mais neurônios por camada deve-se representar a RNA no MATLAB conforme a Figura 20.

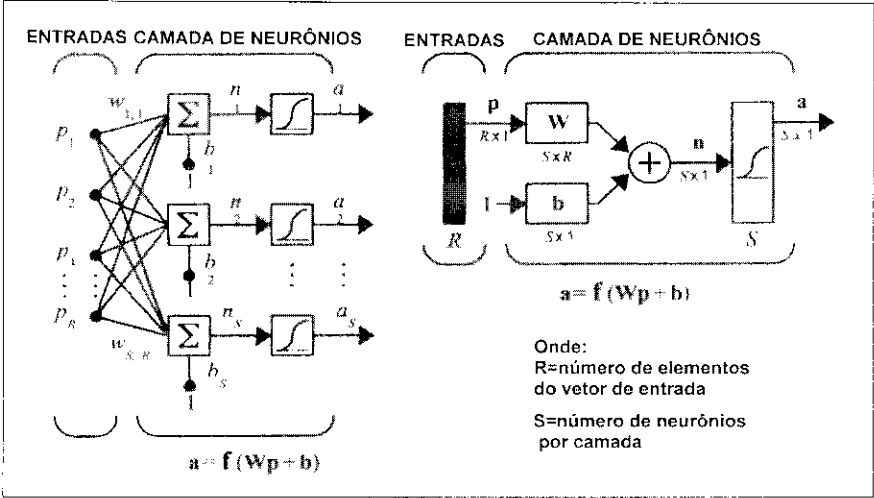


Fig.20 - Representação de mais de um neurônio por camada no MATLAB

A Figura 21 mostra a representação no MATLAB de uma RNA de múltiplas camadas de neurônios.

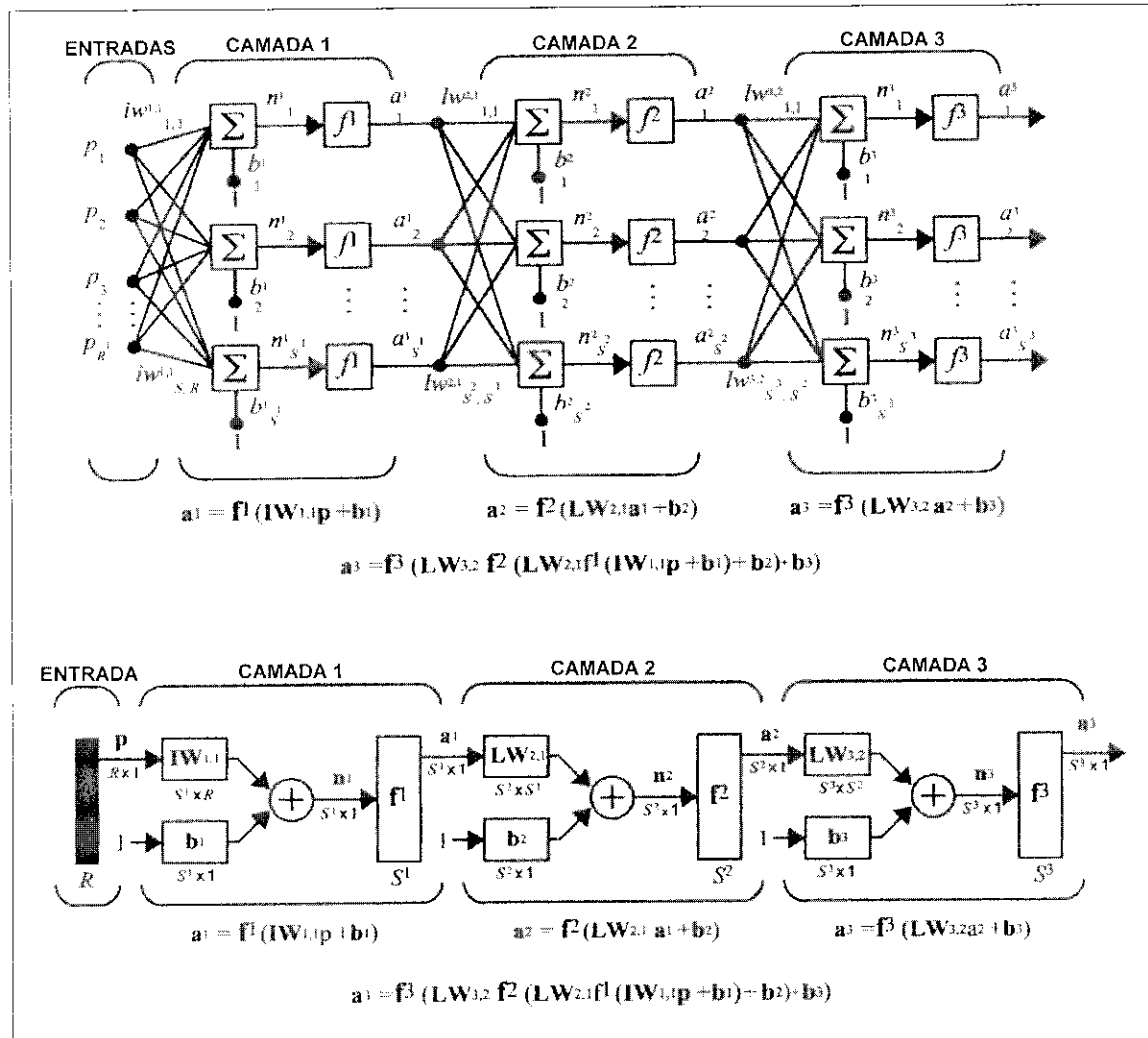


Fig.21 - Representação de múltiplas camadas de neurônios no MATLAB

Para uma aplicação prática em RNA deve-se utilizar o comando computacional do MATLAB, conforme será mostrado a seguir.

Para treinar uma RNA simples do tipo *feedforward* com 3 camadas, e arquitetura do tipo 1-3-1, deve-se escrever o seguinte comando:

```
net=newff([-1 2 ; 0 5] , [3 , 1] , {'tansig' , 'purelin'} , 'traingd');
```

Detalhamento do Comando:

- Elemento 1:** variando de -1 a 2
- Elemento 2:** variando de 0 a 5
- Arquitetura da RNA:** [3 , 1]
- Tipo de treinamento da RNA:** trainGD - Back Propagation Gradiente Descendente
- Tipos de função de transferência:**
 - na primeira camada nenhuma
 - na segunda camada tangente
 - na terceira camada linear
- RNA tipo:** Feedforward
- Vetor de entrada:** com dois elementos
- 3 camadas:**
 - primeira de entrada com 1 neurônio
 - segunda escondida com 3 neurônios
 - última saída com 1 neurônio

Observa-se que antes de iniciar o treinamento da RNA do tipo *feedforward*, é necessário inicializar os pesos e os bias. O comando *newff* automaticamente inicializa os pesos e os bias. Entretanto para poder reinicializar a qualquer momento os pesos e bias deve-se utilizar o comando

```
net = init(net);
```

Para simular uma RNA já treinada utiliza-se o comando *sim*, como

```
p = [1 ; 2];      ⇒ entrada
a = sim(net , p) ⇒ a é a saída da RNA simulada
a =
-0.1011 ⇒ saída
```

ou

```
p = [1 3 2 ; 2 4 1];      ⇒ entrada
a = sim(net , p)          ⇒ a é a saída da RNA simulada
a =
-0.1011 -0.2308 0.4955 ⇒ saída
```

Observa-se que esta RNA simulada antes teve de ser treinada utilizando algum tipo de algoritmo de treinamento (*Back-Propagation*), além do que é sempre necessário fornecer um par ENTRADA-ALVO (*input-target*). Este par entrada-alvo nada mais é do que a correlação entre o vetor de entrada e o vetor de alvo. Esta correlação entre a entrada e o alvo possibilita treinar a RNA para que a mesma possa fornecer na saída um valor, se não igual, bem próximo do esperado (alvo).

No Apêndice C foram transcritos os programas escritos em MATLAB que foram utilizados neste relatório, para a obtenção dos dados mostrados a seguir. Para um maior aprofundamento nos comandos do programa MATLAB, para a simulação de RNA, recomenda-se a leitura do Guia de Uso do *Neural Network Toolbox*^[21] e/ou uso dos programas transcritos no Apêndice C.

3.2. Algoritmo *Back-Propagation* Original e suas Derivações^[01-09, 21,23-25]

O algoritmo de treinamento *Back-Propagation* original^[23-24] foi criado na década de 80, seu funcionamento é simples e sua topologia pode ser do tipo *feedforward* ou *feedback* com múltiplas camadas.

Durante o processo de treinamento com o algoritmo original a rede opera sempre em sequência de dois passos. No primeiro passo é apresentado um padrão à camada de entrada da rede, e o processo de treinamento é propagado (*feedforward*) através da rede indo de camada em camada até que o padrão seja reproduzido na saída. No segundo passo a saída reproduzida é comparada com a saída desejada (alvo) para este padrão em particular. Se a saída não for satisfatória é calculado o erro. O erro é retropropagado (*feed-backward*) no sentido contrário indo da camada de saída para a camada de entrada para ajustar as conexões sinápticas (pesos).

As RNA que utilizam o algoritmo *Back-Propagation* original trabalham com uma variação da Regra Delta, apropriada para redes de múltiplas camadas chamada de Regra Delta Generalizada. A Regra Delta padrão implementa um gradiente descendente no quadrado da soma do erro, para as funções de ativação lineares.

Existem várias definições (passos) para a implementação computacional da RNA utilizando o algoritmo *Back-Propagation* original dentre estas pode-se destacar:

- Regra de propagação $\Rightarrow \text{net}_j = \sum x_i \cdot w_{ij} + \text{bias}$;
- Função de ativação \Rightarrow não-linear;
- Topologia \Rightarrow *feedforward* ou *feedback* com múltiplas camadas;
- Aprendizado \Rightarrow supervisionado;
- Processo de minimização do erro quadrático pelo método de gradiente descendente \Rightarrow

$$\Delta w_{ij} = -\eta \frac{\delta E_j}{\delta w_{ij}};$$

- Peso sináptico i ;
- Neurônio j ;
- Erro quadrático $\Rightarrow E_j = \frac{1}{2}(t_j - y_j)^2$;
- Valor desejado (ALVO) na camada de saída para o neurônio $j \Rightarrow t_j$;
- Estado de ativação do neurônio $j \Rightarrow y_j$;
- Processo de aprendizagem $\Rightarrow -\Delta w_{ij} = \eta \cdot y_i \cdot e_j$;
- Valor de entrada da conexão sináptica $i \Rightarrow y_i$;
- Valor calculado do erro do neurônio $j \Rightarrow e_j$;
- Cálculo do erro na camada de saída $\Rightarrow e_j = (t_j - y_j) \cdot \frac{\delta F(\text{net})}{\delta \text{net}}$;
- Cálculo do erro na camada intermediária $\Rightarrow e_j = (\sum e_n - w_{jn}) \cdot \frac{\delta F(\text{net})}{\delta \text{net}}$

No Programa MATLAB a implementação de uma iteração do algoritmo *Back-Propagation* original é escrita da seguinte forma

$$x_{k+1} = x_k - \alpha_k g_k \quad (58)$$

onde x_k é o vetor atual dos pesos e bias, g_k é o gradiente atual e o α_k é a taxa de aprendizado.

Outro tipo de treinamento utilizando o algoritmo *Back-Propagation* é o *Gradiente Descendente com Momento*. A utilização do momento neste algoritmo é devido a maior velocidade na convergência, não só para os gradientes locais, mas também para algumas tendências da superfície de erro. Este atua com um filtro passa-baixa, e ignora pequenas deformações na superfície de erro, sem isto a RNA pode cair em um mínimo local e ficar preso. O momento pode ser adicionado ao algoritmo *Back-Propagation* nas modificações dos pesos utilizando uma constante de momento, que varia de 0 a 1. Quando a constante de momento é zero as modificações nos pesos são dadas apenas pelo gradiente. Quando o momento é 1 novas mudanças nos pesos são adicionadas e os últimos pesos e seus gradiente são ignorados.

O algoritmo *Back-Propagation* original e o algoritmo *Back-Propagation* com momento são muito lentos para o treinamento em uso prático. Por isto foram incluídas modificações no algoritmo *Back-Propagation*, com a finalidade de possibilitar um treinamento mais veloz e poder ser utilizado em aplicações práticas. A seguir serão mostradas algumas destas modificações e seus principais aspectos.

As variações aqui apresentadas do algoritmo *Back-Propagation* se dividem basicamente em duas categorias. A primeira categoria utiliza técnicas heurísticas, e as variações do algoritmo são: algoritmo *Back-Propagation com Taxa de Aprendizado Variável*^[21-22] e algoritmo *Resilient Back-Propagation*^[21-22] (BP Elástico). A Segunda categoria utiliza a técnica de otimização numérica, e as variações do algoritmo são: algoritmo *Back-Propagation com Gradientes Conjugados (Fletcher-Reeves*^[21-29] e *Powell-Beale*^[21-30]), algoritmo *Back-Propagation Quasi-Newton*^[21] e o algoritmo *Back-Propagation Levenberg-Marquardt*^[21-31].

Back-Propagation com Taxa de Aprendizado Variável – O algoritmo *Back-Propagation* original utiliza uma técnica de treinamento constante. Isto faz com que o algoritmo fique muito sensível ao ajuste da taxa de aprendizado. Como se sabe, se a taxa de aprendizado for alta o algoritmo oscila e se torna instável, em contra partida, se a taxa de aprendizado for pequena o algoritmo demora muito para convergir. A escolha de uma taxa de aprendizado ideal não é fácil de ser obtida, podendo ser determinada durante o processo de alguns treinamentos da rede, variando e analisando o comportamento do par ENTRADA-ALVO.

Este algoritmo em particular implementa uma modificação na taxa de aprendizado durante o próprio processo de treinamento, isto é, enquanto ele ocorre. A taxa de aprendizado é a principal responsável pela complexidade da superfície de erro.

A taxa de aprendizagem adaptativa requer algumas modificações no processo de treinamento, como por exemplo antes do início do treinamento as saída e o erro são calculados a cada iteração, assim os novos pesos e bias são calculados utilizando a taxa de aprendizado atual e desta forma as novas saídas e erros são outra vez calculadas. A taxa sempre é atualizada quando o erro medido a cada iteração tende a aumentar.

Resilient Back-Propagation – As RNA de múltiplas camadas utilizam tipicamente a função de transferência do tipo *sigmoid* nas camadas escondidas. A função de transferência *sigmoid* é caracterizada pelo fato de fazer com que uma entrada de grande magnitude se aproxime de zero, mas isto pode ser um problema para pequenas magnitudes de entrada, como é o caso dos sinais medidos com as sondas magnéticas em tokamaks, pois isto causa pequenas modificações nos valores dos pesos e bias dificultando a convergência do treinamento. A proposta do algoritmo *Resilient Back-Propagation* é eliminar os efeitos nocivos das magnitudes nas derivadas parciais. Neste caso somente um sinal da derivada é utilizado para determinar a direção das atualizações dos pesos e bias. Observa-se que neste caso a magnitude da derivada não afeta a atualização dos pesos. O tamanho da modificação dos pesos é determinado por um valor de atualização. A atualização dos pesos e bias é incrementado por um fator vindo do sinal da derivada, quando o sinal da derivada não sofre variação por mais de duas iterações. O decremento nos pesos e bias só se faz quando o sinal da derivada se modifica a cada iteração. No caso da derivada zero, o valor de atualização dos pesos e bias permanece o mesmo da iteração anterior. Este efeito elástico dá nome a este algoritmo.

O algoritmo *Back-Propagation* original ajusta seus pesos em passos na direção descendente, ou seja, gradiente negativo. Desta forma a função tende a decrescer muito rapidamente na direção do gradiente negativo, porém isto não necessariamente produz uma convergência rápida. Os algoritmos de gradiente conjugado fazem sua convergência ao longo da direção do conjugado, e isto produz geralmente uma rápida convergência na direção descendente.

Back-Propagation com atualização do tipo Fletcher-Reeves – Todos os algoritmos de gradiente conjugado iniciam sua busca pela direção descendente acentuada, ou gradiente negativo, na primeira iteração.

A busca é feita de tal forma a determinar a distância ótima do movimento ao longo de uma determinada direção. A nova busca de direção é determinada pela direção anterior do conjugado. Geralmente este procedimento determina a nova direção de busca, que é combinada com a direção descendente da busca anterior:

$$P_k = -g_k + \beta_k P_{k-1} \quad (59)$$

As versões existentes de gradiente conjugado diferem basicamente pela maneira de computar a constante β_k . Para o Fletcher-Reeves a atualização se procede da seguinte maneira:

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \quad (60)$$

Os algoritmos de gradiente conjugado requerem uma pequena armazenagem em memória, por serem algoritmos simples, sendo assim uma boa escolha para RNA que possuam uma arquitetura grande com muitos pesos.

Back-Propagation com reinicialização do tipo Powell-Beale – Todos os algoritmos deste tipo (conjugados) fazem busca de direção podendo ser restabelecido para um gradiente negativo. O restabelecimento ocorre quando o número de iterações é igual ao número de parâmetros da rede (pesos e bias). Entretanto, existem outros meios de reestabelecer eficientemente o treinamento. A técnica do Powell-Beale faz a reinicialização se a ortogonalidade entre o gradiente atual e o anterior for muito pequena. Se a condição da eq.61 for satisfeita, a direção de busca é restabelecida no sentido do gradiente negativo.

$$|g_{k-1}^T g_k| \geq 0.2 \|g_k\|^2 \quad (61)$$

A rotina do treinamento do Powell-Beale dificulta a previsão da RNA e a armazenagem de memória para este algoritmo é grande, não sendo ideal para RNA com arquitetura grande.

Back-Propagation com Algoritmo Quasi-Newton – O método de Newton é uma alternativa ao método do gradiente conjugado para acelerar a otimização do treinamento de RNA. Basicamente, o método de Newton utiliza a cada passo:

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (62)$$

Observa-se que A_k é a matriz de *Hessian* (segunda derivada) que é na verdade formada pelos valores atuais de pesos e bias. O método de Newton freqüentemente converge mais rápido do que o método de gradiente conjugado. Infelizmente, é extremamente complexo e por isso mesmo exige uma carga computacional pesada, devido ao cálculo da matriz de *Hessian*. Isto se faz mais visível quando é aplicada a uma RNA do tipo *feedforward*. Todos os tipos de algoritmos baseados no método de Newton requerem o cálculo da segunda derivada. Este algoritmo faz a atualização e aproximação da matriz de *Hessian* a cada iteração do algoritmo.

Este algoritmo requer uma armazenagem em memória muito grande quando comparado ao método de gradiente conjugado. Nota-se que por causa do amplo processamento computacional este algoritmo converge em poucas iterações. Para RNA com arquiteturas pequenas este algoritmo se mostra bastante eficiente.

Back-Propagation com algoritmo Levenberg-Marquardt - Este algoritmo foi feito para obter uma aproximação de segunda ordem na velocidade de treinamento, sem ter que computar a matriz de *Hessian*. Quando a função tem a forma de soma de quadrados (típico para treinamentos do tipo *feedforward*), a matriz de *Hessian* pode ser aproximada para

$$H = J^T J \quad (63)$$

e o gradiente é computado

$$g = J^T e \quad (64)$$

Observa-se que J é a matriz Jacobiana que contém todas as primeiras derivadas do erro da RNA, a respeito dos pesos e bias. Nota-se que e é o vetor de erro da RNA.

A matriz Jacobiana pode ser computada pelo método padrão (original) da técnica *Back-Propagation*, devido a sua pequena complexidade quando comparada à matriz de *Hessian*.

O algoritmo de Levenberg-Marquardt usa a aproximação para a matriz de *Hessian*, assim como o método de Newton, para a atualização dos pesos e bias.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (65)$$

Nota-se que quando o escalar de μ é igual a zero, assim como o método de Newton, utiliza-se a aproximação da matriz de *Hessian*. Quando μ é grande inicia-se o gradiente descendente com pequenos passos de iteração. O método de Newton é mais preciso e rápido quando está próximo do erro mínimo. O parâmetro μ decresce a cada passo de iteração, reduzindo a função.

Este algoritmo é um dos mais rápidos, e se mostra bastante eficiente para treinar RNA com arquiteturas com tamanho moderado. Esta se mostra mais eficiente ainda quando treinada utilizando o programa MATLAB, por ser uma linguagem computacional baseada em matemática de matrizes.

No próximo item deste relatório, são apresentadas as simulações dos treinamentos realizados no programa MATLAB com a implementação destes algoritmos modificados.

3.3. Comparação entre as Derivações do Algoritmo *Back-Propagation*^[01-09]

Para testar a velocidade e precisão de treinamentos de RNA para os algoritmos da família do *Back-Propagation* foi escolhida a arquitetura igual ao tipo de arquitetura para o controle da posição do plasma em tokamaks, do tipo 7-14-14-2, conforme a ilustração da Figura 22.




Fig.22 – Ilustração da RNA testada nos algoritmos da família *Back-Propagation*

A topologia utilizada no treinamento foi do tipo *feedforward*, todas as simulações mantiveram-se com os mesmos parâmetros e mesmos vetores de entrada e de alvo.

Observa-se que as simulações de treinamento aqui apresentadas não foram sempre obtidas com as primeiras tentativas. Para alguns algoritmos foram realizadas dezenas de tentativas, reiniciando os pesos para tentar obter o melhor resultado, mas nem sempre isto foi possível. Então pode-se dizer que as simulações aqui contidas, são os melhores casos obtidos para cada tipo de algoritmo.

O computador usado nas simulações foi um PC Pentium II 400MHz com 256 MB de memória RAM. Antes das simulações foi utilizado um programa para liberar memória RAM, ocupada pelo sistema operacional ou outros programas. Durante a análise das simulações a memória RAM estava operando com 60 a 70% de sua totalidade.

No Apêndice C estão transcritos os programas utilizados no MATLAB para cada um dos algoritmos.

Inicialmente foi analisado o treinamento do *Back-Propagation Original, Gradiente Descendente*. Na Figura 23 pode ser observada a tentativa de treinamento utilizando o gradiente descendente.




Fig.23 – Treinamento do algoritmo BP gradiente descendente no MATLAB

Nota-se que o algoritmo não convergiu para o erro quadrático médio estipulado. No detalhe uma aproximação das primeiras 300 iterações do treinamento. Fica claro que o algoritmo não convergiu porque caiu em um mínimo local. Observar os sinais de saída das iterações no Apêndice C, treinamento gradiente descendente.

O treinamento do *Back-Propagation com Gradiente Descendente com Momento* pode ser visto na Figura 24.




Fig.24 – Treinamento do algoritmo BP GD com momento no MATLAB

Nota-se que o algoritmo não convergiu para o erro quadrático médio estipulado. No detalhe uma aproximação das primeiras 300 iterações do treinamento. Fica claro que o algoritmo também não convergiu, porque caiu em um mínimo local. Observar os sinais de saída das iterações no Apêndice C, treinamento GD com momento.

O treinamento do *Back-Propagation com Taxa de Aprendizagem Variável* pode ser visto na Figura 25.




Fig.25 – Treinamento do algoritmo BP com Taxa de AV no MATLAB

Nota-se que o algoritmo não convergiu para o erro quadrático médio estipulado. No detalhe uma aproximação das primeiras 300 iterações do treinamento. Fica claro que o algoritmo também não convergiu porque caiu em um mínimo local. Observar os sinais de saída das iterações no Apêndice C, treinamento com taxa de aprendizado variável.

O treinamento do algoritmo *Resilient Back-Propagation* pode ser visto na Figura 26.




Fig.26 – Treinamento do algoritmo Resilient Back-Propagation no MATLAB

Nota-se que o algoritmo convergiu para o erro quadrático médio estipulado em apenas 26 iterações, em um tempo de 2,58 segundos. Este foi o treinamento mais rápido de todos os algoritmos, porém sua precisão foi pior que outros como o Levenberg-Marquardt. Observar os sinais de saída das iterações no Apêndice C, treinamento com resilient *Back-Propagation*.

O treinamento do algoritmo *Back-Propagation do tipo Fletcher-Reeves* pode ser visto na Figura 27.




Fig.27 – Treinamento do algoritmo BP do tipo Fletcher-Reeves no MATLAB

Nota-se que o algoritmo convergiu para o erro quadrático médio estipulado em 400 iterações, em um tempo de 22,58 segundos, e sua precisão não foi das piores. Observar os sinais de saída das iterações no Apêndice C, treinamento *BP* tipo Fletcher-Reeves.

O treinamento do algoritmo *Back-Propagation do tipo Powell-Beale* pode ser visto na Figura 28.




Fig.28 – Treinamento do algoritmo BP do tipo Powell-Beale no MATLAB

Nota-se que o algoritmo convergiu para o erro quadrático médio estipulado em apenas 55 iterações, em um tempo de 5,55 segundos, e sua precisão não foi muito boa. Observar os sinais de saída das iterações no Apêndice C, treinamento *Back-Propagation* tipo Powell-Beale.

O treinamento do algoritmo *Back-Propagation do tipo Quasi-Newton* pode ser visto na Figura 29.




Fig.29 – Treinamento do algoritmo BP do tipo Quasi-Newton no MATLAB

Nota-se que o algoritmo convergiu para o erro quadrático médio estipulado em 70 iterações, em um tempo de 50,69 segundos, e sua precisão não foi muito boa. Observar os sinais de saída das iterações no Apêndice C, treinamento *Back-Propagation* tipo Quasi-Newton.

O treinamento do algoritmo *Back-Propagation do tipo Levenberg-Marquardt*, pode ser visto na Figura 30.




Fig.30 – Treinamento do algoritmo BP do tipo Levenberg-Marquardt no MATLAB

Nota-se que o algoritmo convergiu para o erro quadrático médio estipulado em apenas 34 iterações, em um tempo de 43,28 segundos, e sua precisão foi muito boa construindo a melhor obtida nas simulações de treinamento. Observar os sinais de saída das iterações no Apêndice C, treinamento *Back-Propagation* tipo Levenberg-Marquardt.

A conclusão que se pode tirar destas simulações de treinamento de RNA é que de fato os algoritmos modificados são mais eficientes. Dentre os algoritmos da família *Back-Propagation*, os de otimização numérica se mostraram mais precisos, para este tipo de arquitetura, e para dados de entrada do tipo utilizado em tokamaks. Os algoritmos *Resilient Back-Propagation* e *Back-Propagation do tipo Levenberg-Marquardt* foram os que apresentaram melhores resultados (tempo, número de iterações e precisão).

Na Figura 31 são observados os resultados obtidos com os treinamentos das RNA para os algoritmos *Back-Propagation Gradiente Descendente*, *Resilient Back-Propagation* e *Back-Propagation do tipo Levenberg-Marquardt*. Foram comparados os valores dos pesos obtidos depois de treinadas as RNA.




Fig.31 – As variações de valores dos pesos para as RNA treinadas pelos algoritmos Back-Propagation (BP) gradiente descendente (GD), Resilient (RP) e Levenberg-Marquardt (LM)

Fica claro no gráfico que os pesos que menos variam produzem uma representação mais real das saídas RNA. O algoritmo mais preciso foi o Levenberg-Marquardt (LM). Observe que para uma média dos sinais este foi o que menos variou seus valores. Bem próximo está também o algoritmo Resilient *Back-Propagation*.

Na Tabela 2 são apresentados os principais parâmetros de desempenho dos treinamentos com algoritmos da família do *Back-Propagation*, extraídos dos sinais de resposta obtidos nas simulações.

Tabela 2 – Parâmetros de desempenho de treinamento de RNA do tipo Back-Propagation

Algoritmo	Tempo de simulação (s)	Número de Iterações	Precisão de saída	Comando MATLAB
Gradiente descendente	64,10	3000	Péssima	traingd
Gradiente descendente com momento	72,17	3000	Péssima	traingdm
Taxa de aprendizado variável	70,96	3000	Péssima	traingda
Resilient	2,58	26	Boa	trainrp
Fletcher-Reeves	22,58	400	Boa	traincgf
Powell-Beale	5,55	55	Boa/Ruim	traisnrgb
Quasi-Newton	50,69	70	Ruim	trainbfg
Levenberg-Marquardt	43,28	34	Ótima	trainlm

Os algoritmos que se destacaram de uma maneira geral foram o Resilient e o Levenberg-Marquardt, como pode ser observado na Tabela 3. Estes foram testados nas simulações de RNA para sinais típicos das bobinas magnéticas do tokamak ETE. Neste momento apenas o algoritmo Levenberg-Marquardt conseguiu convergir para o erro médio quadrático requerido.

Tabela 3 - Desempenho dos algoritmos da família Back-Propagation, pontos e classificação

Algoritmo	Velocidade (1-8)	Iterações (1-8)	Precisão (1-8)	Soma Pontos menor pontuação é melhor	Classificação
GD	6°	6°	6°	18	6°
GDM	7°	6°	6°	19	7°
TAV	8°	6°	6°	20	8°
R	1°	1°	2°	4	1°
FR	3°	5°	2°	10	4°
PB	2°	3°	3°	8	3°
QN	5°	4°	4°	13	5°
LM	4°	2°	1°	7	2°

Observa-se que para este tipo de sinal, o Levenberg-Marquardt convergiu em 80% das simulações de treinamento. Os resultados desta simulação são apresentados no próximo item.

3.4. Simulação Computacional de RNA para o Controle do Plasma no ETE^[01-09]

Como foi dito anteriormente, o algoritmo Levenberg-Marquardt foi utilizado nas simulações com os dados de equilíbrio de plasma do tokamak. Os vetores de entrada para treinamento, validação e testes, foram obtidos das tabelas criadas com as simulações computacionais do programa de equilíbrio de plasmas em tokamaks TOPEOL. Estas tabelas de encontram transcritas no Apêndice D deste relatório.

As listagens dos programas simulados no MATLAB estão no Apêndice C.

Durante esta fase de treinamento foram realizadas 20 simulações com reinicialização dos pesos e bias aleatoriamente, e foram obtidas 16 convergências de treinamento (80%). Para os 20% restantes os outros 20%, o algoritmo não convergiu ou ocorreram falhas nos cálculos.

Na Figura 32 pode-se observar a convergência para um dos melhores treinamentos com o algoritmo Levenberg-Marquardt, para sinais típicos de deslocamento do plasma no ETE.

Este treinamento levou 488,46 segundos (8 minutos e 14 segundos) para convergir em 170 iterações e sua precisão foi ótima, os sinais de saída são iguais aos alvos.




Fig.32 – Simulação da RNA para controle do deslocamento de plasma no ETE, com o programa MATLAB

Observando os resultados dos testes realizados com a RNA depois de treinada, conclusão mais óbvia é de que a simulação de RNA em computadores, com chips convencionais, não são capazes de realizar o controle *in loco* de equilíbrio de plasmas em tokamaks por serem muito lentas. A simulação mais rápida, para um caso simples de derivação da coluna de plasma, foi 6 vezes mais demorada do que todo o evento do plasma em uma descarga, tornando imprescindível sua armazenagem em *chips neurais*. Outra observação pode ser feita do ponto de vista do projeto da RNA. Arquiteturas do tipo 7-14-14-2, com expansão das camadas escondidas, se mostra mais apropriada para o caso dos sinais de tokamaks do que as arquiteturas do tipo 7-3-3-2, com compressão das camadas escondidas. Enquanto que 70-80% dos casos de expansão das camadas escondidas convergiram, apenas 20-30% dos casos compressivos convergiram e mesmo assim a precisão final na saída não se mostrou apropriada.

A variação do número de camadas escondida entre uma ou duas, não mostrou uma resposta conclusiva de melhora ou piora sensível no treinamento.

Os treinamentos que convergiram mostraram que o funcionamento (simulação) da RNA treinada é muito rápido para os casos onde a correlação ENTRADA-ALVO são mais precisos. Isto mostra que um algoritmo de treinamento lento mas preciso é preferível que um treinamento rápido e pouco preciso. Isto porque no caso de tokamaks a velocidade de treinamento da RNA pouco importa sob o ponto de vista de controle, uma vez que os treinamentos de RNA para tokamaks não se alteram freqüentemente, só ocorrendo quando um parâmetro principal é alterado. Portanto é perfeitamente suportável para o caso de RNA em tokamaks uma simulação de treinamento que demore algumas dezenas de minutos.

4. Conclusão e Perspectivas

Este quarto relatório, referente à bolsa de doutorado “Redes Neurais no Modelamento e Controle de Tokamaks – Aplicação ao ETE”, descreve o estudo e o projeto do compensador do levitador magnético, as simulações computacionais de redes neurais artificiais com o programa MATLAB, e os sinais obtidos da simulação de RNA para o deslocamento do plasma.

Durante este período:

- Foram realizadas medidas de campo magnético no MagLev (ver Apêndice A);
- Foi estudado e projetado um compensador para a aplicação no levitador magnético MagLev, utilizando a teoria de controle (ver Apêndices B);
- Foram realizadas simulações computacionais de RNA com o programa MATLAB (ver Apêndices C);
- O estudante também colaborou na montagem utilização do diagnóstico da câmera CCD e na operação do sistema de controle do tokamak ETE no LAP/INPE.

Por ocasião do próximo relatório desta bolsa de pesquisas, espera-se:

- Implementar o circuito de controle convencional no MagLev;
- Simular a RNA, treinando e testando, para o caso do MagLev;
- Implementar o Hardware Neural no MagLev, uma vez que o processo de compra esta em vias de ser enviado para a FAPESP;
- Realizar estudos dos sinais medidos com as sondas magnéticas no ETE, e definir um fator de correção que permita transformar os valores medidos em Tesla para um deslocamento do plasma em milímetros;
- Redigir o texto da Tese.

Referências Bibliográficas

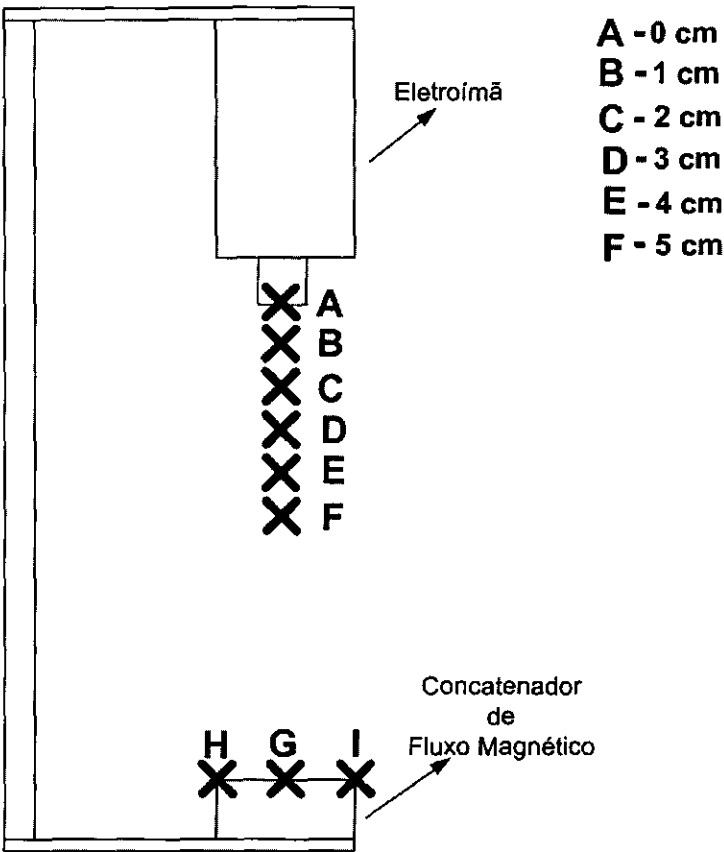
- [01] Barbosa, L.F.W.; Ludwig, G.O., *Redes neurais no modelamento e controle de tokamaks – aplicação ao ETE (Experimento Tokamak Esférico)* Primeiro Relatório, São José dos Campos, INPE, 1999. (INPE-7252-PRP/220)
- [02] Barbosa, L.F.W.; Ludwig, G.O., *Redes neurais no modelamento e controle de tokamaks – aplicação ao ETE (Experimento Tokamak Esférico)* Segundo Relatório, São José dos Campos, INPE, 2000. (INPE-7995-PRP/223)
- [03] Barbosa, L.F.W.; Ludwig, G.O., *Redes neurais no modelamento e controle de tokamaks – aplicação ao ETE (Experimento Tokamak Esférico)* Terceiro Relatório, São José dos Campos, INPE, 2001. (INPE-8477-PRP/226)
- [04] Kuo, B.C., *Sistemas de Controle Automático*, Prentice Hall do Brasil, Rio de Janeiro, 1985.
- [05] Gille, J.C.; Pelegrin, M.J.; Decaulne, P., *Feedback Control Systems*, McGraw Hill, New York, 1959.
- [06] Stefani, R.T.; Savant, C.J.Jr.; Shahian, B.; Hostetter, G.H., *Design of Feedback Control Systems*, Saunders College, New York, 1994.
- [07] Ogata, K., *Engenharia de Controle Moderno*, Prentice Hall do Brasil, Rio de Janeiro, 1982.
- [08] Ogata, K., *Soluções de Problemas de Engenharia de Controle com o MATLAB*, Prentice Hall do Brasil, Rio de Janeiro, 1994.
- [09] Evans, W.R., *Graphical Analysis of Control Systems*, Trans. AIEE, 67, 547- 551, 1948.
- [10] Evans, W.R., *Control System Synthesis by Root Locus Method*, Trans. AIEE, 69, 66- 69, 1950.
- [11] Abzug, M.J., *A Root Locus Method for the Anaysis of Nonlinear Servomechanisms*, IRE Trans.Automatic Control, AC-4(3), 38- 44, 1959.
- [12] Mitchell, J.R.; McDaniel, W.L.Jr., *A Generalized Root Locus Following Technique*, IEEE Trans.Automatic Control, AC-15, 483- 485, 1970.
- [13] Pillai, S.K., *The e Method of the Routh-Hurwitz Criterion*, IEEE Trans.Automatic Control, AC-26, 584, 1981.
- [14] Carmichael, A.T.; Hinchliffe, S.; Murgatroyd, H.; Willians, I.D., *Magnetic suspension systems with digital controllers*, Rev.Sci.Instrum. 57(8), 1611- 1615, 1986.

- [15] Wong, T.H., *Design of a magnetic levitation control systems – an undergraduate project*, IEEE Transactions of Education, E-29(4), 196-200, November, 1986.
- [16] Oliveira, V.A.; Costa, E.F.; Vargas, J.B., *Digital implementation of a magnetic suspension control systems for laboratory experiments*, IEEE Trans. on Education, v42(4), 315-322, November, 1999.
- [17] Oguchi, K.; Tomigashi, Y., *Digital control for a magnetic suspension system as an undergraduate project*, Int. J. Elect. Eng. Educ. 27, 226-236, 1990.
- [18] Lari, M.; Bloch, G., *A neural network whit minimal structure for MagLev systems modeling and control*, Proc. of IEEE, International Symposium on Intelligent control / Intelligent Systems and Semiutics, Cambridge, MA., 15-17 September, 1999.
- [19] Chiaberge, M.; Merelo, J.J.; Reyneri, L.M.; Prieto, A.; Zocca, L., *A Comparison of Neural Networks, Linear Controllers, Genetic Algorithms and Simulated Annealing for Real Time Control*, Proc. of ESANN 94, European Symposium on Artificial Neural Networks, Brussels, Belgic, April, 1994.
- [20] Reyneri, L.M.; Chiaberge, M.; Zocca, L., *CINTIA: A Neuro-Fuzzy Real Time Controller for Low Power Embedded Systems*, MICRONEURO 94, Int'l Conf. on Microelectronics for Neural Networks and Fuzzy Systems, Torino, Italy, September, 1994.
- [21] Dernuth, H.; Beale, M., *Neural Network Toolbox For Use with MATLAB*, MathWorks Inc., USA, 2000.
- [22] Demuth, H.; Beale, M., *Neural Network Toolbox For Use with MATLAB*, MathWorks Inc., USA, 1994.
- [23] Rumelhart,D.E.; Hilton,G.E.; Willians, R.J., *Learning Representations by Back-Propagation error*, Nature, 323, 533-536, 1986.
- [24] Rumelhart,D.E.; Hilton,G.E.; Willians, R.J., *Learning Internal Representations by error Propagation*, Parallel Data Processing, 1, 318-362, 1986.
- [25] Schalkoff, R.J., *Artificial Neural Networks*, Mc Graw-Hill, New York, 1997.
- [26] Windsor, C.G.; et al., *On-Line Control of the COMPASS-D Tokamak using a Neural Network*, Nuclear Energy, 34(2), 85-91, 1995.
- [27] Goh, A.T.C., *Back-Propagation Neural Networks for Modeling Complex Systems*, Artificial Intelligence in Engineering, 09, 143-151, 1995.
- [28] Basheer, I.A.; Hajmeer, M., *Artificial Neural Networks: Fundamentals, Computing, Design, and Application*, Journal of Microbiological Methods, 43, 3-31, 2000.

- [29] Fletcher, R.; Reeves, C.M., *Function Minimization by Conjugate Gradients*, Computer Journal, 7, 149-154, 1964.
- [30] Powell, M.J.D., *Restart Procedures for the Conjugate Gradient Method*, Mathematical Programming, 12, 241-254, 1977.
- [31] Hagan, M.T.; Menhaj, M., *Training Feedforward Networks with the Marquardt Algorithm*, IEEE Transactions on Neural Networks, 5(6), 989-993, 1994.
- [32] Lippman, R.P., *An Introduction to Computing with Neural Nets*, IEEE ASSP Magazine, 4-22, 1987.

APÊNDICE A

Medidas de Campo Magnético no MagLev



Corrente de 4A	
A	0,1263T
B	0,06T
C	0,025T
D	0,014T
E	0,01T
F	0,006T
G	0,0018T
H	0,0021T
I	0,0023T





Corrente de 2A	
A	0,098T
B	0,048T
C	0,016T
D	0,01T
E	0,006T
F	0,004T
G	0,0015T

APÊNDICE B

**Tabelas e Gráficos Úteis
para
Teoria de Controle Clássico**

Componentes Elétricos

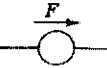
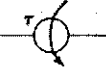
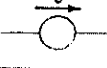
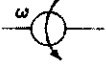

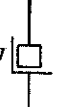




ELECTRIC-NETWORK COMPONENTS*

	Meshes		Symbol	Nodes	
Active elements	Signs indicate polarity when $V(t)$ is positive	$- \quad +$ Voltage $V(t)$	 Source	\rightarrow Current $I(t)$	Arrow indicates direction when $I(t)$ is positive
Passive elements	$V = RI$	Resistance R	 Dissipation of energy	Conductance $G = \frac{1}{R}$	$I = \frac{V}{R}$
	$V = L \frac{dI}{dt}$	Inductance L	 Storage of electromagnetic energy	Inverse inductance $\frac{1}{L}$	$I = \frac{1}{L} \int V dt$
	$V = \frac{1}{C} \int I dt$	Elastance $S = \frac{1}{C}$	 Storage of electrostatic energy	Capacitance C	$I = C \frac{dV}{dt}$
Kirchhoff's equations	A voltage drop is considered as positive when mesh is described clockwise	$\sum_k V_k(t) = 0$ along mesh		$\sum_k I_k(t) = 0$ at node	Currents directed from a node are considered positive

* Adapted from M. Gardner and F. Barnes, "Transients in Linear Systems," pp. 36-37, Wiley, New York, 1942, by kind permission of the authors and publisher.

Componentes Mecânicos

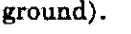

MECHANICAL-NETWORK COMPONENTS

	Translational		Rotational	
	Name	Symbol	Name	Symbol
Active elements	Force source		Torque source	
	Velocity source		Angular velocity source	
Passive elements	Mass m $F = m \frac{dv}{dt}$		Moment of inertia J $\tau = J \frac{d\omega}{dt}$	
	Mechanical resistance f $F = f v$		Mechanical resistance f $\tau = f \omega$	
	Stiffness $F = k \int v dt$		Torsional stiffness $\tau = k \int \omega dt$	

Análogo Elétrico - Mecânico



ELECTRIC ANALOGS FOR TRANSLATIONAL MECHANICAL SYSTEMS

	Mechanical-system parameters	Electric analog $V \sim v$ or $I \sim F$	Electric analog $V \sim F$ or $I \sim v$
Variables	Force F Velocity v	Current $I = F$ Voltage $V = v$	Voltage $V = F$ Current $I = v$
Elements	Mass m $F = m \frac{dv}{dt}$	Capacitance $C = m$ $I = C \frac{dV}{dt}$	Inductance $L = m$ $V = L \frac{dI}{dt}$
	Mechanical resistance f $F = fv$	Resistance $R = 1/f$ $I = \frac{1}{R} V$	Resistance $R = f$ $V = RI$
	Stiffness k $F = k \int v dt$	Inductance $L = 1/k$ $I = \frac{1}{L} \int V dt$	Capacitance $C = 1/k$ $V = \frac{1}{C} \int I dt$


Note. As an aid to memory, the $V \sim v$ analogy preserves the form of the diagrams and the references (fixed space, ground). In the same analogy, a spring k  becomes an inductance $L = 1/k$ .

ELECTRIC ANALOGS FOR ROTATIONAL MECHANICAL SYSTEMS

	Mechanical	Electric analog $V \sim \omega$ or $I \sim \tau$	Electric analog $V \sim \tau$ or $I \sim \omega$
Variables	Torque τ Angular velocity ω	Current $I = \tau$ Voltage $V = \omega$	Voltage $V = \tau$ Current $I = \omega$
Elements	Moment of inertia J $\tau = J \frac{d\omega}{dt}$	Capacitance $C = J$ $I = C \frac{dV}{dt}$	Inductance $L = J$ $V = L \frac{dI}{dt}$
	Rotational mechanical resistance f $\tau = f\omega$	Resistance $R = 1/f$ $I = \frac{1}{R} V$	Resistance $R = f$ $V = RI$
	Torsional stiffness k $\tau = k \int \omega dt$	Inductance $L = 1/k$ $I = \frac{1}{L} \int V dt$	Capacitance $C = 1/k$ $V = \frac{1}{C} \int I dt$


Note. As an aid to memory, the $V \sim \omega$ analogy preserves the form of the diagrams and the references (fixed space, ground). In the same analogy a torsional spring k  becomes an inductance $L = 1/k$ .

Transitórios








Satisfactory and unsatisfactory transient performances.


Resposta a Função Degrau Unitário




Lugar Geométrico da Raízes



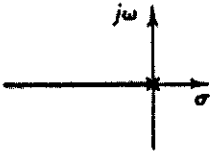
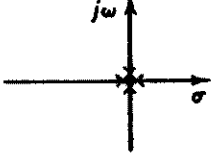
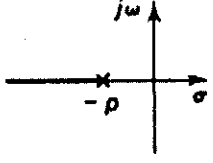
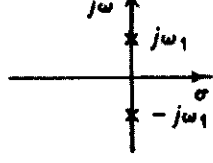
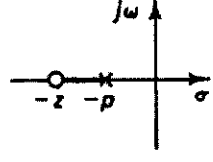
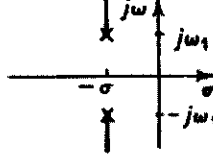
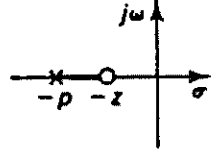
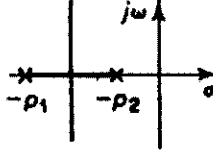
(a) Lugares de frequências não-amortecidas naturais constantes. (b) Lugares de taxas de amortecimento constantes. (c) Lugares de fatores de amortecimento constantes. (d) Lugares de frequências condicionais constantes.

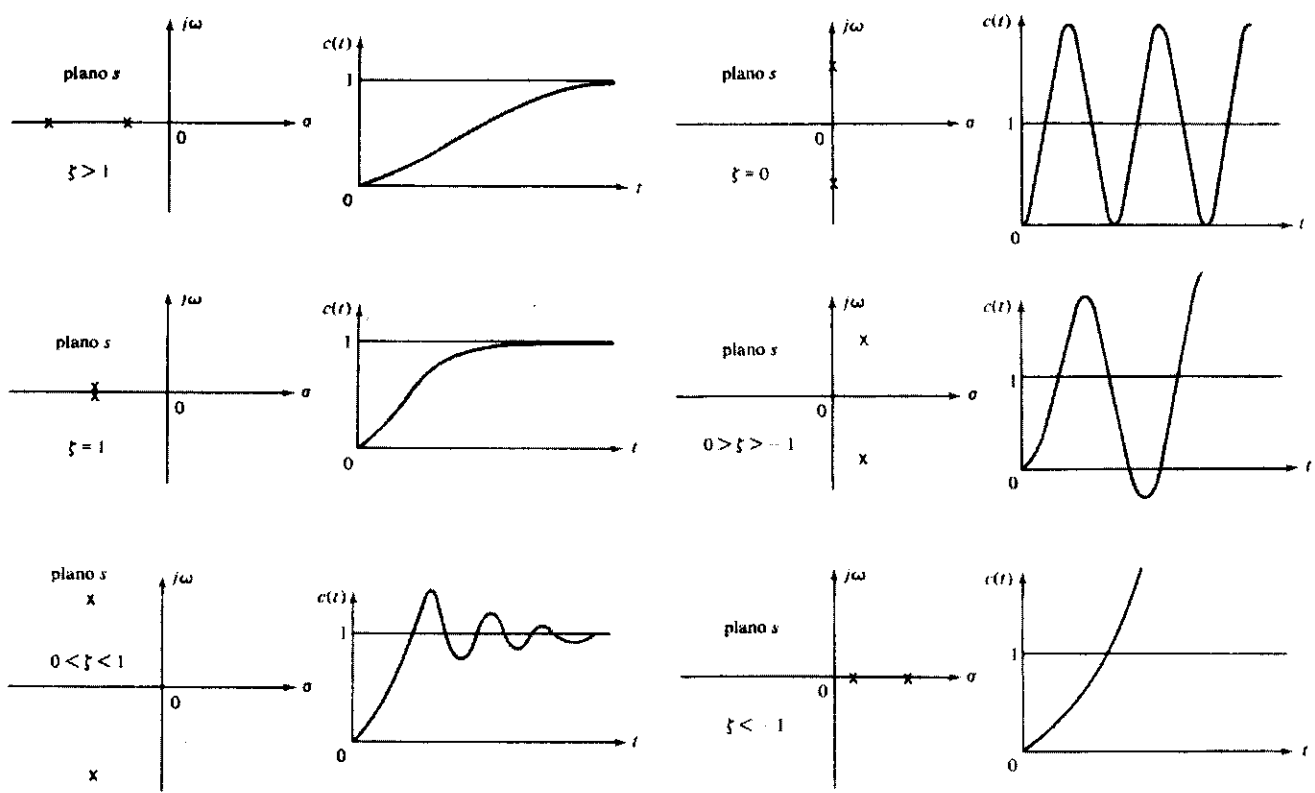


- $0 < \zeta < 1$: $s_1, s_2 = -\zeta\omega_n \pm j\omega_n\sqrt{1-\zeta^2}$ caso subamortecido
 $\zeta = 1$: $s_1, s_2 = -\omega_n$ caso criticamente amortecido
 $\zeta > 1$: $s_1, s_2 = -\zeta\omega_n \pm \omega_n\sqrt{\zeta^2-1}$ caso superamortecido
 $\zeta = 0$: $s_1, s_2 = \pm j\omega_n$ caso não-amortecido
 $\zeta < 0$: $s_1, s_2 = -\zeta\omega_n \pm j\omega_n\sqrt{1-\zeta^2}$ caso negativamente amortecido


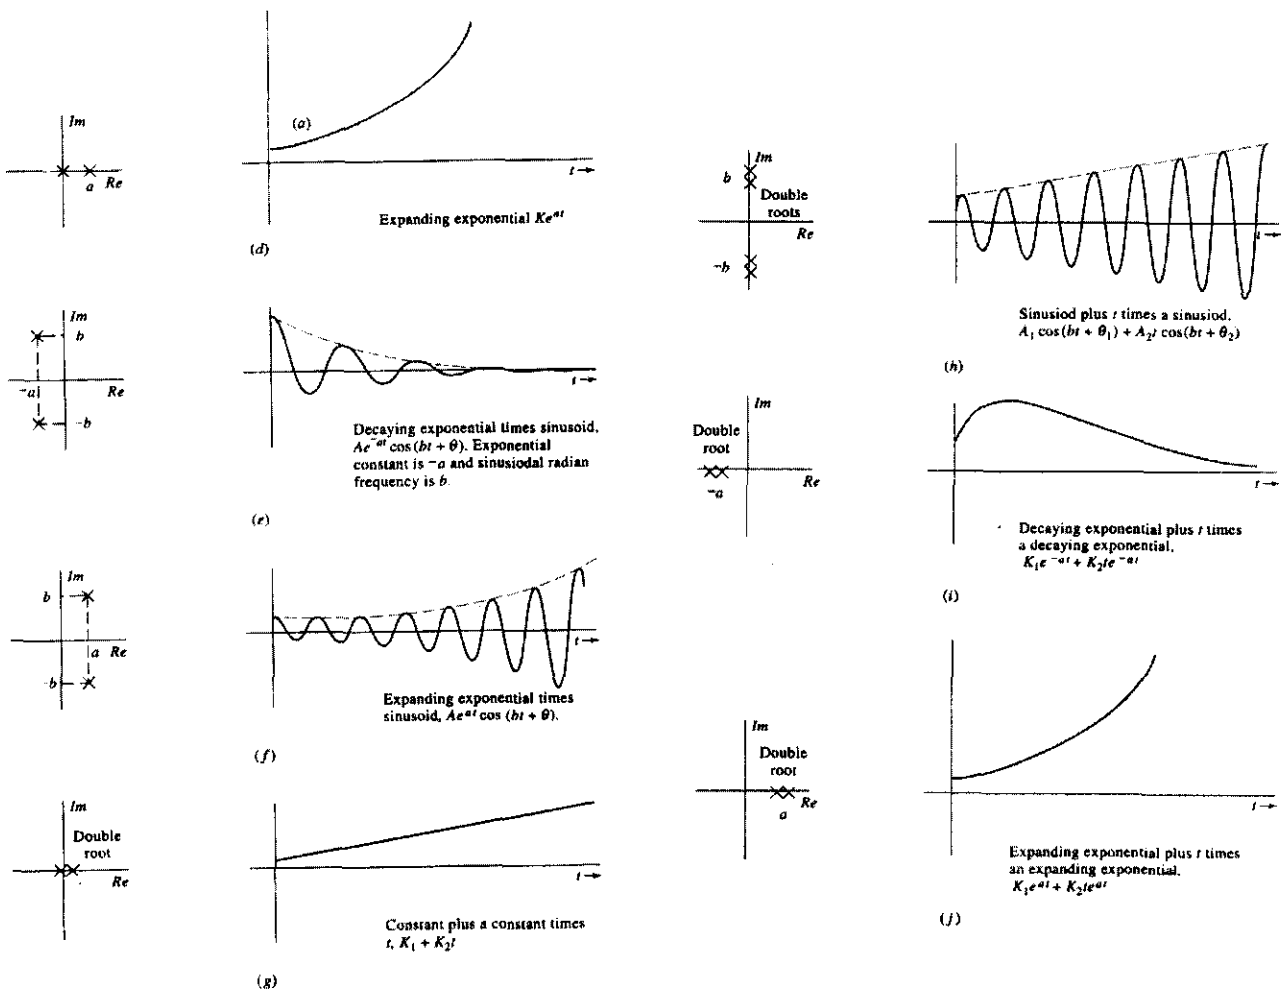


Lugar de raízes quando ω_n é mantido constante e a taxa de amortecimento varia de $-\infty$ a $+\infty$.


$G(s)H(s)$	Localizações do pólo-zero de malha aberta e lugares das raízes	$G(s)H(s)$	Localizações do pólo-zero de malha aberta e lugares das raízes
$\frac{K}{s}$		$\frac{K}{s^2}$	
$\frac{K}{s+p}$		$\frac{K}{s^2 + \omega_1^2}$	
$\frac{K(s+z)}{s+p}$ ($z > p$)		$\frac{K}{(s+\sigma)^2 + \omega_1^2}$	
$\frac{K(s+z)}{s+p}$ ($z < p$)		$\frac{K}{(s+p_1)(s+p_2)}$	



Comparação de respostas para várias localizações de raízes no plano s .




Regiões estável e instável no plano s



Traçado no plano s das raízes da equação característica de um sistema de segunda ordem e sua correlação com a solução transitória no domínio do tempo a uma excitação em degrau: (a) subamortecido, estável, $0 < \zeta < 1$; (b) criticamente amortecido, estável, $\zeta = 1$; (c) superamortecido, estável, $\zeta > 1$; (d) não amortecido, oscilação a amplitude constante, $\zeta = 0$; (e) raízes reais, instável, $\zeta < -1$; (f) subamortecido, instável, $0 > \zeta > -1$.


Efeitos da Adição de Pólos



Diagramas do lugar das raízes mostrando os efeitos da adição de pólos a $G(s)H(s)$.

- (a) - Sistema original, estável;
- (b) - Inclusão do pólo $-b$ no sistema original, pode se tornar instável;
- (c) - Inclusão de outro pólo $-c$, sistema de quarta ordem;
- (d) - Inclusão de dois pólos complexos conjugados.

Efeito da Adição de Zeros




Diagramas do lugar das raízes mostrando os efeitos da adição de zeros a $G(s)H(s)$.

- (a) - Inclusão do zero $-b$ no sistema original, se torna mais estável;
- (b) - Inclusão de um par de zeros no sistema original, se torna mais estável;
- (c) - Inclusão de outro zero $-c$.

Curvas de Nyquist


$N = Z - P$	Sentido do percurso do lugar do plano s	Lugar no plano $F(s)$	
		Número de circundamentos da origem	Sentido do circundamento
$N > 0$	Sentido horário	N	Sentido horário
	Sentido anti-horário		Sentido anti-horário
$N < 0$	Sentido horário	N	Sentido anti-horário
	Sentido anti-horário		Sentido horário
$N = 0$	Sentido horário	0	Nenhum circundamento
	Sentido anti-horário		Nenhum circundamento

- Seção 1: de $s = +j\infty$ a $+j\omega_1^+$ ao longo do eixo $j\omega$.
 Seção 2: de $+j\omega_1^+$ a $+j\omega_1^-$ ao longo do pequeno semicírculo ao redor de $s = j\omega_1$.
 Seção 3: de $s = j\omega_1^-$ a $+j0^+$ ao longo do eixo $j\omega$.
 Seção 4: de $+j0^+$ a $-j0^+$ ao longo do pequeno semicírculo ao redor de $s = 0$.
 Seção 5: de $s = -j0^+$ a $-j\omega_1^-$ ao longo do eixo $j\omega$ (imagem-espelho da seção 3).
 Seção 6: de $s = -j\omega_1^-$ e $-j\omega_1^+$ ao longo do semicírculo ao redor de $s = -j\omega_1$ (imagem-espelho da seção 2).




Curva de Nyquist


Nyquist - Resposta em Degrau e Freqüência




(a) Sistema estável e bem amortecido.



(b) Sistema estável mas oscilatório.




(c) Sistema marginalmente estável.



(d) Sistema instável.

Correlação entre os gráficos de Nyquist, respostas a e respostas em frequência degrau

Diagrama de Bode








Chart for determining step response from Bode plots.




Curvas de Lyapunov

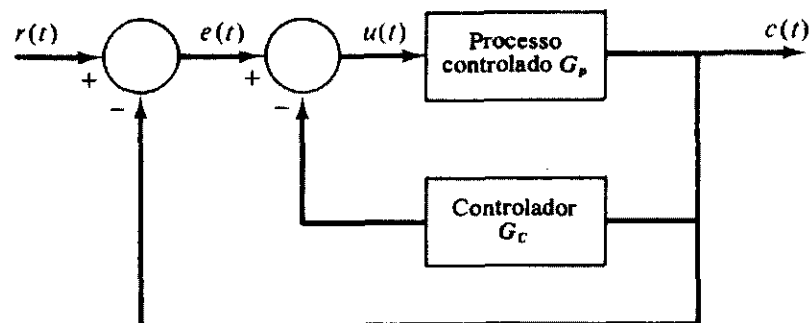


(a) Estado de equilíbrio estável e uma trajetória representativa; (b) estado de equilíbrio assintoticamente estável e uma trajetória representativa; (c) estado de equilíbrio instável e uma trajetória representativa.

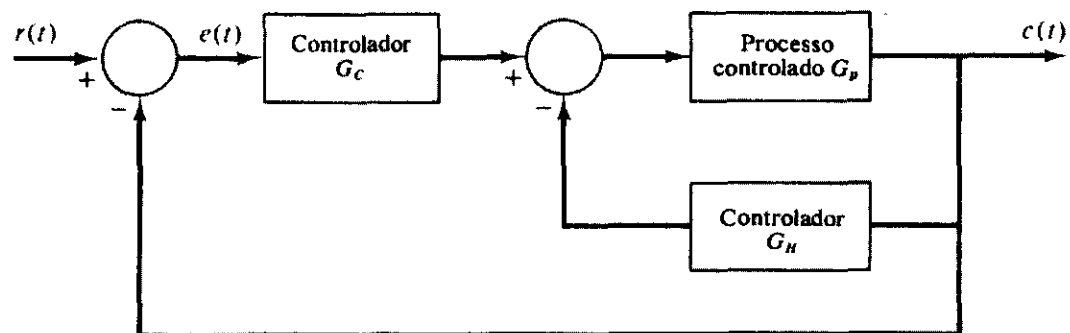
Posição do Controlador no Diagrama de Blocos da Malha de Controle



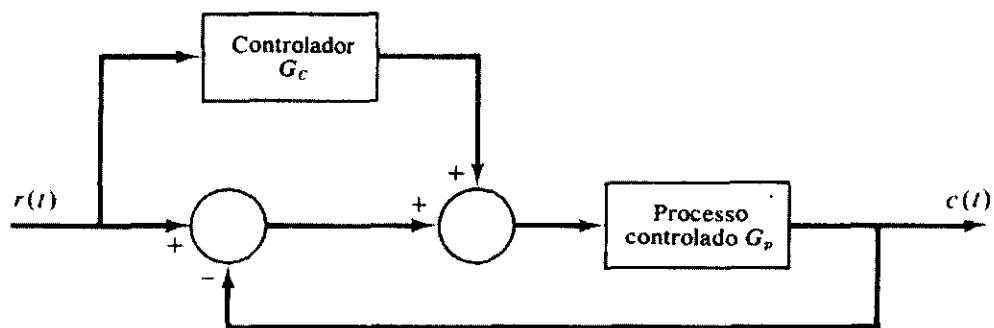
(a)




(b)



(c)



(d)



(e)

APÊNDICE C

TREINAMENTO BP GRADIENTE DESCENDENTE

```
%
%           Rede Neural Artificial
%           tipo FeedForward - BackPropagation
%           treinamento com BackPropagation Gradiente Descendente (traingd)
%           RNA 7-14-14-2
%
%           Entrada obtida da tabela de treinamento feita com o TOPEOL
%           para Equilibrio do Plasma com Deslocamento Positivo
%           com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'traingd');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_gd
%TRAINGD, Epoch 0/3000, MSE 123.279/1, Gradient 646.703/1e-010
%TRAINGD, Epoch 50/3000, MSE 31.4403/1, Gradient 0.51481/1e-010
%TRAINGD, Epoch 100/3000, MSE 31.403/1, Gradient 0.758959/1e-010
%TRAINGD, Epoch 150/3000, MSE 29.755/1, Gradient 0.926857/1e-010
%TRAINGD, Epoch 200/3000, MSE 29.4731/1, Gradient 0.238533/1e-010
%TRAINGD, Epoch 250/3000, MSE 29.4465/1, Gradient 0.118448/1e-010
%TRAINGD, Epoch 300/3000, MSE 29.1283/1, Gradient 90.3107/1e-010
```

%TRAINGD, Epoch 350/3000, MSE 31.4173/1, Gradient 0.00493101/1e-010
 %TRAINGD, Epoch 400/3000, MSE 31.4172/1, Gradient 0.00235347/1e-010
 %TRAINGD, Epoch 450/3000, MSE 31.4172/1, Gradient 0.00245941/1e-010
 %TRAINGD, Epoch 500/3000, MSE 31.4172/1, Gradient 0.0025758/1e-010
 %TRAINGD, Epoch 550/3000, MSE 31.4172/1, Gradient 0.00270399/1e-010
 %TRAINGD, Epoch 600/3000, MSE 31.4172/1, Gradient 0.00284589/1e-010
 %TRAINGD, Epoch 650/3000, MSE 31.4172/1, Gradient 0.00300379/1e-010
 %TRAINGD, Epoch 700/3000, MSE 31.4172/1, Gradient 0.00318056/1e-010
 %TRAINGD, Epoch 750/3000, MSE 31.4172/1, Gradient 0.00337979/1e-010
 %TRAINGD, Epoch 800/3000, MSE 31.4172/1, Gradient 0.00360604/1e-010
 %TRAINGD, Epoch 850/3000, MSE 31.4172/1, Gradient 0.00386519/1e-010
 %TRAINGD, Epoch 900/3000, MSE 31.4172/1, Gradient 0.00416495/1e-010
 %TRAINGD, Epoch 950/3000, MSE 31.4171/1, Gradient 0.00451566/1e-010
 %TRAINGD, Epoch 1000/3000, MSE 31.4171/1, Gradient 0.00493147/1e-010
 %TRAINGD, Epoch 1050/3000, MSE 31.4171/1, Gradient 0.00543231/1e-010
 %TRAINGD, Epoch 1100/3000, MSE 31.4171/1, Gradient 0.00604715/1e-010
 %TRAINGD, Epoch 1150/3000, MSE 31.4171/1, Gradient 0.00681982/1e-010
 %TRAINGD, Epoch 1200/3000, MSE 31.4171/1, Gradient 0.00781984/1e-010
 %TRAINGD, Epoch 1250/3000, MSE 31.4169/1, Gradient 0.0091646/1e-010
 %TRAINGD, Epoch 1300/3000, MSE 31.4168/1, Gradient 0.0110689/1e-010
 %TRAINGD, Epoch 1350/3000, MSE 31.4166/1, Gradient 0.0139724/1e-010
 %TRAINGD, Epoch 1400/3000, MSE 31.4164/1, Gradient 0.0189376/1e-010
 %TRAINGD, Epoch 1450/3000, MSE 31.4158/1, Gradient 0.0293528/1e-010
 %TRAINGD, Epoch 1500/3000, MSE 31.4139/1, Gradient 0.0648569/1e-010
 %TRAINGD, Epoch 1550/3000, MSE 31.4112/1, Gradient 0.438448/1e-010
 %TRAINGD, Epoch 1600/3000, MSE 31.4174/1, Gradient 0.00922837/1e-010
 %TRAINGD, Epoch 1650/3000, MSE 31.4173/1, Gradient 0.000844226/1e-010
 %TRAINGD, Epoch 1700/3000, MSE 31.4173/1, Gradient 0.000847343/1e-010
 %TRAINGD, Epoch 1750/3000, MSE 31.4173/1, Gradient 0.00086098/1e-010
 %TRAINGD, Epoch 1800/3000, MSE 31.4173/1, Gradient 0.000875065/1e-010
 %TRAINGD, Epoch 1850/3000, MSE 31.4173/1, Gradient 0.000889618/1e-010
 %TRAINGD, Epoch 1900/3000, MSE 31.4173/1, Gradient 0.000904664/1e-010
 %TRAINGD, Epoch 1950/3000, MSE 31.4173/1, Gradient 0.000920227/1e-010
 %TRAINGD, Epoch 2000/3000, MSE 31.4173/1, Gradient 0.000936335/1e-010
 %TRAINGD, Epoch 2050/3000, MSE 31.4173/1, Gradient 0.000953016/1e-010
 %TRAINGD, Epoch 2100/3000, MSE 31.4173/1, Gradient 0.000970303/1e-010
 %TRAINGD, Epoch 2150/3000, MSE 31.4173/1, Gradient 0.000988228/1e-010
 %TRAINGD, Epoch 2200/3000, MSE 31.4173/1, Gradient 0.00100683/1e-010
 %TRAINGD, Epoch 2250/3000, MSE 31.4173/1, Gradient 0.00102614/1e-010
 %TRAINGD, Epoch 2300/3000, MSE 31.4173/1, Gradient 0.00104621/1e-010
 %TRAINGD, Epoch 2350/3000, MSE 31.4173/1, Gradient 0.00106708/1e-010
 %TRAINGD, Epoch 2400/3000, MSE 31.4173/1, Gradient 0.00108879/1e-010
 %TRAINGD, Epoch 2450/3000, MSE 31.4173/1, Gradient 0.00111141/1e-010
 %TRAINGD, Epoch 2500/3000, MSE 31.4173/1, Gradient 0.00113499/1e-010
 %TRAINGD, Epoch 2550/3000, MSE 31.4173/1, Gradient 0.0011596/1e-010
 %TRAINGD, Epoch 2600/3000, MSE 31.4173/1, Gradient 0.00118529/1e-010
 %TRAINGD, Epoch 2650/3000, MSE 31.4173/1, Gradient 0.00121214/1e-010
 %TRAINGD, Epoch 2700/3000, MSE 31.4173/1, Gradient 0.00124024/1e-010
 %TRAINGD, Epoch 2750/3000, MSE 31.4173/1, Gradient 0.00126967/1e-010
 %TRAINGD, Epoch 2800/3000, MSE 31.4173/1, Gradient 0.00130054/1e-010
 %TRAINGD, Epoch 2850/3000, MSE 31.4173/1, Gradient 0.00133294/1e-010
 %TRAINGD, Epoch 2900/3000, MSE 31.4173/1, Gradient 0.001367/1e-010
 %TRAINGD, Epoch 2950/3000, MSE 31.4173/1, Gradient 0.00140284/1e-010
 %TRAINGD, Epoch 3000/3000, MSE 31.4173/1, Gradient 0.00144061/1e-010
 %TRAINGD, Maximum epoch reached, performance goal was not met.

%elapsed_time = 64.1000

%SAIDA

%a =

% -9.4371 7.4695 -9.4371 -9.4371 -9.4371 7.4695 -9.4371
% -9.4371 7.4695 -9.4371 -9.4371 -9.4371 7.4695 -9.4371

%ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 8

% -1.6907 -1.5813 -1.4960 -1.4813 -1.4647 -1.4150 -1.3501 -1.2591
% -0.5258 -0.4992 -0.5082 -0.4992 -0.4815 -0.5451 -0.4822 -0.5469
% 1.1674 1.1554 1.2265 1.1472 1.1933 1.2176 1.1759 1.2387
% -0.5245 -0.5116 -0.4327 -0.4592 -0.4261 -0.4569 -0.4984 -0.4522
% -0.3341 -0.3328 -0.4032 -0.3346 -0.4006 -0.3545 -0.3588 -0.3359
% 1.1121 1.0944 1.0657 1.0821 1.0732 1.0445 1.0502 1.1112
% 0.4750 0.4140 0.3713 0.4014 0.3782 0.3282 0.2379 0.2720
% 0.8388 0.7715 0.8530 0.8635 0.8661 0.8384 0.8745 0.8533
% -0.5963 -0.6608 -0.5764 -0.6124 -0.5784 -0.6069 -0.5612 -0.5947
% -0.4745 -0.4659 -0.4857 -0.5124 -0.5456 -0.4872 -0.4661 -0.4813
% 2.2818 2.2792 2.3626 2.3509 2.3254 2.3597 2.3401 2.3948
% -0.6036 -0.5246 -0.5201 -0.5064 -0.5776 -0.5773 -0.5498 -0.4851
% 0.8379 0.8825 0.8781 0.8684 0.8594 0.8615 0.8237 0.8385
% 0.0554 0.1338 0.2147 0.2426 0.2215 0.2659 0.3656 0.4431

% Columns 9 through 16

% -1.2455 -1.2176 -1.2121 -1.1572 -1.0366 -1.0480 -0.9551 -0.9033
% -0.5643 -0.5109 -0.5574 -0.5626 -0.5722 -0.4815 -0.5292 -0.4955
% 1.2454 1.1896 1.2420 1.2713 1.2208 1.2741 1.2004 1.2188
% -0.4504 -0.4821 -0.4466 -0.4017 -0.4316 -0.4524 -0.3811 -0.4538
% -0.3105 -0.3878 -0.3286 -0.3114 -0.2735 -0.3340 -0.3277 -0.3434
% 1.1298 1.0319 1.1260 1.0425 1.0807 1.0902 1.0588 1.0500
% 0.2580 0.2278 0.2068 0.1765 0.1786 0.1008 0.0332 0.0639
% 0.8598 0.8421 0.7935 0.8473 0.8314 0.8112 0.8816 0.8564
% -0.5910 -0.5889 -0.6103 -0.5623 -0.6421 -0.6037 -0.6624 -0.5889
% -0.4965 -0.4972 -0.4804 -0.5353 -0.4518 -0.4754 -0.4756 -0.5534
% 2.3449 2.3497 2.3351 2.3848 2.4074 2.3884 2.3783 2.3378
% -0.5557 -0.5033 -0.4907 -0.5384 -0.4776 -0.4663 -0.4860 -0.4856
% 0.7881 0.7904 0.8055 0.7617 0.8051 0.7159 0.7879 0.7712
% 0.4446 0.5253 0.5850 0.5740 0.6064 0.7334 0.7841 0.8107

% [14x14 double]

% [2x14 double]

%BIAS

% 1.3893
% 1.4375
% 1.3035
% 0.2642

% -0.2457
% -0.8752
% 1.0976
% 0.5427
% 1.0343
% 1.6044
% -1.5538
% -0.7869
% 0.1475
% -1.6251

% 1.7074
% 1.3571
% -0.9263
% -1.0177
% 0.6859
% 0.2310
% -0.0964
% -0.1063
% -0.2930
% -0.7138
% 0.6888
% -1.1089
% 1.2826
% -1.5397

% 0.3372
% -0.5134

TREINAMENTO BP GRADIENTE DESCENDENTE COM MOMENTO

```
%
    Rede Neural Artificial
%
    tipo FeedForward - BackPropagation
% treinamento com BackPropagation Gradiente Descendente com Momento (traingdm)
%
    RNA 7-14-14-2
%
%
% Entrada obtida da tabela de treinamento feita com o TOPEOL
% para Equilibrio do Plasma com Deslocamento Positivo
% com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'traingdm');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_gdm
%TRAIINGDM, Epoch 0/3000, MSE 122.533/1, Gradient 382.996/1e-010
%TRAIINGDM, Epoch 50/3000, MSE 31.4499/1, Gradient 0.885989/1e-010
%TRAIINGDM, Epoch 100/3000, MSE 31.4178/1, Gradient 0.0892689/1e-010
%TRAIINGDM, Epoch 150/3000, MSE 31.4174/1, Gradient 0.00903994/1e-010
%TRAIINGDM, Epoch 200/3000, MSE 31.4174/1, Gradient 0.00053308/1e-010
%TRAIINGDM, Epoch 250/3000, MSE 31.4174/1, Gradient 8.15989e-005/1e-010
%TRAIINGDM, Epoch 300/3000, MSE 31.4174/1, Gradient 1.16685e-005/1e-010
```


%SAIDA

%a =

% -9.4371 7.4695 -9.4371 -9.4371 -9.4371 7.4695 -9.4371
% -9.4371 7.4695 -9.4371 -9.4371 -9.4371 7.4695 -9.4371

%ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 8

% -0.2816 -0.2737 -0.2366 -0.2675 -0.2998 -0.3180 -0.3160 -0.3045
% 1.1089 1.0771 1.0612 1.1127 1.1028 1.0430 1.1312 1.1084
% 5.8341 5.8534 5.7684 5.7603 5.7753 5.7541 5.6822 5.7099
% 2.0113 2.0059 1.9707 1.9197 1.9505 1.9442 1.9854 1.8780
% 12.0518 12.1508 12.0780 12.1374 12.2350 12.2285 12.3012 12.2989
% 0.8466 0.8861 0.8483 0.8659 0.8689 0.8308 0.8632 0.8259
% -8.6942 -8.6700 -8.7334 -8.6824 -8.7233 -8.6494 -8.6812 -8.6638
% -0.8480 -0.8359 -0.8466 -0.8946 -0.8408 -0.8789 -0.8539 -0.8856
% -7.1877 -7.1607 -7.1721 -7.2415 -7.1953 -7.2784 -7.3042 -7.2778
% -6.1947 -6.1869 -6.2000 -6.2293 -6.2648 -6.2541 -6.2952 -6.2537
% 0.0858 0.1426 0.0923 0.2131 0.1623 0.1689 0.2140 0.1907
% 0.5988 0.5980 0.6855 0.6381 0.6276 0.6704 0.6112 0.6863
% -2.2749 -2.2920 -2.2110 -2.2535 -2.1989 -2.2393 -2.2493 -2.2482
% -0.3069 -0.3514 -0.3236 -0.3493 -0.3391 -0.2976 -0.2517 -0.2613

% Columns 9 through 16

% -0.2249 -0.2763 -0.2625 -0.2825 -0.2232 -0.2551 -0.2120 -0.2363
% 1.1297 1.0757 1.0865 1.1390 1.1563 1.1168 1.1571 1.1710
% 5.6276 5.7184 5.6625 5.6130 5.6196 5.5594 5.5235 5.5622
% 1.9560 1.9661 1.9388 1.9062 1.9500 1.9049 1.8830 1.9216
% 12.3325 12.3316 12.3516 12.4452 12.4451 12.4413 12.5416 12.5198
% 0.8649 0.8307 0.8637 0.7749 0.8393 0.8423 0.8074 0.8221
% -8.6458 -8.6573 -8.7309 -8.6952 -8.7119 -8.6793 -8.7342 -8.6990
% -0.7975 -0.8175 -0.7951 -0.8763 -0.8626 -0.8021 -0.7857 -0.8022
% -7.2575 -7.2814 -7.2910 -7.3917 -7.3971 -7.3871 -7.3932 -7.3858
% -6.2258 -6.2358 -6.2854 -6.3543 -6.2557 -6.2805 -6.3313 -6.3807
% 0.2278 0.2936 0.2908 0.3016 0.2653 0.3427 0.3173 0.3557
% 0.7173 0.6510 0.6866 0.6793 0.6972 0.6819 0.7160 0.7570
% -2.2632 -2.1974 -2.2493 -2.2746 -2.2422 -2.2870 -2.2851 -2.2881
% -0.2674 -0.3174 -0.3365 -0.2656 -0.3069 -0.2426 -0.2521 -0.2840

% [14x14 double]

% [2x14 double]

%BIAS

% 1.7431
% -0.2139
% 0.7093
% -0.9607
% 0.4222

% 1.1898
% -0.0129
% 0.5924
% -0.0125
% 1.8234
% -0.7955
% -0.9520
% -1.9441
% 1.7404

% -1.8475
% 1.2331
% 0.6107
% -1.2468
% 0.2687
% -0.4570
% 0.4749
% -0.4479
% 1.5456
% 0.4432
% -1.1502
% -0.5520
% -1.2235
% 1.5473

% -0.4337
% -0.7124

TREINAMENTO BP COM TAXA DE APRENDIZADO VARIÁVEL

```
%
% Rede Neural Artificial
% tipo FeedForward - BackPropagation
% treinamento com BackPropagation Taxa de Aprendizado Variavel (traingda)
% RNA 7-14-14-2
%
% Entrada obtida da tabela de treinamento feita com o TOPEOL
% para Equilibrio do Plasma com Deslocamento Positivo
% com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238      4.956  -5.241  -15.0   -17.8   9.813   -9.335 ; -0.476 5.082   -5.168  -14.8   -18.0   9.544   -
9.590 ; ...
-0.712 5.201  -5.110  -14.5   -18.2   9.274  -9.844 ; -0.949 5.327   -5.057  -14.3   -18.4   9.005  -10.100 ; ...
-1.187 5.462  -4.994  -14.1   -18.6   8.736  -10.400 ; -1.424 5.598   -4.942  -13.9   -18.8   8.466  -10.600 ; ...
-1.661 5.735  -4.894  -13.7   -19.0   8.197  -10.900 ; -1.898 5.876   -4.843  -13.4   -19.2   7.928  -11.100 ; ...
-2.136 6.027  -4.799  -13.2   -19.4   7.659  -11.400 ; -2.373 6.181   -4.751  -13.0   -19.6   7.390  -11.600 ; ...
-2.611 6.338  -4.710  -12.8   -19.8   7.121  -11.900 ; -2.848 6.501   -4.673  -12.6   -20.0   6.852  -12.100 ; ...
-3.085 6.655  -4.637  -12.3   -20.2   6.583  -12.400 ; -3.323 6.833   -4.601  -12.1   -20.4   6.314  -12.700 ; ...
-3.561 7.005  -4.569  -11.9   -20.6   6.045  -12.900 ; -3.804 7.264   -4.500  -11.7   -20.8   5.781  -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6   10.1 -9.080 ; -0.0016 4.839 -5.304   -15.2 -17.6   10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'traingda');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_gda
%TRAINGDA, Epoch 0/3000, MSE 111.121/1, Gradient 775.263/1e-006
%TRAINGDA, Epoch 50/3000, MSE 28.7955/1, Gradient 8.47312/1e-006
%TRAINGDA, Epoch 100/3000, MSE 22.4083/1, Gradient 10.6956/1e-006
%TRAINGDA, Epoch 150/3000, MSE 18.7712/1, Gradient 4.22038/1e-006
%TRAINGDA, Epoch 200/3000, MSE 17.5521/1, Gradient 3.20513/1e-006
%TRAINGDA, Epoch 250/3000, MSE 16.3276/1, Gradient 43.6088/1e-006
```

%TRAINGDA, Epoch 300/3000, MSE 15.9389/1, Gradient 24.3874/1e-006
 %TRAINGDA, Epoch 350/3000, MSE 15.5335/1, Gradient 44.2741/1e-006
 %TRAINGDA, Epoch 400/3000, MSE 15.7431/1, Gradient 81.0229/1e-006
 %TRAINGDA, Epoch 450/3000, MSE 13.9866/1, Gradient 116.263/1e-006
 %TRAINGDA, Epoch 500/3000, MSE 13.0902/1, Gradient 140.984/1e-006
 %TRAINGDA, Epoch 550/3000, MSE 12.2576/1, Gradient 137.356/1e-006
 %TRAINGDA, Epoch 600/3000, MSE 11.4176/1, Gradient 97.8506/1e-006
 %TRAINGDA, Epoch 650/3000, MSE 11.1127/1, Gradient 122.873/1e-006
 %TRAINGDA, Epoch 700/3000, MSE 11.2375/1, Gradient 121.14/1e-006
 %TRAINGDA, Epoch 750/3000, MSE 10.7113/1, Gradient 92.1598/1e-006
 %TRAINGDA, Epoch 800/3000, MSE 10.3424/1, Gradient 52.0003/1e-006
 %TRAINGDA, Epoch 850/3000, MSE 10.2804/1, Gradient 70.5186/1e-006
 %TRAINGDA, Epoch 900/3000, MSE 10.1917/1, Gradient 105.811/1e-006
 %TRAINGDA, Epoch 950/3000, MSE 10.457/1, Gradient 115.03/1e-006
 %TRAINGDA, Epoch 1000/3000, MSE 9.84717/1, Gradient 53.6284/1e-006
 %TRAINGDA, Epoch 1050/3000, MSE 9.74962/1, Gradient 70.2319/1e-006
 %TRAINGDA, Epoch 1100/3000, MSE 9.91002/1, Gradient 104.565/1e-006
 %TRAINGDA, Epoch 1150/3000, MSE 9.67972/1, Gradient 121.468/1e-006
 %TRAINGDA, Epoch 1200/3000, MSE 9.42936/1, Gradient 60.9145/1e-006
 %TRAINGDA, Epoch 1250/3000, MSE 9.37167/1, Gradient 65.6263/1e-006
 %TRAINGDA, Epoch 1300/3000, MSE 9.36489/1, Gradient 111.047/1e-006
 %TRAINGDA, Epoch 1350/3000, MSE 9.6701/1, Gradient 126.59/1e-006
 %TRAINGDA, Epoch 1400/3000, MSE 9.12285/1, Gradient 70.0283/1e-006
 %TRAINGDA, Epoch 1450/3000, MSE 9.04204/1, Gradient 84.1249/1e-006
 %TRAINGDA, Epoch 1500/3000, MSE 9.1068/1, Gradient 133.571/1e-006
 %TRAINGDA, Epoch 1550/3000, MSE 8.93336/1, Gradient 83.9365/1e-006
 %TRAINGDA, Epoch 1600/3000, MSE 8.93304/1, Gradient 99.2773/1e-006
 %TRAINGDA, Epoch 1650/3000, MSE 8.80077/1, Gradient 108.338/1e-006
 %TRAINGDA, Epoch 1700/3000, MSE 8.65315/1, Gradient 75.8321/1e-006
 %TRAINGDA, Epoch 1750/3000, MSE 9.04986/1, Gradient 136.104/1e-006
 %TRAINGDA, Epoch 1800/3000, MSE 8.67033/1, Gradient 104.686/1e-006
 %TRAINGDA, Epoch 1850/3000, MSE 8.49902/1, Gradient 81.7809/1e-006
 %TRAINGDA, Epoch 1900/3000, MSE 8.58345/1, Gradient 145.162/1e-006
 %TRAINGDA, Epoch 1950/3000, MSE 8.4498/1, Gradient 124.536/1e-006
 %TRAINGDA, Epoch 2000/3000, MSE 8.26767/1, Gradient 76.1283/1e-006
 %TRAINGDA, Epoch 2050/3000, MSE 8.20573/1, Gradient 74.6488/1e-006
 %TRAINGDA, Epoch 2100/3000, MSE 8.534/1, Gradient 137.776/1e-006
 %TRAINGDA, Epoch 2150/3000, MSE 8.16284/1, Gradient 90.8725/1e-006
 %TRAINGDA, Epoch 2200/3000, MSE 8.05806/1, Gradient 75.8455/1e-006
 %TRAINGDA, Epoch 2250/3000, MSE 8.19607/1, Gradient 152.21/1e-006
 %TRAINGDA, Epoch 2300/3000, MSE 8.00664/1, Gradient 110.442/1e-006
 %TRAINGDA, Epoch 2350/3000, MSE 7.87865/1, Gradient 76.6072/1e-006
 %TRAINGDA, Epoch 2400/3000, MSE 8.05566/1, Gradient 156.882/1e-006
 %TRAINGDA, Epoch 2450/3000, MSE 7.88079/1, Gradient 102.225/1e-006
 %TRAINGDA, Epoch 2500/3000, MSE 7.89853/1, Gradient 116.708/1e-006
 %TRAINGDA, Epoch 2550/3000, MSE 7.87447/1, Gradient 149.172/1e-006
 %TRAINGDA, Epoch 2600/3000, MSE 7.67172/1, Gradient 96.3577/1e-006
 %TRAINGDA, Epoch 2650/3000, MSE 7.83925/1, Gradient 164.577/1e-006
 %TRAINGDA, Epoch 2700/3000, MSE 7.6709/1, Gradient 110.836/1e-006
 %TRAINGDA, Epoch 2750/3000, MSE 7.49809/1, Gradient 71.2286/1e-006
 %TRAINGDA, Epoch 2800/3000, MSE 7.51397/1, Gradient 107.018/1e-006
 %TRAINGDA, Epoch 2850/3000, MSE 7.39299/1, Gradient 68.0643/1e-006
 %TRAINGDA, Epoch 2900/3000, MSE 7.54658/1, Gradient 123.314/1e-006
 %TRAINGDA, Epoch 2950/3000, MSE 7.3377/1, Gradient 77.2608/1e-006
 %TRAINGDA, Epoch 3000/3000, MSE 7.33561/1, Gradient 103.969/1e-006
 %TRAINGDA, Maximum epoch reached, performance goal was not met.

%elapsed_time =70.9600

%SAIDA

%a =

% -4.1157 7.6614 -5.8237 -12.8857 -12.8815 7.6870 -8.3946
% -2.7326 8.1035 -5.0738 -13.4202 -13.4145 8.1394 -8.1178

%ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 8

% -0.8334 -0.8471 -0.8879 -0.8298 -0.9089 -0.8325 -0.8556 -0.8561
% 1.4023 1.4565 1.4906 1.4571 1.4205 1.4522 1.4537 1.5234
% 0.4507 0.4086 0.4398 0.3553 0.3782 0.4270 0.3486 0.3798
% 0.3936 0.3648 0.3458 0.3645 0.3399 0.3727 0.3057 0.4010
% -1.3967 -1.4508 -1.4046 -1.3811 -1.4737 -1.4396 -1.4349 -1.4448
% 0.0322 0.0944 0.0913 0.0573 0.0373 0.0146 0.0330 0.0409
% 0.0318 0.0261 0.0286 0.0710 0.0183 0.0974 0.1029 0.0481
% -0.7680 -0.7380 -0.7372 -0.7401 -0.8125 -0.7551 -0.7562 -0.7332
% 2.7415 2.6738 2.7216 2.6871 2.6483 2.6640 2.6767 2.6531
% -0.7332 -0.7472 -0.7224 -0.6154 -0.6460 -0.6227 -0.6282 -0.5939
% -0.6634 -0.7106 -0.6166 -0.6279 -0.6124 -0.6660 -0.6454 -0.6435
% -0.2885 -0.2357 -0.2693 -0.3039 -0.3010 -0.2464 -0.2379 -0.2281
% 1.2175 1.1553 1.1433 1.1649 1.1994 1.1841 1.1573 1.1964
% 0.6188 0.5662 0.5803 0.5972 0.5150 0.4953 0.5094 0.5375

% Columns 9 through 16

% -0.8636 -0.8943 -0.9221 -0.8897 -0.9625 -0.9431 -0.9939 -0.9861
% 1.5662 1.5583 1.5332 1.5557 1.5779 1.6284 1.5822 1.6264
% 0.3593 0.3922 0.3864 0.3628 0.3500 0.2910 0.2873 0.3581
% 0.3871 0.3834 0.4033 0.3331 0.3304 0.3396 0.3587 0.3041
% -1.3844 -1.4760 -1.4506 -1.3986 -1.4524 -1.4582 -1.4818 -1.4557
% -0.0304 -0.0218 0.0307 0.0118 -0.0207 -0.0268 -0.0906 -0.0485
% 0.0403 0.0766 0.0799 0.1180 0.1628 0.0927 0.1309 0.1457
% -0.7632 -0.7544 -0.8241 -0.8245 -0.7647 -0.7930 -0.7744 -0.8360
% 2.6002 2.6521 2.6273 2.5761 2.5856 2.5815 2.6485 2.5544
% -0.6127 -0.5835 -0.5077 -0.5204 -0.4933 -0.4365 -0.4857 -0.4784
% -0.6496 -0.5923 -0.6364 -0.6513 -0.5863 -0.6242 -0.5476 -0.6049
% -0.2570 -0.3153 -0.2604 -0.2350 -0.2533 -0.2204 -0.2693 -0.2828
% 1.1324 1.1958 1.1309 1.2095 1.1777 1.2174 1.2198 1.1709
% 0.5277 0.4764 0.5315 0.4377 0.4459 0.4360 0.4598 0.4329

% [14x14 double]

% [2x14 double]

%BIAS

% 2.4562
% 1.9143
% -0.7204

% -0.8704
% -0.8920
% 1.5626
% -0.4289
% 0.7296
% -0.1476
% -1.6359
% 0.1306
% 0.0120
% 2.1685
% 0.9700

% 1.5804
% 1.1732
% -1.1880
% -0.9776
% 0.7314
% -0.3434
% 0.2346
% -0.0607
% -0.4684
% -0.4635
% -1.0243
% -1.0879
% -1.5028
% 1.6436

% 0.0829
% -0.5269

TREINAMENTO RESILIENT BACK-PROPAGATION

```
%
    Rede Neural Artificial
%
    tipo FeedForward - BackPropagation
%
    treinamento com BackPropagation Resilient (trainrp)
%
    RNA 7-14-14-2
%
%
%   Entrada obtida da tabela de treinamento feita com o TOPEOL
%   para Equilibrio do Plasma com Deslocamento Positivo
%   com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'trainrp');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_rp
%TRAINRP, Epoch 0/3000, MSE 109.351/1, Gradient 660.421/1e-006
%TRAINRP, Epoch 26/3000, MSE 0.792279/1, Gradient 55.8908/1e-006
%TRAINRP, Performance goal met.

%elapsed_time = 2.5800

%SAIDA
```

```
%a =
% -0.1130  5.4072 -5.0774 -14.7802 -17.4273  9.6652 -10.0687
% -0.0892  5.3292 -4.5748 -13.9129 -15.7637 10.3922 -10.9345
```

```
%ALVO = -0.0016  4.839 -5.304 -15.2 -17.6 10.1 -9.080
```

```
%PESOS
```

```
% Columns 1 through 8
```

```
% -0.0190 -0.0899 -0.1117 -0.0991 -0.0417 -0.1136  0.0207 -0.0234
% -0.0261  0.0115 -0.0275  0.0537  0.0150 -0.0557 -0.0476 -0.0512
% -0.1863 -0.2526 -0.1914 -0.2296 -0.1878 -0.2502 -0.2627 -0.2156
% -0.1650 -0.2211 -0.1769 -0.1464 -0.1563 -0.1770 -0.1879 -0.1969
%  0.2239  0.2256  0.1781  0.2525  0.2753  0.2029  0.2440  0.2017
%  0.0182 -0.0399  0.0063  0.0109 -0.0208 -0.0212  0.0376  0.0419
% -0.2032 -0.2709 -0.2020 -0.2327 -0.2785 -0.2206 -0.2455 -0.2052
% -0.0163  0.0011  0.0084 -0.0336 -0.0277  0.0159  0.0299 -0.0233
%  0.0259  0.0281 -0.0286 -0.0317 -0.0548  0.0068  0.0139 -0.0514
%  0.0026  0.0287  0.0056  0.0122 -0.0240  0.0258  0.0154  0.0135
% -0.6476 -0.6363 -0.6364 -0.5701 -0.6489 -0.5945 -0.6049 -0.6011
% -0.1242 -0.0999 -0.0435 -0.0345 -0.0533 -0.0902 -0.0544 -0.0500
%  0.0131 -0.0671 -0.1163 -0.0807 -0.0432 -0.0621 -0.0517  0.1819
%  0.1211  0.2042  0.1744  0.2104  0.1361  0.0966 -0.1160 -0.0433
```

```
% Columns 9 through 16
```

```
%  0.0558  0.0078  0.0230  0.0176  0.0054  0.0053  0.0351  0.0119
% -0.0532 -0.0464 -0.0160 -0.0048 -0.0177 -0.0161 -0.0531 -0.0417
% -0.2116 -0.1872 -0.2274 -0.2437 -0.2770 -0.1895 -0.2575 -0.2309
% -0.2269 -0.1775 -0.1972 -0.1276 -0.1758 -0.2228 -0.1308 -0.2137
%  0.1890  0.2564  0.2547  0.2270  0.2672  0.1996  0.2365  0.2776
%  0.0290 -0.0192 -0.0400  0.0087 -0.0110  0.0430 -0.0078  0.0501
% -0.2748 -0.2062 -0.2215 -0.2819 -0.2411 -0.2742 -0.2594 -0.2310
% -0.0177  0.0073 -0.0229 -0.0184  0.0569 -0.0332 -0.0069  0.0359
%  0.0329 -0.0561 -0.0658 -0.0482 -0.0033 -0.0411 -0.0033 -0.0273
%  0.0060 -0.0652 -0.0250  0.0005 -0.0523 -0.0039  0.0142 -0.0747
% -0.5903 -0.6233 -0.6604 -0.6861 -0.6573 -0.6342 -0.6560 -0.6094
% -0.0162 -0.0844 -0.0691  0.0269  0.0060 -0.0597 -0.0246 -0.0038
%  0.1525  0.1347  0.1211  0.1739  0.1293  0.0401  0.0866  0.0439
% -0.1150 -0.0915 -0.0781 -0.1013 -0.0681 -0.1252 -0.0712 -0.1051
```

```
% [14x14 double]
```

```
% [2x14 double]
```

```
%BIAS
```

```
% -2.5397
%  0.0159
% -0.6846
% -0.8052
%  0.5454
%  1.4703
```

% 0.9264
% -0.5265
% -0.3566
% 2.3566
% -0.7025
% -0.8229
% 1.6905
% -1.7789

% -2.2784
% -1.4533
% -1.0929
% 0.7995
% -0.5490
% -0.0927
% 0.2334
% -0.5723
% 0.3352
% -0.2638
% 0.9053
% 0.9759
% 1.4882
% -1.3721

% -2.7615
% -2.2243

TREINAMENTO BP FLETCHER-REEVES

```
%
%       Rede Neural Artificial
%       tipo FeedForward - BackPropagation
%       treinamento com BackPropagation Gradiente Conjugado
%       Fletcher - Reeves (traincgf)
%       RNA 7-14-14-2
%
%       Entrada obtida da tabela de treinamento feita com o TOPEOL
%       para Equilibrio do Plasma com Deslocamento Positivo
%       com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238      4.956  -5.241  -15.0   -17.8   9.813   -9.335 ; -0.476 5.082   -5.168  -14.8   -18.0   9.544   -
9.590 ; ...
-0.712 5.201  -5.110  -14.5   -18.2   9.274  -9.844 ; -0.949 5.327   -5.057  -14.3   -18.4   9.005  -10.100 ; ...
-1.187 5.462  -4.994  -14.1   -18.6   8.736  -10.400 ; -1.424 5.598   -4.942  -13.9   -18.8   8.466  -10.600 ; ...
-1.661 5.735  -4.894  -13.7   -19.0   8.197  -10.900 ; -1.898 5.876   -4.843  -13.4   -19.2   7.928  -11.100 ; ...
-2.136 6.027  -4.799  -13.2   -19.4   7.659  -11.400 ; -2.373 6.181   -4.751  -13.0   -19.6   7.390  -11.600 ; ...
-2.611 6.338  -4.710  -12.8   -19.8   7.121  -11.900 ; -2.848 6.501   -4.673  -12.6   -20.0   6.852  -12.100 ; ...
-3.085 6.655  -4.637  -12.3   -20.2   6.583  -12.400 ; -3.323 6.833   -4.601  -12.1   -20.4   6.314  -12.700 ; ...
-3.561 7.005  -4.569  -11.9   -20.6   6.045  -12.900 ; -3.804 7.264   -4.500  -11.7   -20.8   5.781  -13.200];
t=[-0.0016 4.839  -5.304 -15.2  -17.6   10.1  -9.080 ; -0.0016 4.839 -5.304   -15.2  -17.6   10.1  -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'traincgf');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> ma_teste_cgf
%TRAINCGF-srchcha, Epoch 0/3000, MSE 116.889/1, Gradient 694.819/1e-006
%TRAINCGF-srchcha, Epoch 50/3000, MSE 2.77242/1, Gradient 21.7069/1e-006
%TRAINCGF-srchcha, Epoch 100/3000, MSE 1.80313/1, Gradient 46.2105/1e-006
%TRAINCGF-srchcha, Epoch 150/3000, MSE 1.72526/1, Gradient 47.6653/1e-006
%TRAINCGF-srchcha, Epoch 200/3000, MSE 1.66024/1, Gradient 41.3877/1e-006
```


%TRAINCGF-srchcha, Epoch 250/3000, MSE 1.56862/1, Gradient 75.2046/1e-006
%TRAINCGF-srchcha, Epoch 300/3000, MSE 1.39868/1, Gradient 112.015/1e-006
%TRAINCGF-srchcha, Epoch 350/3000, MSE 1.17915/1, Gradient 93.8989/1e-006
%TRAINCGF-srchcha, Epoch 400/3000, MSE 0.99762/1, Gradient 75.7794/1e-006
%TRAINCGF, Performance goal met.

%elapsed_time = 22.5800

%SAIDA

%a =
% 0.9840 4.7073 -5.0240 -15.0577 -16.9234 8.2306 -9.2854
% 0.9018 3.8023 -4.9863 -14.9799 -16.6035 7.6810 -9.0884

%ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 8

% -0.3898 -0.4259 -0.3993 -0.3705 -0.4492 -0.4331 -0.3769 -0.4120
% -0.2897 -0.2867 -0.2799 -0.2362 -0.1221 -0.1875 -0.0541 -0.0287
% 0.0904 0.1029 0.0296 0.0114 0.0062 0.0026 -0.0246 -0.0357
% -0.3815 -0.3765 -0.3655 -0.2983 -0.3630 -0.3408 -0.2873 -0.2950
% -0.0985 -0.1408 -0.1356 -0.0577 -0.1258 -0.0998 -0.1064 -0.0859
% 0.9481 0.9849 0.9960 0.9532 0.9702 0.8896 0.8851 0.9360
% 0.1521 0.1251 0.1423 0.0977 0.2002 0.1423 0.2045 0.1355
% -0.0815 -0.0887 -0.0684 -0.0684 -0.0857 -0.0297 -0.0990 -0.0012
% -0.1951 -0.1785 -0.2171 -0.1687 -0.1651 -0.1807 -0.2382 -0.1579
% 0.1503 0.1333 0.0544 0.0855 0.1071 0.0764 0.0657 0.0700
% 0.0991 0.0890 0.1064 0.1369 0.1103 0.0738 0.1018 0.1441
% 0.0446 0.0327 0.0799 0.0049 0.0387 0.0861 0.0862 -0.0016
% 0.3355 0.4177 0.3375 0.3885 0.3501 0.4076 0.4072 0.3487
% 0.2351 0.2425 0.2468 0.2094 0.2706 0.1839 0.2744 0.2682

% Columns 9 through 16

% -0.3865 -0.3558 -0.3955 -0.3822 -0.3415 -0.3756 -0.3359 -0.3770
% -0.0369 0.0137 0.0750 0.1503 0.1485 0.2656 0.3123 0.3572
% 0.0153 -0.0101 -0.0060 -0.0706 -0.0795 -0.0895 -0.0120 -0.1069
% -0.3512 -0.2842 -0.3181 -0.3154 -0.2960 -0.2944 -0.3354 -0.3380
% -0.0834 -0.0306 -0.0329 -0.0424 -0.0274 -0.0113 -0.0523 -0.0936
% 0.8988 0.9256 0.9302 0.9032 0.8475 0.8292 0.8499 0.8906
% 0.1646 0.1209 0.1434 0.1427 0.1905 0.1247 0.1013 0.1462
% -0.0482 -0.0715 -0.0770 0.0004 0.0206 0.0164 -0.0280 -0.0483
% -0.2487 -0.1874 -0.2009 -0.2209 -0.2344 -0.2096 -0.2024 -0.2821
% 0.0191 -0.0269 -0.0159 -0.0902 -0.0783 -0.0649 -0.0684 -0.0683
% 0.0886 0.1149 0.1731 0.1294 0.1374 0.1568 0.1456 0.0995
% 0.0051 -0.0073 0.0168 0.0265 0.0699 0.0508 0.0382 -0.0010
% 0.3978 0.3287 0.3268 0.3563 0.3534 0.3626 0.3879 0.3471
% 0.2051 0.1842 0.2277 0.2534 0.2467 0.1881 0.2658 0.2411

% [14x14 double]

% [2x14 double]

%BIAS

- % -3.0694
- % -1.1932
- % -2.3654
- % 1.3319
- % -0.1796
- % -0.2050
- % -0.0059
- % -0.4307
- % 1.3293
- % 1.9757
- % -0.4393
- % -1.3307
- % -2.1762
- % 1.4512

- % 1.5779
- % 1.6314
- % -1.0129
- % 1.0101
- % 0.8528
- % -0.5949
- % -0.1623
- % -0.0440
- % 0.9804
- % -0.8504
- % 0.7993
- % 1.1930
- % 1.2941
- % -1.7605

- % -0.7235
- % -1.4535

TREINAMENTO BP POWELL-BEALE

```
%
    Rede Neural Artificial
%
    tipo FeedForward - BackPropagation
%
    treinamento com BackPropagation Gradiente Conjugado
%
    Powell - Beale (traincgb)
%
    RNA 7-14-14-2
%
% Entrada obtida da tabela de treinamento feita com o TOPEOL
% para Equilibrio do Plasma com Deslocamento Positivo
% com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'traincgb');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_cgb
%TRAINCGB-srchcha, Epoch 0/3000, MSE 121.564/1, Gradient 407.487/1e-006
%TRAINCGB-srchcha, Epoch 50/3000, MSE 1.32927/1, Gradient 11.564/1e-006
%TRAINCGB-srchcha, Epoch 55/3000, MSE 0.862199/1, Gradient 8.09952/1e-006
%TRAINCGB, Performance goal met.

%elapsed_time = 5.5500
```

%SAIDA

%a =
% 0.4108 4.7979 -6.1754 -15.1641 -15.2340 9.6462 -9.2939
% 0.4490 5.6663 -5.5441 -15.5106 -15.5876 9.6730 -8.9569

%ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 8

% 0.1376 0.0911 0.1077 0.1332 0.1062 0.0807 0.0123 -0.0261
% 0.0920 0.1528 0.1010 0.1466 0.1549 0.1064 0.1605 0.0868
% 0.3344 0.2416 0.2709 0.2360 0.1379 0.1361 0.1099 0.0302
% -0.1165 -0.1376 -0.1172 -0.1861 -0.1808 -0.2021 -0.1974 -0.1577
% 0.0045 -0.0524 0.0042 -0.0609 -0.0683 0.0234 -0.0344 -0.0326
% -0.0229 -0.0086 -0.0487 -0.0573 -0.1799 -0.2093 -0.2321 -0.2188
% 0.0229 0.0364 -0.0613 0.0212 0.0206 -0.0318 0.0126 -0.0064
% -0.0539 -0.0604 0.0234 -0.0381 -0.0652 -0.0601 -0.0273 0.0297
% 0.0229 0.0714 -0.0050 0.0134 0.0728 0.0760 0.0725 0.1034
% 0.0673 0.0449 0.1079 0.0353 0.0456 0.0333 0.0361 0.0576
% -0.0404 -0.0313 -0.0286 -0.0081 0.0027 -0.1024 -0.0343 -0.0540
% -0.1277 -0.0564 -0.0824 -0.0234 -0.0367 -0.0008 -0.0350 -0.0125
% 0.0433 0.0505 0.0520 0.0024 0.0603 0.0394 0.0898 -0.0030
% -0.1772 -0.1274 -0.1370 -0.2018 -0.1066 -0.1403 -0.1691 -0.1091

% Columns 9 through 16

% 0.0422 -0.0602 -0.0586 -0.0381 -0.0858 -0.1031 -0.1279 -0.1698
% 0.0859 0.1032 0.1133 0.0737 0.1150 0.1570 0.1390 0.0888
% -0.0178 0.0121 -0.1034 -0.0827 -0.1296 -0.1686 -0.2727 -0.2299
% -0.1572 -0.1237 -0.1242 -0.1513 -0.1528 -0.1917 -0.2047 -0.1974
% -0.0465 0.0147 -0.0052 -0.0228 0.0002 0.0448 0.0663 0.0171
% -0.2341 -0.2885 -0.3503 -0.3451 -0.4181 -0.4542 -0.4230 -0.5290
% -0.0256 -0.0491 -0.0304 -0.0176 -0.0488 -0.0798 -0.0414 -0.0084
% 0.0284 0.0117 -0.0028 0.0087 -0.0105 -0.0060 0.0312 0.0401
% 0.0977 0.0987 0.0852 0.0884 0.1162 0.1217 0.1206 0.0885
% 0.0950 0.0486 0.0994 0.1066 0.0945 0.1187 0.0792 0.1103
% -0.0593 -0.0534 -0.1507 -0.1428 -0.0993 -0.1238 -0.1512 -0.1587
% -0.0450 0.0107 -0.0125 -0.0235 0.0182 0.0212 0.1117 0.0517
% 0.0051 0.0228 0.0021 -0.0321 0.0110 0.0132 -0.0554 0.0193
% -0.1791 -0.1160 -0.1447 -0.0829 -0.1240 -0.1096 -0.1408 -0.0649

% [14x14 double]

% [2x14 double]

%BIAS

% -2.2385
% 1.5577
% -0.7228
% -1.2603
% -1.3153

% 0.4320
% 0.8505
% -1.3699
% 1.2574
% -1.2036
% -0.4175
% -2.1182
% -2.4231
% -1.2982

% -1.7869
% 1.4092
% 1.0622
% 0.6110
% 0.5247
% -0.3224
% 0.2588
% 0.1136
% -0.3592
% -0.5719
% -1.0171
% 1.3644
% 1.3455
% 1.7141

% -0.8777
% -1.3296

TREINAMENTO BP QUASI-NEWTON

```
%
    Rede Neural Artificial
%
    tipo FeedForward - BackPropagation
%
    treinamento com BackPropagation Quasi-Newton(trainbfg)
%
    RNA 7-14-14-2
%
%
%   Entrada obtida da tabela de treinamento feita com o TOPEOL
%   para Equilibrio do Plasma com Deslocamento Positivo
%   com 16 vetores de entrada com 7 elementos cada
%
% L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'trainbfg');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_bfg
%TRAINBFG-srchbac, Epoch 0/3000, MSE 120.27/1, Gradient 290.243/1e-006
%TRAINBFG-srchbac, Epoch 50/3000, MSE 7.49013/1, Gradient 0.131257/1e-006
%TRAINBFG-srchbac, Epoch 70/3000, MSE 0.788656/1, Gradient 90.207/1e-006
%TRAINBFG, Performance goal met.

%elapsed_time =50.6900
```

%SAIDA
%a =
% -0.8117 5.5406 -6.0348 -16.3687 -16.6743 8.6274 -9.2579
% -0.6694 5.5893 -5.4121 -16.2905 -16.6121 8.8060 -8.8050

%ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 8

% 1.5028 1.4555 1.4226 1.4410 1.4021 1.3709 1.3247 1.3573
% 0.5158 0.4811 0.4375 0.3862 0.3561 0.3843 0.3151 0.3084
% -2.7265 -2.6207 -2.6564 -2.6531 -2.6095 -2.6081 -2.6132 -2.5380
% 1.3976 1.3468 1.3550 1.4081 1.3848 1.3926 1.4152 1.4364
% 2.6788 2.7502 2.7319 2.7744 2.7544 2.8018 2.8742 2.9049
% -0.2657 -0.2448 -0.1982 -0.1813 -0.2210 -0.2646 -0.2041 -0.2460
% -0.4350 -0.2196 -0.0958 0.0737 0.1058 0.2553 0.1918 0.3341
% -2.3289 -2.3184 -2.3997 -2.3892 -2.3275 -2.3299 -2.3892 -2.3700
% -0.0320 0.0376 0.0656 0.1353 0.1380 0.1683 0.2423 0.2527
% -2.6833 -2.7081 -2.6726 -2.7236 -2.7021 -2.6910 -2.7047 -2.7666
% 0.6529 0.6810 0.6938 0.7204 0.6863 0.7658 0.7689 0.7125
% 1.8022 1.7950 1.8763 1.8732 1.8391 1.8149 1.8989 1.8189
% 4.0778 4.0809 4.0722 4.0811 4.1046 4.0637 4.0786 4.1527
% -0.2700 -0.2714 -0.2201 -0.2633 -0.1921 -0.1903 -0.2790 -0.2124

% Columns 9 through 16

% 1.3272 1.3198 1.2603 1.2985 1.2120 1.2475 1.2305 1.2186
% 0.3299 0.2688 0.2790 0.1763 0.1986 0.1167 0.0926 0.1361
% -2.5567 -2.5418 -2.5067 -2.5665 -2.4529 -2.4865 -2.4472 -2.5139
% 1.4963 1.4730 1.4906 1.5521 1.5024 1.5855 1.5222 1.5405
% 2.8971 2.9037 2.9470 2.9472 2.9296 3.0371 2.9733 3.0890
% -0.2334 -0.2696 -0.2744 -0.2214 -0.2481 -0.2624 -0.2030 -0.2653
% 0.2670 0.3472 0.1558 0.1401 0.0669 -0.2187 -0.2085 -0.5876
% -2.3595 -2.3265 -2.3041 -2.3304 -2.3652 -2.3145 -2.3452 -2.3818
% 0.2181 0.3167 0.3677 0.3321 0.3472 0.3996 0.4413 0.4958
% -2.7747 -2.7537 -2.8164 -2.8512 -2.7668 -2.8342 -2.8613 -2.8239
% 0.7279 0.7547 0.8245 0.7858 0.7907 0.7990 0.8672 0.8308
% 1.9190 1.8579 1.8778 1.8732 1.9239 1.9004 1.8789 1.9171
% 4.1066 4.1446 4.2179 4.1670 4.1915 4.2490 4.2497 4.1997
% -0.2375 -0.2482 -0.2195 -0.1978 -0.1689 -0.1952 -0.2315 -0.2501

% [14x14 double]

% [2x14 double]

%BIAS

% 1.7893
% -1.3307
% 1.0248
% -1.9893
% 0.3876
% -0.6692
% 0.4316

% -0.1646
% -0.7234
% 1.4287
% -2.4466
% -1.8045
% 1.5563
% -1.3519

% 2.5197
% 3.2639
% -0.9776
% 1.2176
% -1.7858
% 0.6347
% 1.6912
% 0.0224
% 1.3707
% -1.3975
% 0.6837
% 0.6348
% 1.4248
% -2.0588

% -4.8022
% -4.7719

TREINAMENTO BP LEVENBERG-MARQUARDT

```
%
    Rede Neural Artificial
%
    tipo FeedForward - BackPropagation
%
    treinamento com BackPropagation Levenberg Marquardt (trainlm)
%
    RNA 7-14-14-2
%
%
%
    Entrada obtida da tabela de treinamento feita com o TOPEOL
%
    para Equilibrio do Plasma com Deslocamento Positivo
%
    com 16 vetores de entrada com 7 elementos cada
%
%
%
    L.F.W.Barbosa 2001
%
tic;
net = init(net);
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'trainlm');
net.trainParam.show = 50;
net.trainParam.lr = 0.02;
net.trainParam.epochs = 3000;
net.trainParam.goal = 1e0;
[net,tr]=train(net,p,t);
toc
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
disp('.');
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% simulacao

%>> rna_teste_lm
%TRAINLM, Epoch 0/3000, MSE 96.3083/1, Gradient 3805.78/1e-010
%TRAINLM, Epoch 34/3000, MSE 0.977449/1, Gradient 49.2861/1e-010
%TRAINLM, Performance goal met.

%elapsed_time =43.2800

%SAIDA
```

```
%a =
% -0.3313  4.5439 -5.8264 -14.5228 -15.1911  10.5273 -9.3200
%  0.1292  5.0535 -5.8117 -14.5917 -15.2067  10.6015 -8.8711

%ALVO = -0.0016  4.839 -5.304 -15.2 -17.6  10.1 -9.080

%PESOS

% Columns 1 through 8

% -0.0909 -0.0381 -0.0784 -0.0364 -0.0787 -0.0123 -0.0895 -0.0436
% -0.0054  0.0191 -0.0390 -0.0105 -0.0817 -0.0775 -0.0886 -0.1427
%  0.1750  0.1559  0.0998  0.1683  0.1024  0.0877  0.0733  0.1427
% -0.0507 -0.0561 -0.0986 -0.0380 -0.1219 -0.0449 -0.0822 -0.0343
% -0.0932 -0.1281 -0.0903 -0.1199 -0.1002 -0.1712 -0.1540 -0.1478
% -0.0730 -0.0459 -0.1062 -0.0813 -0.0833 -0.1012 -0.0370 -0.1222
% -0.6832 -0.6545 -0.5828 -0.6221 -0.5523 -0.5652 -0.5062 -0.5769
% -0.0381 -0.0098 -0.0174 -0.0211 -0.0448 -0.0585 -0.0343 -0.0298
% -0.0863 -0.0995 -0.1176 -0.0333 -0.0516 -0.0416 -0.0885 -0.1333
% -0.3498 -0.3083 -0.2797 -0.1596 -0.1860 -0.1420 -0.1312 -0.0812
% -0.0325 -0.0528 -0.0061  0.0644 -0.0270  0.0060  0.0001  0.1195
%  0.1070  0.1286  0.0678  0.1629  0.1720  0.2135  0.2000  0.2696
%  0.0615  0.0362  0.0797  0.0590  0.0810  0.0476  0.0875  0.0952
% -0.3578 -0.3598 -0.2729 -0.2680 -0.2041 -0.1907 -0.1125 -0.0062

% Columns 9 through 16

% -0.0847 -0.0205 -0.0754 -0.0150 -0.0624 -0.0214 -0.0706 -0.1019
% -0.1172 -0.0894 -0.1172 -0.1205 -0.1159 -0.1965 -0.2448 -0.2448
%  0.1156  0.0956  0.1144  0.0458  0.0624  0.1066  0.0576  0.0424
% -0.0650 -0.0310 -0.1089 -0.0474 -0.1040 -0.1028 -0.0719 -0.1323
% -0.1399 -0.1441 -0.0905 -0.1328 -0.1917 -0.0988 -0.1180 -0.1472
% -0.0732 -0.0348 -0.0474 -0.1129 -0.1037 -0.0273 -0.1030 -0.0561
% -0.5348 -0.4823 -0.4949 -0.4089 -0.4251 -0.4049 -0.4332 -0.3370
% -0.0671 -0.1180 -0.0689 -0.0363 -0.0783 -0.1265 -0.1002 -0.0741
% -0.1272 -0.1650 -0.1161 -0.1053 -0.1294 -0.1272 -0.1077 -0.1505
% -0.0701 -0.0416  0.0568  0.0513  0.1546  0.1616  0.1624  0.1882
%  0.0241  0.0482  0.0438  0.1129 -0.0045 -0.0455 -0.0258 -0.0364
%  0.2130  0.3109  0.2814  0.3706  0.3678  0.3543  0.4064  0.4020
%  0.0022  0.0691  0.0967  0.0307 -0.0076  0.0582  0.0540  0.0640
%  0.0491  0.0465  0.1571  0.1246  0.2267  0.2986  0.2791  0.3888

% [14x14 double]

% [2x14 double]

%BIAS

%  2.1877
%  0.8057
% -0.9932
% -0.3228
%  0.2447
% -0.2967
%  0.8330
```

% 0.9543
% -0.3511
% -1.3443
% 1.5320
% 1.4413
% -1.2521
% 1.7829

% 1.7587
% -1.4173
% -0.9678
% 0.8511
% -0.7663
% 0.4943
% -0.5410
% -0.1414
% -0.3386
% -0.3182
% -0.7845
% 0.8870
% 1.3671
% 1.1747

% -0.7496
% -0.6634

TREINAMENTO BP LEVENBERG-MARQUARDT
PARA DADOS SIMULADOS NO PROGRAMA TOPEOL PARA O EXPERIMENTO TOKAMAK
ESFÉRICO (ETE)

```
%
%       Rede Neural Artificial
%       tipo FeedForward - BackPropagation
%       treinamento com BackPropagation Levenberg Marquardt (trainlm)
%       RNA 7-14-14-2
%
%       RNA para a Simulacao no TOPEOL para
%       Equilibrio do Plasma no Experimento Tokamak Esferico
%
%       dados obtidos das tabelas de treinamento,
%       teste e conjunto realista de teste feitas no programa
%       de equilibrio de plasma em tokamaks TOPEOL
%       para Equilibrio do Plasma com Deslocamento Positivo e Negativo
%
%       TREINAMENTO
%       (tabela de treinamento)
%       totalizando 32 vetores com 7 elementos cada
%
%       VALIDACAO
%       (tabela de teste)
%       totalizando 32 vetores com 7 elementos cada
%
%       TESTE
%       (tabela do conjunto realista)
%       totalizando 32 vetores com 7 elementos cada
%
%
% L.F.W.Barbosa dez2001 - jan2002
%
tic;%inicia a contagem de tempo e desliga quando passar pelo TOC
%
%       CONJUNTO_TREINAMENTO
%
p=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; ...
-0.712 5.201 -5.110 -14.5 -18.2 9.274 -9.844 ; -0.949 5.327 -5.057 -14.3 -18.4 9.005 -10.100 ; ...
-1.187 5.462 -4.994 -14.1 -18.6 8.736 -10.400 ; -1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; ...
-1.661 5.735 -4.894 -13.7 -19.0 8.197 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -11.100 ; ...
-2.136 6.027 -4.799 -13.2 -19.4 7.659 -11.400 ; -2.373 6.181 -4.751 -13.0 -19.6 7.390 -11.600 ; ...
-2.611 6.338 -4.710 -12.8 -19.8 7.121 -11.900 ; -2.848 6.501 -4.673 -12.6 -20.0 6.852 -12.100 ; ...
-3.085 6.655 -4.637 -12.3 -20.2 6.583 -12.400 ; -3.323 6.833 -4.601 -12.1 -20.4 6.314 -12.700 ; ...
-3.561 7.005 -4.569 -11.9 -20.6 6.045 -12.900 ; -3.804 7.264 -4.500 -11.7 -20.8 5.781 -13.200 ; ...
0.235 4.731 -5.373 -15.4 -17.4 10.4 -8.826 ; 0.472 4.613 -5.450 -15.6 -17.2 10.6 -8.571 ; ...
0.709 4.508 -5.522 -15.9 -17.0 10.9 -8.316 ; 0.946 4.408 -5.602 -16.1 -16.8 11.2 -8.062 ; ...
1.184 4.300 -5.686 -16.3 -16.6 11.4 -7.808 ; 1.421 4.205 -5.773 -16.5 -16.4 11.7 -7.554 ; ...
1.658 4.111 -5.861 -16.7 -16.2 12.0 -7.300 ; 1.895 4.015 -5.955 -16.9 -16.0 12.2 -7.046 ; ...
2.132 3.926 -6.056 -17.2 -15.7 12.5 -6.791 ; 2.370 3.834 -6.157 -17.4 -15.5 12.8 -6.537 ; ...
2.607 3.747 -6.265 -17.6 -15.3 13.1 -6.282 ; 2.845 3.664 -6.378 -17.8 -15.1 13.3 -6.028 ; ...
3.082 3.579 -6.488 -18.0 -14.9 13.6 -5.773 ; 3.320 3.499 -6.614 -18.2 -14.7 13.9 -5.519 ; ...
3.557 3.423 -6.734 -18.5 -14.5 14.1 -5.264 ; 3.800 3.310 -6.928 -18.7 -14.3 14.4 -5.014];
t=[-0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080 ; -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080];
%
%
```

```

% Simulacao de Redes Neurais Artificiais
%
net=newff(minmax(p),[14, 14, 2],{'tansig', 'tansig', 'purelin'},'trainlm');
%
% Parametros de TREINAMENTO, VALIDACAO e TESTE
%
net.trainParam.show = 50;% numero de passo mostrados (50 em 50)
net.trainParam.lr = 0.02;% taxa de aprendizado
net.trainParam.epochs = 1000;% numero de iteracoes
net.trainParam.goal = 0;% meta para o valor de erro quadratico medio
net = init(net);%inicializacao aleatoria dos pesos e bias
[net,tr]=train(net,p,t);
toc%contador de tempo
TR=[1:10:1:10];
%plotfa(p,t,p,a)
figure
plottr(TR)
disp('SAIDA');
a = sim(net,p)
disp('ALVO = -0.0016  4.839  -5.304  -15.2  -17.6  10.1  -9.080');
disp('.');
disp('.');
%disp('m e b - Ajustes na Curva e r - Correlacao SAIDA-ALVO');
%[m, b, r] = postreg(a,t)
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

% SIMULACAO

%>> rna_tokamak_lm_TREINAMENTO
%TRAINLM, Epoch 0/1000, MSE 83.6815/0, Gradient 3448.58/1e-010
%TRAINLM, Epoch 50/1000, MSE 5.66056/0, Gradient 66.2324/1e-010
%TRAINLM, Epoch 100/1000, MSE 1.14444/0, Gradient 142.358/1e-010
%TRAINLM, Epoch 150/1000, MSE 0.596069/0, Gradient 72.7934/1e-010
%TRAINLM, Epoch 170/1000, MSE 3.0156e-027/0, Gradient 5.93598e-013/1e-010
%TRAINLM, Minimum gradient reached, performance goal was not met.

%elapsed_time =488.4600

%SAIDA

%a =

% -0.0016  4.8390  -5.3040  -15.2000  -17.6000  10.1000  -9.0800
% -0.0016  4.8390  -5.3040  -15.2000  -17.6000  10.1000  -9.0800

%ALVO = -0.0016  4.839  -5.304  -15.2  -17.6  10.1  -9.080

%PESOS

```

% Columns 1 through 10

%	0.2617	0.3269	0.4226	0.4734	0.5259	0.5612	0.6182	0.6506	0.7047	0.7102
%	-0.0285	-0.0633	-0.0164	-0.0113	-0.0570	-0.0029	-0.0395	-0.0428	0.0132	-0.0234
%	-0.1679	-0.1593	-0.1463	-0.1250	-0.1041	-0.0738	-0.1221	-0.0908	-0.1138	-0.1041
%	-1.6512	-1.6094	-1.6281	-1.6780	-1.6388	-1.6736	-1.6816	-1.6988	-1.7170	-1.7597
%	0.5224	0.5409	0.4693	0.4671	0.4350	0.4597	0.4015	0.3933	0.3762	0.3553
%	-0.3582	-0.3631	-0.3195	-0.2382	-0.2140	-0.2056	-0.1170	-0.1098	-0.1033	-0.0693
%	0.3589	0.3453	0.2233	0.1861	0.1948	0.1338	0.0630	-0.0377	-0.0660	-0.1277
%	-0.0197	0.0634	0.1151	0.1628	0.1867	0.2362	0.2940	0.3285	0.3982	0.4515
%	-0.0696	-0.0643	-0.0564	-0.0048	-0.0021	0.0026	0.0239	-0.0118	-0.0232	0.0339
%	-0.2948	-0.3164	-0.2731	-0.2049	-0.2559	-0.2187	-0.1296	-0.0388	-0.0274	0.0409
%	0.0814	0.0426	0.0848	0.0753	0.0361	0.0510	0.0386	0.0138	-0.0358	-0.0506
%	-0.6578	-0.6871	-0.6657	-0.6902	-0.6629	-0.7067	-0.7094	-0.6910	-0.6810	-0.7218
%	-0.0170	0.0839	0.1164	0.1762	0.2713	0.3503	0.3810	0.4841	0.5302	0.5598
%	-0.1624	-0.1465	-0.1889	-0.2010	-0.1970	-0.1795	-0.2020	-0.2003	-0.2651	-0.2536

% Columns 11 through 20

%	0.7409	0.7543	0.7677	0.8122	0.8017	0.8729	0.1349	0.0412	-0.0477	-0.1270
%	-0.0377	-0.0190	0.0091	0.0040	0.0030	0.0332	-0.0619	-0.0551	-0.0524	-0.0746
%	-0.0824	-0.0387	-0.0655	-0.0397	-0.0691	-0.0564	-0.1711	-0.1829	-0.1930	-0.1905
%	-1.7509	-1.7601	-1.8057	-1.7808	-1.8378	-1.7927	-1.6069	-1.6502	-1.5872	-1.6409
%	0.3421	0.3295	0.2906	0.2612	0.2675	0.2415	0.6177	0.6305	0.6365	0.6348
%	-0.0113	0.0203	0.0382	0.0861	0.1357	0.1567	-0.4315	-0.4928	-0.5690	-0.6068
%	-0.2233	-0.2479	-0.4189	-0.4741	-0.5562	-0.5256	0.3726	0.3156	0.4167	0.3829
%	0.5231	0.5389	0.6021	0.6313	0.7281	0.7385	-0.1304	-0.1442	-0.2474	-0.2623
%	0.0202	0.0594	0.0526	0.0666	0.0691	0.0616	-0.0848	-0.0411	-0.0586	-0.0990
%	0.0515	0.1490	0.3015	0.3536	0.4392	0.3788	-0.3417	-0.2972	-0.3550	-0.2984
%	-0.0685	-0.0646	-0.0994	-0.0967	-0.1505	-0.1954	0.0865	0.0881	0.1384	0.1117
%	-0.7420	-0.7234	-0.7226	-0.7530	-0.7635	-0.7332	-0.6847	-0.7103	-0.7044	-0.6520
%	0.6523	0.7126	0.7664	0.8802	0.9105	0.9759	-0.1121	-0.1974	-0.2522	-0.3053
%	-0.2589	-0.3058	-0.2521	-0.3167	-0.3171	-0.3070	-0.1280	-0.1061	-0.0918	-0.1337

% Columns 21 through 30

%	-0.2681	-0.3467	-0.4955	-0.6452	-0.7411	-0.8673	-1.0535	-1.2215	-1.3613	-1.5207
%	-0.0689	-0.0991	-0.0893	-0.0738	-0.0845	-0.0975	-0.0949	-0.1092	-0.1062	-0.1529
%	-0.1988	-0.2259	-0.2172	-0.1907	-0.2257	-0.2300	-0.2694	-0.2753	-0.2779	-0.2477
%	-1.6077	-1.6083	-1.5819	-1.6121	-1.6134	-1.6022	-1.6109	-1.6292	-1.6583	-1.6230
%	0.6639	0.6896	0.7119	0.7750	0.7691	0.8252	0.8484	0.8809	0.8779	0.9050
%	-0.6423	-0.7063	-0.7408	-0.7704	-0.8492	-0.8514	-0.9464	-0.9744	-1.0405	-1.0921
%	0.3553	0.3344	0.3278	0.3103	0.2765	0.2688	0.1809	0.0866	0.0474	-0.0668
%	-0.3553	-0.3675	-0.4552	-0.4734	-0.5474	-0.5580	-0.6316	-0.6666	-0.7456	-0.8179
%	-0.0961	-0.0904	-0.1212	-0.0895	-0.1008	-0.1405	-0.1527	-0.1250	-0.1613	-0.1322
%	-0.2724	-0.2268	-0.1698	-0.1079	-0.1335	-0.0403	0.0644	0.1555	0.2855	0.3936
%	0.1442	0.1190	0.1248	0.1565	0.1745	0.1573	0.1526	0.1795	0.1617	0.1596
%	-0.6645	-0.6880	-0.6651	-0.6915	-0.6617	-0.6872	-0.6704	-0.7215	-0.6740	-0.6771
%	-0.3426	-0.4243	-0.4945	-0.5704	-0.6256	-0.7206	-0.7841	-0.7882	-0.9093	-0.9221
%	-0.1088	-0.0627	-0.0955	-0.0646	-0.0418	-0.0730	-0.0646	-0.0231	-0.0441	-0.0016

% Columns 31 through 32

%	-1.7137	-1.9445
%	-0.1134	-0.1545
%	-0.2749	-0.2919

% -1.6469 -1.6880
% 0.9738 1.0137
% -1.1872 -1.2596
% -0.0919 -0.3618
% -0.8255 -0.8923
% -0.1637 -0.1659
% 0.4433 0.7602
% 0.1861 0.1776
% -0.7051 -0.7132
% -0.9973 -1.0500
% -0.0319 -0.0147

% [14x14 double]

% [2x14 double]

%BIAS

% 0.8631
% -0.6911
% -0.1436
% 1.5752
% 0.9737
% -0.2871
% 1.2714
% -0.0085
% 0.0883
% -0.4668
% -1.6202
% 1.0879
% -2.2857
% -1.9395

% -1.0805
% 0.9303
% -1.2051
% -1.2996
% 0.8955
% -0.4483
% -0.0525
% 0.7153
% -0.9295
% -1.0898
% -0.8836
% 0.6044
% 1.4241
% -1.4798

% -0.8346
% -0.6509

VALIDAÇÃO BP LEVENBERG-MARQUARDT
PARA DADOS SIMULADOS NO PROGRAMA TOPEOL PARA O EXPERIMENTO TOKAMAK
ESFÉRICO (ETE)

```
% Rede Neural Artificial
% tipo FeedForward - BackPropagation
% BackPropagation Levenberg-Marquardt(trainlm)
%
% PLASMA CONTROL EQUILIBRIUM
%
%LFWBarbosa - 2001
%
% RNA 7-14-14-2 pesos rna_tokamak_lm
% VALIDACAO com a RNA ja' Treinada
%
tic;
%
% _____ CONJUNTO_VALIDACAO _____
%
val.P=[-0.143  4.905  -5.268  -15.1  -17.7  9.921  -9.233 ; -0.523  5.104  -5.158  -14.7  -18.0  9.490  -
9.641 ; ...
-0.665  5.177  -5.121  -14.6  -18.1  9.328  -9.794 ; -1.045  5.384  -5.029  -14.2  -18.5  8.897  -
10.2 ; ...
-1.420  5.598  -4.942  -13.9  -18.8  8.466  -10.6 ; -1.560  5.682  -4.914  -13.8  -18.9  8.305  -
10.8 ; ...
-1.661  5.735  -4.894  -13.7  -19.0  8.197  -10.9 ; -1.946  5.905  -4.833  -13.4  -19.2  7.874  -
11.2 ; ...
-2.326  6.145  -4.764  -13.0  -19.6  7.444  -11.6 ; -2.468  6.237  -4.738  -12.9  -19.7  7.283  -
11.7 ; ...
-2.563  6.299  -4.720  -12.8  -19.8  7.175  -11.8 ; -2.943  6.558  -4.660  -12.5  -20.1  6.745  -
12.2 ; ...
-3.232  6.717  -4.586  -12.2  -20.3  6.426  -12.6 ; -3.419  6.908  -4.546  -12.0  -20.5  6.207  -
12.8 ; ...
-3.513  6.967  -4.577  -11.9  -20.6  6.099  -12.9 ; -3.899  7.337  -4.489  -11.6  -20.9  5.673  -
13.3 ; ...
0.140  4.775  -5.342  -15.3  -17.4  10.2  -8.820 ; 0.519  4.594  -5.461  -15.7  -17.2  10.7  -
8.520 ; ...
0.662  4.527  -5.509  -15.8  -17.0  10.8  -8.367 ; 1.041  4.362  -5.639  -16.2  -16.7  11.3  -
7.960 ; ...
1.421  4.205  -5.773  -16.5  -16.4  11.7  -7.554 ; 1.563  4.150  -5.826  -16.6  -16.2  11.9  -
7.401 ; ...
1.658  4.111  -5.861  -16.7  -16.2  12.0  -7.300 ; 1.942  3.996  -5.973  -17.0  -15.9  12.3  -
6.994 ; ...
2.320  3.856  -6.131  -17.3  -15.6  12.7  -6.588 ; 2.464  3.803  -6.192  -17.5  -15.5  12.9  -
6.435 ; ...
2.560  3.764  -6.242  -17.5  -15.4  13.0  -6.333 ; 2.939  3.632  -6.419  -17.9  -15.1  13.4  -
5.926 ; ...
3.229  3.507  -6.612  -18.2  -14.8  13.8  -5.624 ; 3.415  3.470  -6.660  -18.3  -14.7  14.0  -
5.417 ; ...
3.510  3.440  -6.705  -18.4  -14.6  14.1  -5.315 ; 3.896  3.281  -6.983  -18.8  -14.3  14.5  -
4.913];

disp('SAIDA');
a = sim(net,p)
toc;
```



```

disp('ALVO = -0.0016  4.839  -5.304  -15.2  -17.6  10.1  -9.080');
disp('.');
disp('.');
%disp('m e b - Ajustes na Curva e r - Correlacao SAIDA-ALVO');
%[m, b, r] = postreg(a,t)
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

%>> rna_tokamak_lm_VALIDACAO
%SAIDA
%a =
% -0.0016  4.8390 -5.3040 -15.2000 -17.6000  10.1000 -9.0800
% -0.0016  4.8390 -5.3040 -15.2000 -17.6000  10.1000 -9.0800

%elapsed_time = 0.1100

%ALVO = -0.0016  4.839  -5.304  -15.2  -17.6  10.1  -9.080

%PESOS

% Columns 1 through 10

% 0.2617  0.3269  0.4226  0.4734  0.5259  0.5612  0.6182  0.6506  0.7047  0.7102
% -0.0285 -0.0633 -0.0164 -0.0113 -0.0570 -0.0029 -0.0395 -0.0428  0.0132 -0.0234
% -0.1679 -0.1593 -0.1463 -0.1250 -0.1041 -0.0738 -0.1221 -0.0908 -0.1138 -0.1041
% -1.6512 -1.6094 -1.6281 -1.6780 -1.6388 -1.6736 -1.6816 -1.6988 -1.7170 -1.7597
% 0.5224  0.5409  0.4693  0.4671  0.4350  0.4597  0.4015  0.3933  0.3762  0.3553
% -0.3582 -0.3631 -0.3195 -0.2382 -0.2140 -0.2056 -0.1170 -0.1098 -0.1033 -0.0693
% 0.3589  0.3453  0.2233  0.1861  0.1948  0.1338  0.0630 -0.0377 -0.0660 -0.1277
% -0.0197  0.0634  0.1151  0.1628  0.1867  0.2362  0.2940  0.3285  0.3982  0.4515
% -0.0696 -0.0643 -0.0564 -0.0048 -0.0021  0.0026  0.0239 -0.0118 -0.0232  0.0339
% -0.2948 -0.3164 -0.2731 -0.2049 -0.2559 -0.2187 -0.1296 -0.0388 -0.0274  0.0409
% 0.0814  0.0426  0.0848  0.0753  0.0361  0.0510  0.0386  0.0138 -0.0358 -0.0506
% -0.6578 -0.6871 -0.6657 -0.6902 -0.6629 -0.7067 -0.7094 -0.6910 -0.6810 -0.7218
% -0.0170  0.0839  0.1164  0.1762  0.2713  0.3503  0.3810  0.4841  0.5302  0.5598
% -0.1624 -0.1465 -0.1889 -0.2010 -0.1970 -0.1795 -0.2020 -0.2003 -0.2651 -0.2536

% Columns 11 through 20

% 0.7409  0.7543  0.7677  0.8122  0.8017  0.8729  0.1349  0.0412 -0.0477 -0.1270
% -0.0377 -0.0190  0.0091  0.0040  0.0030  0.0332 -0.0619 -0.0551 -0.0524 -0.0746
% -0.0824 -0.0387 -0.0655 -0.0397 -0.0691 -0.0564 -0.1711 -0.1829 -0.1930 -0.1905
% -1.7509 -1.7601 -1.8057 -1.7808 -1.8378 -1.7927 -1.6069 -1.6502 -1.5872 -1.6409
% 0.3421  0.3295  0.2906  0.2612  0.2675  0.2415  0.6177  0.6305  0.6365  0.6348
% -0.0113  0.0203  0.0382  0.0861  0.1357  0.1567 -0.4315 -0.4928 -0.5690 -0.6068
% -0.2233 -0.2479 -0.4189 -0.4741 -0.5562 -0.5256  0.3726  0.3156  0.4167  0.3829
% 0.5231  0.5389  0.6021  0.6313  0.7281  0.7385 -0.1304 -0.1442 -0.2474 -0.2623
% 0.0202  0.0594  0.0526  0.0666  0.0691  0.0616 -0.0848 -0.0411 -0.0586 -0.0990
% 0.0515  0.1490  0.3015  0.3536  0.4392  0.3788 -0.3417 -0.2972 -0.3550 -0.2984
% -0.0685 -0.0646 -0.0994 -0.0967 -0.1505 -0.1954  0.0865  0.0881  0.1384  0.1117

```

%	-0.7420	-0.7234	-0.7226	-0.7530	-0.7635	-0.7332	-0.6847	-0.7103	-0.7044	-0.6520
%	0.6523	0.7126	0.7664	0.8802	0.9105	0.9759	-0.1121	-0.1974	-0.2522	-0.3053
%	-0.2589	-0.3058	-0.2521	-0.3167	-0.3171	-0.3070	-0.1280	-0.1061	-0.0918	-0.1337

% Columns 21 through 30

%	-0.2681	-0.3467	-0.4955	-0.6452	-0.7411	-0.8673	-1.0535	-1.2215	-1.3613	-1.5207
%	-0.0689	-0.0991	-0.0893	-0.0738	-0.0845	-0.0975	-0.0949	-0.1092	-0.1062	-0.1529
%	-0.1988	-0.2259	-0.2172	-0.1907	-0.2257	-0.2300	-0.2694	-0.2753	-0.2779	-0.2477
%	-1.6077	-1.6083	-1.5819	-1.6121	-1.6134	-1.6022	-1.6109	-1.6292	-1.6583	-1.6230
%	0.6639	0.6896	0.7119	0.7750	0.7691	0.8252	0.8484	0.8809	0.8779	0.9050
%	-0.6423	-0.7063	-0.7408	-0.7704	-0.8492	-0.8514	-0.9464	-0.9744	-1.0405	-1.0921
%	0.3553	0.3344	0.3278	0.3103	0.2765	0.2688	0.1809	0.0866	0.0474	-0.0668
%	-0.3553	-0.3675	-0.4552	-0.4734	-0.5474	-0.5580	-0.6316	-0.6666	-0.7456	-0.8179
%	-0.0961	-0.0904	-0.1212	-0.0895	-0.1008	-0.1405	-0.1527	-0.1250	-0.1613	-0.1322
%	-0.2724	-0.2268	-0.1698	-0.1079	-0.1335	-0.0403	0.0644	0.1555	0.2855	0.3936
%	0.1442	0.1190	0.1248	0.1565	0.1745	0.1573	0.1526	0.1795	0.1617	0.1596
%	-0.6645	-0.6880	-0.6651	-0.6915	-0.6617	-0.6872	-0.6704	-0.7215	-0.6740	-0.6771
%	-0.3426	-0.4243	-0.4945	-0.5704	-0.6256	-0.7206	-0.7841	-0.7882	-0.9093	-0.9221
%	-0.1088	-0.0627	-0.0955	-0.0646	-0.0418	-0.0730	-0.0646	-0.0231	-0.0441	-0.0016

% Columns 31 through 32

%	-1.7137	-1.9445
%	-0.1134	-0.1545
%	-0.2749	-0.2919
%	-1.6469	-1.6880
%	0.9738	1.0137
%	-1.1872	-1.2596
%	-0.0919	-0.3618
%	-0.8255	-0.8923
%	-0.1637	-0.1659
%	0.4433	0.7602
%	0.1861	0.1776
%	-0.7051	-0.7132
%	-0.9973	-1.0500
%	-0.0319	-0.0147

% [14x14 double]

% [2x14 double]

%BIAS

%	0.8631
%	-0.6911
%	-0.1436
%	1.5752
%	0.9737
%	-0.2871
%	1.2714
%	-0.0085
%	0.0883
%	-0.4668
%	-1.6202

% 1.0879
% -2.2857
% -1.9395

% -1.0805
% 0.9303
% -1.2051
% -1.2996
% 0.8955
% -0.4483
% -0.0525
% 0.7153
% -0.9295
% -1.0898
% -0.8836
% 0.6044
% 1.4241
% -1.4798

% -0.8346
% -0.6509

TESTE BP LEVENBERG-MARQUARDT
PARA DADOS SIMULADOS NO PROGRAMA TOPEOL PARA O EXPERIMENTO TOKAMAK
ESFÉRICO (ETE)

```
% Rede Neural Artificial
% tipo FeedForward - BackPropagation
% BackPropagation Levenberg-Marquardt(trainlm)
%
% PLASMA CONTROL EQUILIBRIUM
%
%LFWBarbosa - 2001
%
% RNA 7-14-14-2 pesos rna_tokamak_lm
% TESTE com a RNA ja' Treinada
%
tic;
test.P=[-0.238 4.956 -5.241 -15.0 -17.8 9.813 -9.335 ; -0.143 4.905 -5.268 -15.1 -17.7 9.921 -
9.233 ; ...
-0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; -0.681 5.150 -5.135 -14.6 -18.1 9.382 -
9.743 ; ...
-0.873 5.283 -5.077 -14.4 -18.3 9.091 -10.000 ; -0.712 5.201 -5.110 -14.5 -18.2 9.224 -
9.844 ; ...
-0.476 5.082 -5.168 -14.8 -18.0 9.544 -9.590 ; -0.238 4.956 -5.241 -15.0 -17.8 9.813 -
9.335 ; ...
0.112 4.790 -5.333 -15.2 -17.5 10.200 -8.958 ; 0.472 4.613 -5.450 -15.6 -17.2 10.600 -
8.571 ; ...
0.709 4.508 -5.522 -15.9 -17.0 10.900 -8.316 ; 0.785 4.476 -5.547 -15.9 -16.9 11.000 -
8.235 ; ...
0.766 4.485 -5.539 -15.9 -16.9 11.000 -8.255 ; 0.576 4.566 -5.481 -15.7 -17.1 10.700 -
8.459 ; ...
0.282 4.707 -5.389 -15.5 -17.3 10.400 -8.775 ; 0.083 4.800 -5.327 -15.3 -17.5 10.200 -
8.989 ; ...
-0.447 5.071 -5.173 -14.8 -18.0 9.576 -9.559 ; -0.197 4.748 -5.362 -15.4 -17.4 10.300 -
8.867 ; ...
-0.093 4.884 -5.279 -15.1 -17.7 9.975 -9.183 ; -0.381 5.033 -5.199 -14.9 -17.9 9.652 -
9.488 ; ...
-0.627 5.155 -5.132 -14.6 -18.1 9.371 -9.753 ; -0.798 5.243 -5.093 -14.5 -18.3 9.177 -
9.936 ; ...
-1.130 5.432 -5.007 -14.2 -18.5 8.800 -10.300 ; -1.281 5.516 -4.971 -14.0 -18.7 8.628 -
10.500 ; ...
-1.728 5.776 -4.877 -13.6 -19.0 8.122 -10.900 ; -1.898 5.876 -4.843 -13.4 -19.2 7.928 -
11.100 ; ...
-1.424 5.598 -4.942 -13.9 -18.8 8.466 -10.600 ; -1.225 5.482 -4.986 -14.1 -18.6 8.692 -
10.400 ; ...
-0.750 5.219 -5.104 -14.5 -18.2 9.231 -9.885 ; -0.266 4.971 -5.233 -15.0 -17.8 9.781 -
9.366 ; ...
-0.206 4.774 -5.364 -15.4 -17.4 10.300 -8.857 ; -0.219 4.946 -5.246 -15.0 -17.8 9.835 -
9.315];

disp('SAIDA');
a = sim(net,p)
toc;
disp('ALVO = -0.0016 4.839 -5.304 -15.2 -17.6 10.1 -9.080');
disp('.');
```

```

disp('.');
%disp('m e b - Ajustes na Curva e r - Correlacao SAIDA-ALVO');
%[m, b, r] = postreg(a,t)
disp('PESOS');
net.IW{1,1}
net.LW(2,1)
net.LW(3,2)
disp('BIAS');
net.b{1}
net.b{2}
net.b{3}

%>> rna_tokamak_lm_TESTE
%SAIDA

%a =
% -0.0016  4.8390 -5.3040 -15.2000 -17.6000 10.1000 -9.0800
% -0.0016  4.8390 -5.3040 -15.2000 -17.6000 10.1000 -9.0800

%elapsed_time = 0.01

%ALVO = -0.0016  4.839 -5.304 -15.2 -17.6 10.1 -9.080

%PESOS

% Columns 1 through 10

% 0.2617  0.3269  0.4226  0.4734  0.5259  0.5612  0.6182  0.6506  0.7047  0.7102
% -0.0285 -0.0633 -0.0164 -0.0113 -0.0570 -0.0029 -0.0395 -0.0428  0.0132 -0.0234
% -0.1679 -0.1593 -0.1463 -0.1250 -0.1041 -0.0738 -0.1221 -0.0908 -0.1138 -0.1041
% -1.6512 -1.6094 -1.6281 -1.6780 -1.6388 -1.6736 -1.6816 -1.6988 -1.7170 -1.7597
% 0.5224  0.5409  0.4693  0.4671  0.4350  0.4597  0.4015  0.3933  0.3762  0.3553
% -0.3582 -0.3631 -0.3195 -0.2382 -0.2140 -0.2056 -0.1170 -0.1098 -0.1033 -0.0693
% 0.3589  0.3453  0.2233  0.1861  0.1948  0.1338  0.0630 -0.0377 -0.0660 -0.1277
% -0.0197  0.0634  0.1151  0.1628  0.1867  0.2362  0.2940  0.3285  0.3982  0.4515
% -0.0696 -0.0643 -0.0564 -0.0048 -0.0021  0.0026  0.0239 -0.0118 -0.0232  0.0339
% -0.2948 -0.3164 -0.2731 -0.2049 -0.2559 -0.2187 -0.1296 -0.0388 -0.0274  0.0409
% 0.0814  0.0426  0.0848  0.0753  0.0361  0.0510  0.0386  0.0138 -0.0358 -0.0506
% -0.6578 -0.6871 -0.6657 -0.6902 -0.6629 -0.7067 -0.7094 -0.6910 -0.6810 -0.7218
% -0.0170  0.0839  0.1164  0.1762  0.2713  0.3503  0.3810  0.4841  0.5302  0.5598
% -0.1624 -0.1465 -0.1889 -0.2010 -0.1970 -0.1795 -0.2020 -0.2003 -0.2651 -0.2536

% Columns 11 through 20

% 0.7409  0.7543  0.7677  0.8122  0.8017  0.8729  0.1349  0.0412 -0.0477 -0.1270
% -0.0377 -0.0190  0.0091  0.0040  0.0030  0.0332 -0.0619 -0.0551 -0.0524 -0.0746
% -0.0824 -0.0387 -0.0655 -0.0397 -0.0691 -0.0564 -0.1711 -0.1829 -0.1930 -0.1905
% -1.7509 -1.7601 -1.8057 -1.7808 -1.8378 -1.7927 -1.6069 -1.6502 -1.5872 -1.6409
% 0.3421  0.3295  0.2906  0.2612  0.2675  0.2415  0.6177  0.6305  0.6365  0.6348
% -0.0113  0.0203  0.0382  0.0861  0.1357  0.1567 -0.4315 -0.4928 -0.5690 -0.6068
% -0.2233 -0.2479 -0.4189 -0.4741 -0.5562 -0.5256  0.3726  0.3156  0.4167  0.3829
% 0.5231  0.5389  0.6021  0.6313  0.7281  0.7385 -0.1304 -0.1442 -0.2474 -0.2623
% 0.0202  0.0594  0.0526  0.0666  0.0691  0.0616 -0.0848 -0.0411 -0.0586 -0.0990
% 0.0515  0.1490  0.3015  0.3536  0.4392  0.3788 -0.3417 -0.2972 -0.3550 -0.2984
% -0.0685 -0.0646 -0.0994 -0.0967 -0.1505 -0.1954  0.0865  0.0881  0.1384  0.1117
% -0.7420 -0.7234 -0.7226 -0.7530 -0.7635 -0.7332 -0.6847 -0.7103 -0.7044 -0.6520

```

```
% 0.6523 0.7126 0.7664 0.8802 0.9105 0.9759 -0.1121 -0.1974 -0.2522 -0.3053
% -0.2589 -0.3058 -0.2521 -0.3167 -0.3171 -0.3070 -0.1280 -0.1061 -0.0918 -0.1337
```

```
% Columns 21 through 30
```

```
% -0.2681 -0.3467 -0.4955 -0.6452 -0.7411 -0.8673 -1.0535 -1.2215 -1.3613 -1.5207
% -0.0689 -0.0991 -0.0893 -0.0738 -0.0845 -0.0975 -0.0949 -0.1092 -0.1062 -0.1529
% -0.1988 -0.2259 -0.2172 -0.1907 -0.2257 -0.2300 -0.2694 -0.2753 -0.2779 -0.2477
% -1.6077 -1.6083 -1.5819 -1.6121 -1.6134 -1.6022 -1.6109 -1.6292 -1.6583 -1.6230
% 0.6639 0.6896 0.7119 0.7750 0.7691 0.8252 0.8484 0.8809 0.8779 0.9050
% -0.6423 -0.7063 -0.7408 -0.7704 -0.8492 -0.8514 -0.9464 -0.9744 -1.0405 -1.0921
% 0.3553 0.3344 0.3278 0.3103 0.2765 0.2688 0.1809 0.0866 0.0474 -0.0668
% -0.3553 -0.3675 -0.4552 -0.4734 -0.5474 -0.5580 -0.6316 -0.6666 -0.7456 -0.8179
% -0.0961 -0.0904 -0.1212 -0.0895 -0.1008 -0.1405 -0.1527 -0.1250 -0.1613 -0.1322
% -0.2724 -0.2268 -0.1698 -0.1079 -0.1335 -0.0403 0.0644 0.1555 0.2855 0.3936
% 0.1442 0.1190 0.1248 0.1565 0.1745 0.1573 0.1526 0.1795 0.1617 0.1596
% -0.6645 -0.6880 -0.6651 -0.6915 -0.6617 -0.6872 -0.6704 -0.7215 -0.6740 -0.6771
% -0.3426 -0.4243 -0.4945 -0.5704 -0.6256 -0.7206 -0.7841 -0.7882 -0.9093 -0.9221
% -0.1088 -0.0627 -0.0955 -0.0646 -0.0418 -0.0730 -0.0646 -0.0231 -0.0441 -0.0016
```

```
% Columns 31 through 32
```

```
% -1.7137 -1.9445
% -0.1134 -0.1545
% -0.2749 -0.2919
% -1.6469 -1.6880
% 0.9738 1.0137
% -1.1872 -1.2596
% -0.0919 -0.3618
% -0.8255 -0.8923
% -0.1637 -0.1659
% 0.4433 0.7602
% 0.1861 0.1776
% -0.7051 -0.7132
% -0.9973 -1.0500
% -0.0319 -0.0147
```

```
% [14x14 double]
```

```
% [2x14 double]
```

```
%BIAS
```

```
% 0.8631
% -0.6911
% -0.1436
% 1.5752
% 0.9737
% -0.2871
% 1.2714
% -0.0085
% 0.0883
% -0.4668
% -1.6202
% 1.0879
```

% -2.2857
% -1.9395

% -1.0805
% 0.9303
% -1.2051
% -1.2996
% 0.8955
% -0.4483
% -0.0525
% 0.7153
% -0.9295
% -1.0898
% -0.8836
% 0.6044
% 1.4241
% -1.4798

% -0.8346
% -0.6509

APÊNDICE D

CONJUNTO DE TREINAMENTO DE RNA PLASMA IP=15KA

DESLOCAMENTO POSITIVO

Tipo de Deslocamento	N°	Incremento (kA)	Corrente Vertical (kA)		Z (mm)	Zo (mm)	SD01 (mT)	SDS02 (mT)	SDI02 (mT)	SDS06 (mT)	SDI06 (mT)	SDS09 (mT)	SDI09 (mT)
		0.0	SUP	INF	0.269	0.157	-0.896	4.839	-5.302	-15.2	-17.6	-16.1	-9.980
POSITIVO	1	0.5	23.5	24.5	2.22	1.72	-0.238	4.956	-5.241	-15.0	-17.8	9.813	-9.335
POSITIVO	2	0.5	23	25	4.48	4.75	-0.476	5.082	-5.168	-14.8	-18.0	9.544	-9.590
POSITIVO	3	0.5	22.5	25.5	6.76	6.33	-0.712	5.201	-5.110	-14.5	-18.2	9.274	-9.844
POSITIVO	4	0.5	22	26	8.98	8.43	-0.949	5.327	-5.057	-14.3	-18.4	9.005	-10.100
POSITIVO	5	0.5	21.5	26.5	11.40	11.20	-1.187	5.462	-4.994	-14.1	-18.6	8.736	-10.400
POSITIVO	6	0.5	21	27	13.70	12.80	-1.424	5.598	-4.942	-13.9	-18.8	8.466	-10.600
POSITIVO	7	0.5	20.5	27.5	15.80	15.50	-1.661	5.735	-4.894	-13.7	-19.0	8.197	-10.900
POSITIVO	8	0.5	20	28	18.20	17.60	-1.898	5.876	-4.843	-13.4	-19.2	7.928	-11.100
POSITIVO	9	0.5	19.5	28.5	20.60	19.40	-2.136	6.027	-4.799	-13.2	-19.4	7.659	-11.400
POSITIVO	10	0.5	19	29	22.80	22.40	-2.373	6.181	-4.751	-13.0	-19.6	7.390	-11.600
POSITIVO	11	0.5	18.5	29.5	25.20	24.10	-2.611	6.338	-4.710	-12.8	-19.8	7.121	-11.900
POSITIVO	12	0.5	18	30	27.50	26.40	-2.848	6.501	-4.673	-12.6	-20.0	6.852	-12.100
POSITIVO	13	0.5	17.5	30.5	29.70	29.00	-3.085	6.655	-4.637	-12.3	-20.2	6.583	-12.400
POSITIVO	14	0.5	17	31	32.30	30.60	-3.323	6.833	-4.601	-12.1	-20.4	6.314	-12.700
POSITIVO	15	0.5	16.5	31.5	34.50	33.70	-3.561	7.005	-4.569	-11.9	-20.6	6.045	-12.900
POSITIVO	16	0.5	16	32	38.10	36.30	-3.804	7.264	-4.500	-11.7	-20.8	5.781	-13.200

CONJUNTO DE TREINAMENTO DE RNA PLASMA IP=15kA

DESLOCAMENTO NEGATIVO

Tipo de Deslocamento	Nº	Incremento (kA)	Corrente Vertical (kA)		Z (mm)	Zo (mm)	SD01 (mT)	SDS02 (mT)	SDI02 (mT)	SDS06 (mT)	SDI06 (mT)	SDS09 (mT)	SDI09 (mT)
			SUP	INF									
EQUILIBRIO	0	0	24	24	-0.269	-0.0157	0.0016	4.319	-5.307	-15.2	-17.6	10.1	-9.080
NEGATIVO	1	0.5	24.5	23.5	-2.31	-1.84	0.235	4.731	-5.373	-15.4	-17.4	10.4	-8.826
NEGATIVO	2	0.5	25	23	-4.52	-4.78	0.472	4.613	-5.450	-15.6	-17.2	10.6	-8.571
NEGATIVO	3	0.5	25.5	22.5	-6.85	-6.58	0.709	4.508	-5.522	-15.9	-17.0	10.9	-8.316
NEGATIVO	4	0.5	26	22	-9.05	-8.54	0.946	4.408	-5.602	-16.1	-16.8	11.2	-8.062
NEGATIVO	5	0.5	26.5	21.5	-11.40	-11.20	1.184	4.300	-5.686	-16.3	-16.6	11.4	-7.808
NEGATIVO	6	0.5	27	21	-13.70	-12.80	1.421	4.205	-5.773	-16.5	-16.4	11.7	-7.554
NEGATIVO	7	0.5	27.5	20.5	-15.90	-15.60	1.658	4.111	-5.861	-16.7	-16.2	12.0	-7.300
NEGATIVO	8	0.5	28	20	-18.30	-17.70	1.895	4.015	-5.955	-16.9	-16.0	12.2	-7.046
NEGATIVO	9	0.5	28.5	19.5	-20.60	-19.40	2.132	3.926	-6.056	-17.2	-15.7	12.5	-6.791
NEGATIVO	10	0.5	29	19	-22.80	-22.40	2.370	3.834	-6.157	-17.4	-15.5	12.8	-6.537
NEGATIVO	11	0.5	29.5	18.5	-25.30	-24.10	2.607	3.747	-6.265	-17.6	-15.3	13.1	-6.282
NEGATIVO	12	0.5	30	18	-27.50	-26.30	2.845	3.664	-6.378	-17.8	-15.1	13.3	-6.028
NEGATIVO	13	0.5	30.5	17.5	-29.80	-29.10	3.082	3.579	-6.488	-18.0	-14.9	13.6	-5.773
NEGATIVO	14	0.5	31	17	-32.30	-30.60	3.320	3.499	-6.614	-18.2	-14.7	13.9	-5.519
NEGATIVO	15	0.5	31.5	16.5	-34.60	-33.20	3.557	3.423	-6.734	-18.5	-14.5	14.1	-5.264
NEGATIVO	16	0.5	32	16	-38.10	-36.20	3.800	3.310	-6.928	-18.7	-14.3	14.4	-5.014

CONJUNTO DE TESTE DA RNA PLASMA (IP=15kA)

DESLOCAMENTO POSITIVO

Tipo de Deslocamento	N°	Incremento (kA)	Corrente Vertical (kA)		Z plasma (mm)	Zo mag. (mm)	SD01 (mT)	SDS02 (mT)	SDI02 (mT)	SDS06 (mT)	SDI06 (mT)	SDS09 (mT)	SDI09 (mT)
			SUP	INF									
POSITIVO	1	0.3	23.7	24.3	1.331	0.879	-0.143	4.905	-5.268	-15.1	-17.7	9.921	-9.233
POSITIVO	2	0.8	22.9	25.1	4.890	5.130	-0.523	5.104	-5.158	-14.7	-18.0	9.490	-9.641
POSITIVO	3	0.3	22.6	25.4	6.314	6.031	-0.665	5.177	-5.121	-14.6	-18.1	9.328	-9.794
POSITIVO	4	0.8	21.8	26.2	9.930	9.899	-1.045	5.384	-5.029	-14.2	-18.5	8.897	-10.2
POSITIVO	5	0.8	21	27	13.700	12.800	-1.420	5.598	-4.942	-13.9	-18.8	8.466	-10.6
POSITIVO	6	0.3	20.7	27.3	15.000	14.100	-1.560	5.682	-4.914	-13.8	-18.9	8.305	-10.8
POSITIVO	7	0.2	20.5	27.5	15.800	15.500	-1.661	5.735	-4.894	-13.7	-19.0	8.197	-10.9
POSITIVO	8	0.6	19.9	28.1	18.700	17.900	-1.946	5.905	-4.833	-13.4	-19.2	7.874	-11.2
POSITIVO	9	0.8	19.1	28.9	22.300	21.900	-2.326	6.145	-4.764	-13.0	-19.6	7.444	-11.6
POSITIVO	10	0.3	18.8	29.2	23.700	23.100	-2.468	6.237	-4.738	-12.9	-19.7	7.283	-11.7
POSITIVO	11	0.2	18.6	29.4	24.700	23.800	-2.563	6.299	-4.720	-12.8	-19.8	7.175	-11.8
POSITIVO	12	0.8	17.8	30.2	28.400	27.700	-2.943	6.558	-4.660	-12.5	-20.1	6.745	-12.2
POSITIVO	13	0.6	17.2	30.8	32.200	30.500	-3.232	6.717	-4.586	-12.2	-20.3	6.426	-12.6
POSITIVO	14	0.4	16.8	31.2	33.200	31.600	-3.419	6.908	-4.546	-12.0	-20.5	6.207	-12.8
POSITIVO	15	0.2	16.6	31.4	34.000	32.900	-3.513	6.967	-4.577	-11.9	-20.6	6.099	-12.9
POSITIVO	16	0.8	15.8	32.2	39.000	37.100	-3.899	7.337	-4.489	-11.6	-20.9	5.673	-13.3

CONJUNTO DE TESTE DA RNA PLASMA (IP=15kA)

DESLOCAMENTO NEGATIVO

Tipo de Deslocamento	N°	Incremento (kA)	Corrente Vertical (kA)		Z plasma (mm)	Zo mag. (mm)	SD01 (mT)	SDS02 (mT)	SDI02 (mT)	SDS06 (mT)	SDI06 (mT)	SDS09 (mT)	SDI09 (mT)
EQUILIBRIO	0	0.0	24.3	23.7	-1.420	-0.951	0.140	4.775	-5.342	-15.3	-17.4	10.2	-8.820
NEGATIVO	1	0.3	24.3	23.7	-1.420	-0.951	0.140	4.775	-5.342	-15.3	-17.4	10.2	-8.820
NEGATIVO	2	0.8	25.1	22.9	-4.946	-5.132	0.519	4.594	-5.461	-15.7	-17.2	10.7	-8.520
NEGATIVO	3	0.3	25.4	22.6	-6.395	-6.082	0.662	4.527	-5.509	-15.8	-17.0	10.8	-8.367
NEGATIVO	4	0.8	26.2	21.8	-9.980	-9.950	1.041	4.362	-5.639	-16.2	-16.7	11.3	-7.960
NEGATIVO	5	0.8	27	21	-13.700	-12.800	1.421	4.205	-5.773	-16.5	-16.4	11.7	-7.554
NEGATIVO	6	0.3	27.3	20.7	-15.000	-14.200	1.563	4.150	-5.826	-16.6	-16.6	11.9	-7.401
NEGATIVO	7	0.2	27.5	20.5	-15.900	-15.600	1.658	4.111	-5.861	-16.7	-16.7	12.0	-7.300
NEGATIVO	8	0.6	28.1	19.9	-18.700	-17.900	1.942	3.996	-5.973	-17.0	-15.9	12.3	-6.994
NEGATIVO	9	0.8	28.9	19.1	-22.300	-21.900	2.320	3.856	-6.131	-17.3	-15.6	12.7	-6.588
NEGATIVO	10	0.3	29.2	18.8	-23.700	-23.100	2.464	3.803	-6.192	-17.5	-15.5	12.9	-6.435
NEGATIVO	11	0.2	29.4	18.6	-24.800	-23.800	2.560	3.764	-6.242	-17.7	-15.4	13.0	-6.333
NEGATIVO	12	0.8	30.2	17.8	-28.400	-27.700	2.939	3.632	-6.419	-17.9	-15.1	13.4	-5.926
NEGATIVO	13	0.6	30.8	17.2	-32.200	-30.500	3.229	3.507	-6.612	-18.2	-14.8	13.8	-5.624
NEGATIVO	14	0.4	31.2	16.8	-33.200	-31.500	3.415	3.470	-6.660	-18.3	-14.7	14.0	-5.417
NEGATIVO	15	0.2	31.4	16.6	-34.100	-32.900	3.510	3.440	-6.705	-18.4	-14.6	14.1	-5.315
NEGATIVO	16	0.8	32.2	15.8	-39.000	-37.100	3.896	3.281	-6.983	-18.8	-14.3	14.5	-4.913

CONJUNTO REALISTA DE TESTE DA RNA PLASMA (IP=15KA)
DESLOCAMENTO DELTA ~20MM DO EIXO HORIZONTAL

Tipo de Deslocamento	Nº	Incremento (kA)	Corrente Vertical (kA)		Z plasma (mm)	Zo mag. (mm)	SD01 (mT)	SDS02 (mT)	SDI02 (mT)	SDS06 (mT)	SDI06 (mT)	SDS09 (mT)	SDI09 (mT)
			SUP	INF									
POSITIVO	1	0.50	23.50	24.50	2.226	1.742	-0.238	4.956	-5.241	-15.0	-17.8	9.813	-9.335
NEGATIVO	2	0.30	23.70	24.30	1.331	0.879	-0.143	4.905	-5.268	-15.1	-17.7	9.921	-9.233
POSITIVO	3	1.00	23.00	25.00	4.483	4.756	-0.476	5.082	-5.168	-14.8	-18.0	9.544	-9.590
POSITIVO	4	1.30	22.70	25.30	5.864	5.735	-0.681	5.150	-5.135	-14.6	-18.1	9.382	-9.743
POSITIVO	5	1.84	22.16	25.84	8.272	7.545	-0.873	5.283	-5.077	-14.4	-18.3	9.091	-10.000
NEGATIVO	6	1.50	22.50	25.50	6.765	6.330	-0.712	5.201	-5.110	-14.5	-18.2	9.224	-9.844
NEGATIVO	7	1.00	23.00	25.00	4.483	4.756	-0.476	5.082	-5.168	-14.8	-18.0	9.544	-9.590
NEGATIVO	8	0.50	23.50	24.50	2.226	1.742	-0.238	4.956	-5.241	-15.0	-17.8	9.813	-9.335
NEGATIVO	9	-0.24	24.24	23.16	-1.143	-1.407	0.112	4.790	-5.333	-15.2	-17.5	10.200	-8.958
NEGATIVO	10	-1.00	25.00	23.00	-4.521	-4.785	0.472	4.613	-5.450	-15.6	-17.2	10.600	-8.571
NEGATIVO	11	-1.50	25.50	22.50	-6.855	-6.385	0.709	4.508	-5.522	-15.9	-17.0	10.900	-8.316
NEGATIVO	12	-1.66	25.66	22.34	-7.636	-6.916	0.785	4.476	-5.547	-15.9	-16.9	11.000	-8.235
POSITIVO	13	-1.62	25.62	22.38	-7.468	-6.774	0.766	4.485	-5.539	-15.9	-16.9	11.000	-8.255
POSITIVO	14	-1.22	25.22	22.78	-5.631	-5.568	0.576	4.566	-5.481	-15.7	-17.1	10.700	-8.459
POSITIVO	15	-0.60	24.60	23.40	-2.768	-2.452	0.282	4.707	-5.389	-15.5	-17.3	10.400	-8.775
POSITIVO	16	-0.18	24.18	23.82	-0.837	-0.554	0.083	4.800	-5.327	-15.3	-17.5	10.200	-8.989
POSITIVO	17	0.94	23.06	24.94	4.231	4.616	-0.447	5.071	-5.173	-14.8	-18.0	9.576	-9.559
NEGATIVO	18	-0.42	24.42	23.58	-1.969	-1.458	-0.197	4.748	-5.362	-15.4	-17.4	10.300	-8.867
POSITIVO	19	0.20	23.80	24.20	0.827	0.550	-0.093	4.884	-5.279	-15.1	-17.7	9.975	-9.183
POSITIVO	20	0.80	23.20	24.80	3.553	3.724	-0.381	5.033	-5.199	-14.9	-17.9	9.652	-9.488
POSITIVO	21	1.32	22.68	25.32	5.957	5.794	-0.627	5.155	-5.132	-14.6	-18.1	9.371	-9.753
POSITIVO	22	1.68	22.32	25.68	7.618	6.909	-0.798	5.243	-5.093	-14.5	-18.3	9.177	-9.936
POSITIVO	23	2.38	21.62	26.38	10.700	10.800	-1.130	5.432	-5.007	-14.2	-18.5	8.800	-10.300
POSITIVO	24	2.70	21.30	26.70	12.300	11.800	-1.281	5.516	-4.971	-14.0	-18.7	8.628	-10.500
POSITIVO	25	3.64	20.36	27.64	16.500	16.200	-1.728	5.776	-4.877	-13.6	-19.0	8.122	-10.900
POSITIVO	26	4.00	20.00	28.00	18.200	17.600	-1.898	5.876	-4.843	-13.4	-19.2	7.928	-11.100
NEGATIVO	27	3.00	21.00	27.00	13.700	12.800	-1.424	5.598	-4.942	-13.9	-18.8	8.466	-10.600
NEGATIVO	28	2.58	21.42	26.58	11.700	11.500	-1.225	5.482	-4.986	-14.1	-18.6	8.692	-10.400
NEGATIVO	29	1.58	22.42	25.58	7.170	6.577	-0.750	5.219	-5.104	-14.5	-18.2	9.231	-9.885
NEGATIVO	30	0.56	23.44	24.56	2.485	2.077	-0.266	4.971	-5.233	-15.0	-17.8	9.781	-9.366
NEGATIVO	31	-0.44	24.44	23.56	-2.056	-1.542	-0.206	4.774	-5.364	-15.4	-17.4	10.300	-8.857
POSITIVO	32	0.46	23.54	24.46	2.059	1.552	-0.219	4.946	-5.246	-15.0	-17.8	9.835	-9.315