

**ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

TRABALHO DE FORMATURA

**TEMA: MODELAGEM DE UM MOTOR MOVIDO A
GÁS NATURAL E UM DINAMÔMETRO HIDRÁULICO
ATRAVÉS DE REDES NEURAIS**

**ORIENTADOR: PROF. DR. AGENOR DE TOLEDO FLEURY
COORIENTADORES: JOSÉ AUGUSTO LOPES
NEY RICARDO MOSCATI**

ALUNOS:

**GUSTAVO HENRIQUE TAVARES SILVA BELLON Nº USP: 2847806
PAULO ROBERTO MOTOKI Nº USP: 2829719**

SÃO PAULO, DEZEMBRO/96

HOMENAGEM

Ao mestre-amigo Agenor de Toledo Fleury,
pelo idealismo, otimismo, coerência e consultoria psicológica gratuita
concedida aos alunos do curso de Engenharia Mecatrônica durante os 5 anos
de Poli.

Aos amigos/coorientadores José Augusto Lopes & Ney Ricardo Moscati,
pela paciência, sinceridade, companheirismo e dicas fundamentais nas árduas
batalhas contra Madalines e Adalines da vida.

Aos nossos pais, mães, irmãos, irmãs e namoradas,
pelo incentivo, alegrias compartilhadas, compreensão e conforto nos
momentos difíceis.

ÍNDICE

CAPÍTULO 1 - MOTIVAÇÃO, OBJETIVOS E ESTRUTURA DO TRABALHO.....	2
1.1 Motivação.....	2
1.1.1 Catalisadores, relação ar-combustível e controle de injeção.....	3
1.1.2 O IPT e o controle de injeção.....	5
1.1.3 Importância dos modelos do motor e do dinamômetro.....	5
1.2 Objetivo do trabalho.....	6
1.2.1 Modelos fenomenológicos e modelos via Redes Neurais.....	6
1.3 Estrutura do trabalho.....	7
CAPÍTULO 2 - MODELO FENOMENOLÓGICO DO MOTOR A GÁS.....	9
2.1 Evolução dos modelos.....	9
2.2 Representação do motor e as hipóteses simplificadoras.....	10
2.3 O modelo do motor.....	11
2.3.1 Subsistema do coletor de admissão.....	12
2.3.2 Subsistema de combustão.....	15
2.3.3 Subsistema da dinâmica rotacional.....	16
2.4 A dinâmica do motor.....	17
CAPÍTULO 3 - MODELO FENOMENOLÓGICO DO DINAMÔMETRO.....	19
3.1 O modelo do dinamômetro.....	21
3.2 Dinâmica do dinamômetro.....	24
CAPÍTULO 4 - REDES NEURAIS.....	28
4.1 História.....	28
4.2 Funcionamento básico.....	29
CAPÍTULO 5 - O PROCESSO DE IMPLEMENTAÇÃO DAS REDES.....	36
5.1 Primeiro passo: algoritmo em Pascal.....	36
5.2 Segundo passo: identificação de sistemas lineares dinâmicos.....	36
5.3 Terceiro passo: identificação de sistemas não-lineares e dinâmicos.....	37
5.4 Quarto passo: modelagem final dos modelos do motor e do dinamômetro.....	38
5.4.1 Etapa 1: definição das variáveis de entrada e saída que se deseja modelar.....	38
5.4.2 Etapa 2: definição da estrutura das redes.....	39

5.4.3 Etapa 3: definição do algoritmo de aprendizado.....	40
5.4.4 Etapa 4: definição de quantas entradas e saídas anteriores deveriam ser informadas para o treinamento das redes.....	40
CAPÍTULO 6 - RESULTADOS OBTIDOS.....41	
6.1 Motor.....	41
6.2 Dinamômetro.....	47
CAPÍTULO 7 - CONTROLE ATRAVÉS DE REDES NEURAIS.....51	
CAPÍTULO 8 - CONCLUSÕES DO TRABALHO.....54	
ANEXOS.....57	
Anexo A: Implementação do programa teste em Pascal.....	58
Anexo B: Implementação no Matlab dos programas de treinamento e simulação das redes do motor e do dinamômetro.....	66
Anexo C: Explicações a respeito das funções pré-definidas utilizadas nos programas.....	71
BIBLIOGRAFIA.....72	

LISTA DE FIGURAS

Figura 1: Esquema geral de controle do sistema de injeção e ignição.....	3
Figura 2: Eficiência do catalisador em função da variação da relação ar-combustível.....	4
Figura 3: Representação esquemática do motor.....	10
Figura 4: Visão geral do modelo dinâmico do motor.....	11
Figura 5: Três subsistemas do modelo do motor.....	12
Figura 6: Subsistema do coletor de admissão.....	13
Figura 7: Modelo da dinâmica do ar.....	13
Figura 8: Modelo da dinâmica do combustível.....	14
Figura 9: Subsistema de combustão.....	15
Figura 10: Subsistema da Dinâmica rotacional.....	16
Figura 11: Entradas de simulação para o modelo do motor.....	17
Figura 12: Saídas do modelo do motor para a simulação feita.....	18
Figura 13: Esquema geral do dinamômetro.....	20
Figura 14: Modelo fenomenológico do dinamômetro.....	21
Figura 15: Bloco Valv.Pistão.....	22
Figura 16: Entrada de simulação ao modelo do dinamômetro.....	24
Figura 17: Rotação.....	25
Figura 18: Variação do ângulo da válvula(alfa).....	26
Figura 19: Espessura do filme de água na câmara de turbilhonamento.....	27
Figura 20a: Neurônio.....	31
Figura 20b: Camada de neurônios.....	31
Figura 20c: Rede neural.....	31

Figura 21: Back-propagation.....	35
Figura 22: Sistema linear dinâmico.....	37
Figura 23: Sistema não-linear dinâmico.....	37
Resultados obtidos	
Gráfico 1: entrada degrau de 75° a 80° para o motor.....	41
Gráfico 2: entrada degrau de 75° a 85° para o motor.....	42
Gráfico 3: entrada degrau de 75° a 90° para o motor.....	43
Gráfico 4: entrada degrau de 80° a 75° para o motor.....	44
Gráfico 5: entrada degrau de 85° a 75° para o motor.....	45
Gráfico 6: entrada degrau de 90° a 75° para o motor.....	46
Gráfico 7: entrada degrau de 700 rpm a 1600 rpm para o dinamômetro	47
Gráfico 8: entrada degrau de 700 rpm a 1650 rpm para o dinamômetro	48
Gráfico 9: entrada degrau de 700 rpm a 1700 rpm para o dinamômetro	49
Gráfico 10: entrada degrau de 700 rpm a 1900 rpm parà o dinamômetro	50
Figura 24: Sistema controlado via redes neurais.....	53
Figura 25: Resposta controlada do sistema.....	53

RESUMO

Neste trabalho objetiva-se o estudo da aplicação de Redes Neurais ao problema de modelagem de sistemas dinâmicos não lineares. Este estudo também é estendido à utilização das Redes Neurais como controladores mas somente a nível de documentação bibliográfica e não de implementação.

A proposta do trabalho é desenvolver duas redes que modelem dois sistemas : um motor movido a gás natural e um dinamômetro hidráulico. Estes dois sistemas estão inseridos numa pesquisa desenvolvida pelo IPT e financiada pela FAPESP que visa a diminuição da taxa de emissão de poluentes em motores de combustão interna (MCI) que utilizam gás natural como combustível.

Tais sistemas são extremamente não lineares, e a modelagem de ambos através de equacionamento físico requer que sejam feitas diversas hipóteses simplificadoras para que se possa desenvolver um modelo satisfatório. As Redes Neurais aparecem como uma interessante alternativa a esta tarefa pois sua estrutura permite que a modelagem seja feita somente a partir das entradas e saídas dos sistemas, eliminando a necessidade de tantas hipóteses e simplificando bastante o trabalho.

CAPÍTULO 1 : MOTIVAÇÃO, OBJETIVOS E ESTRUTURA DO TRABALHO

1.1) MOTIVAÇÃO

O problema da poluição nos grandes centros urbanos preocupa hoje toda a sociedade. Uma das grandes fontes de poluição são os gases de escape dos veículos automotores que circulam pelas cidades todos os dias. Monóxido de Carbono (CO), hidrocarbonetos (HC), nitretos e nitratos (NO_x), enxofre e particulados sólidos são os subprodutos da combustão interna dos motores que mais poluem o ar. A taxa de emissão de tais poluentes é alta em função da natureza química dos combustíveis usuais (álcool, gasolina e diesel), e também em função do processo de combustão por compressão de alguns motores (em geral movidos a diesel).

A legislação ambiental vem se tornando cada vez mais rigorosa, principalmente com respeito à emissão de poluentes em motores de combustão interna (MCI). Este rigor tem estimulado a busca de motores mais modernos e a investigação do uso de combustíveis alternativos.

Uma alternativa energética que vem sendo largamente pesquisada é a utilização do gás natural como combustível para os MCI. O gás polui bem menos que os combustíveis convencionais. Devido à sua natureza química as taxas de emissão de monóxido de carbono e enxofre são baixas. Além disso o processo de ignição é dado por centelha, propiciando índices de emissão desprezíveis de particulados sólidos. O grande problema em termos de poluição do gás natural está relacionado com a alta taxa de emissão de nitretos e nitratos (NO_x), que ainda é alta.

Diversas são as linhas de pesquisa relacionadas com a diminuição da taxa de emissão de poluentes provenientes dos MCI, principalmente aqueles movidos a gás natural. Uma dessas linhas é a busca por estratégias de controle a serem aplicadas nos sistemas de injeção e ignição destes motores, visando manter a relação ar-combustível ao redor do valor estequiométrico.

1.1.1) Catalisadores, relação ar-combustível e controle de injeção

A figura 1 nos mostra um representação esquemática de um sistema de controle de injeção e ignição num MCI.

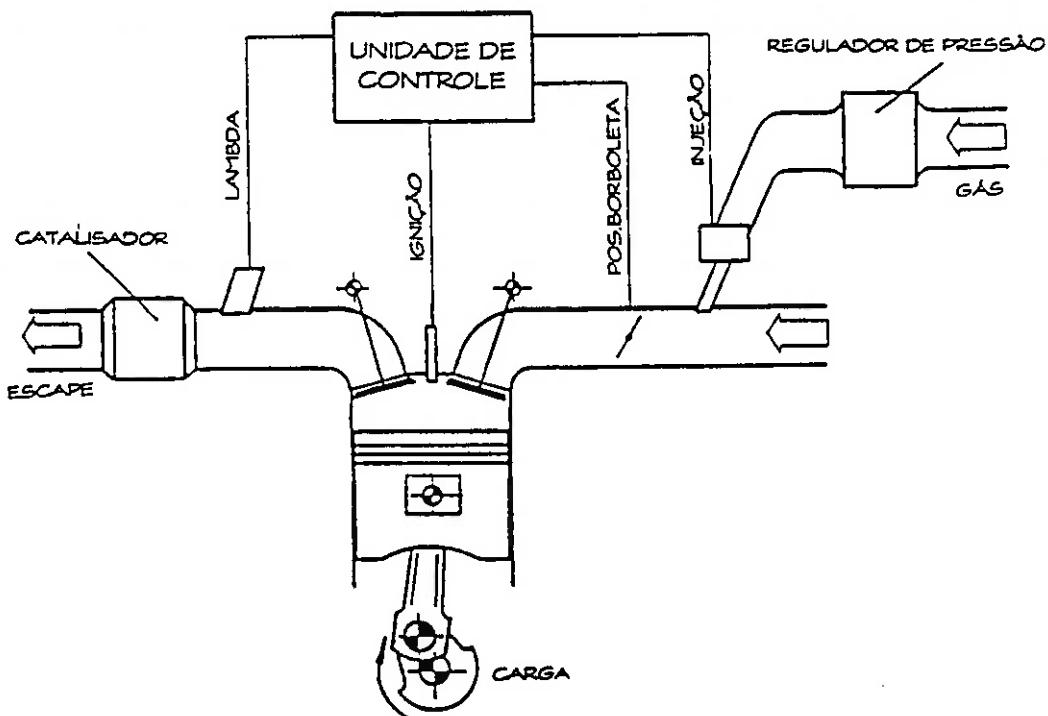


Figura 1 - Esquema geral de controle do sistema de injeção e ignição

Conforme a figura depois que os gases são queimados e saem da câmara de combustão, eles são forçados a passar através de um catalisador para serem tratados antes de expelidos para atmosfera. Para que este catalisador opere com máxima eficiência, a relação ar-combustível da mistura que sai da câmara deve estar no ponto estequiométrico. O sensor lambda mede a relação ar-combustível dos gases de escape e informa este valor à unidade de controle, que por sua vez manda sinais de comando para os sistemas de injeção e ignição.

Muitas pesquisas têm sido desenvolvidas à procura de tecnologias de controle eficientes para estes sistemas de injeção e ignição (Cassidy et al., 1980; Jones, 1988; Moskwa, 1993; Lopes, 1996). Este problema já está praticamente resolvido para os motores operando em regime permanente, com diversas soluções encontradas na literatura e também disponíveis no mercado para carros de passeio. Não existem no entanto soluções de controladores que sejam eficientes a nível de regime transitório, quando acontecem variações bruscas de rotação e torque. Isto porque o controle é todo

feito em cima de um mapeamento estático que determina qual deve ser a quantidade de gás injetado em função do ponto de operação do motor. Este mapeamento é feito para o motor operando em regime permanente. Mas quando o motor vai de um ponto de operação para outro ele passa por um regime transitório, e é neste momento que o controle falha.

Um controle eficaz a nível de transitório deve manter a relação ar-combustível ao redor de 1% do valor estequiométrico, para não comprometer a eficiência do catalisador. A figura 2 mostra como varia a eficiência do catalisador em função da variação no valor da relação ar-combustível normalizada ($\lambda = 1$).

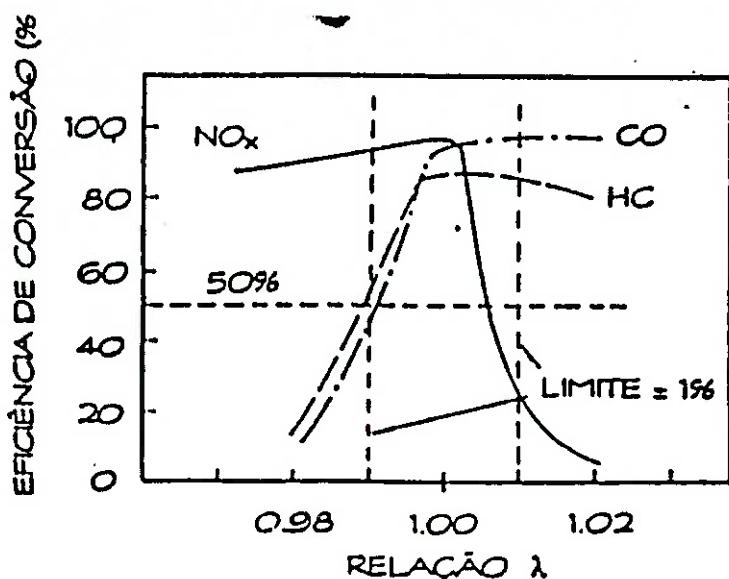


Figura 2 - Eficiência do catalisador em função da variação da relação ar-combustível

O catalisador utilizado é do tipo de três vias (platina, paládio e rádio), que oxida o HC e o CO e reduz o NO_x. Pode-se perceber pela figura como é drástica a queda de eficiência do catalisador quando λ foge do valor 1. No limite de 1%, a eficiência de conversão catalítica para o CO e para o HC cai para 50%, e no caso do NO_x cai para 20%.

Não havendo um controle eficaz no transitório a eficiência do catalisador nestes instantes fica comprometida e os gases que são expelidos praticamente não são tratados. Este é um problema de grandes proporções nos centros urbanos, uma vez que os veículos passam a maior parte do tempo em regime transitório, frenando e acelerando devido a tráfegos intensos, sinais de trânsito, etc. Quando falamos de ônibus os transitórios são ainda mais freqüentes.

Existe ainda um outro problema relacionado com o transitório dado em um MCI que é o empobrecimento/enriquecimento momentâneo da mistura, conforme haja aceleração ou desaceleração. Este problema também pode ser atribuído ao atraso na injeção do combustível no instante do transitório.

Esta deficiência nos sistemas de controle a nível de transitório tem levado institutos de pesquisa e empresas a estudar a fundo este assunto.

1.1.2) O IPT e o controle de injeção

O IPT (Instituto de Pesquisas Tecnológicas) vem desenvolvendo uma pesquisa com motores a gás natural. Esta pesquisa conta com a parceria da Mercedes-Benz e com o financiamento da Fapesp. A pesquisa tem diversas linhas de ação, e uma delas, na qual está envolvido o Agrupamento de Sistemas e Controle, visa justamente estudar o problema do controle do sistema de injeção do motor a nível de regime transitório. Para a condução deste estudo estão disponíveis no Laboratório de Motores, um motor de ônibus movido a gás natural cedido pela Mercedes e um dinamômetro hidráulico (freio dinamométrico). O dinamômetro fica acoplado ao eixo do motor e serve para simular condições de carga e rotação e para medir o torque fornecido pelo motor. No sentido de estudar o controle de injeção, um primeiro passo é construir modelos dinâmicos tanto do motor quanto do dinamômetro.

1.1.3) Importância dos modelos do motor e do dinamômetro

O problema de controle a nível de transitório da injeção de motores é extremamente complexo e como foi dito, ainda não possui nenhuma solução prática muito bem definida. Assim sendo é de grande importância que se possa avaliar o desempenho de uma proposta de controlador a nível de simulação, em função da simplicidade, rapidez, baixo custo e capacidade de criar diversas situações diferentes que um ambiente de simulação permite.

Para criar este ambiente de simulação é necessário o desenvolvimento de um modelo dinâmico da planta a ser controlada, no caso o motor a gás. O modelo deve reproduzir com o máximo de fidelidade a dinâmica do motor para que o projeto do controlador esteja o mais perto o possível da realidade.

Existem ainda outras aplicações para este modelo, que são :

- . Detecção de falhas do sistema físico real. Se possuímos um modelo validado em laboratório, ou seja que reproduz com um bom grau de fidelidade o motor real,

podemos periodicamente comparar as saídas do modelo e do motor para uma mesma entrada e havendo diferença nas saídas isto significa que o motor está apresentando algum problema.

. Estimação de estados. Variáveis de estado que por alguma razão não podem ser medidas através de sensores podem ser estimadas a partir do modelo.

. Inversão da planta. Esta estratégia permite que se desconsidere a parte não linear do sistema e desta forma linearizar o modelo.

O dinamômetro hidráulico apresenta dinâmicas muito lentas quando comparadas com as dinâmicas do motor. Esta diferença torna as medições feitas pelo dinamômetro no transitório do motor pouco precisas e pouco confiáveis. Daí surge a necessidade de construir o seu modelo, para melhor compreender a complicada dinâmica deste sistema. Podemos portanto reproduzir transitórios preestabelecidos com erros conhecidos de medição (uma vez que possuímos o modelo do dinamômetro).

É de grande importância salientar que o objetivo é que se tenha, como representação da planta na malha de controle, o modelo do motor acoplado ao modelo do dinamômetro, constituindo um único modelo dinâmico.

1.2) OBJETIVO DO TRABALHO

A proposta de implementação do trabalho é a seguinte :

“Modelar 2 sistemas dinâmicos não-lineares, um motor a gás natural e um dinamômetro hidráulico através de Redes Neurais”.

1.2.1) Modelos fenomenológicos e modelos via Redes Neurais

O IPT já conta com dois modelos fenomenológicos, ou seja baseado em equações físicas, do motor e do dinamômetro. Estes modelos já foram até mesmo acoplados um ao outro, de forma que se possui hoje um único modelo dinâmico consolidado.

Neste trabalho propõe-se o desenvolvimento de outros dois modelos utilizando-se uma abordagem diferente que são as Redes Neurais. As razões para isto são várias :

a) Os modelos existentes são baseados em equações físicas. As redes neurais são algoritmos matemáticos. A legitimidade desta tentativa de modelagem está na fuga de um paradigma, ou seja, este trabalho abre uma frente de pesquisa em uma forma de modelagem completamente diferente, e que vem recebendo grande atenção da comunidade científica.

b) Tanto o motor a gás quanto o dinamômetro hidráulico são sistemas altamente não lineares. Este aspecto dificulta muito a modelagem por meio de equações físicas. Diversas hipóteses simplificadoras têm que ser assumidas, e os modelos são linearizados para determinados pontos de operação restringindo suas alcançabilidades. A modelagem via Redes Neurais é uma alternativa interessante pois requer apenas que se conheça vetores de entrada ao sistema e vetores de saída correspondentes àquelas entradas. Isto elimina de uma certa forma a necessidade de tantas hipóteses simplificadoras, que comprometem os modelos.

c) Mesmo que a alcançabilidade de uma única rede não seja muito grande, a sua simplicidade de modelagem permite que se monte diversas redes para diversos pontos de operação. Teríamos multi-modelos de redes, de forma que dependendo da entrada chaveamos de um modelo para outro e assim podemos ter a resposta desejada.

d) O que se pretende no fundo é plantar uma semente, que possa no futuro com a continuidade do trabalho apresentar resultados até mesmo melhores dos que já se possui com os modelos fenomenológicos.

e) Além da utilização como modelos, existem muitas pesquisas feitas que mostram a utilização de redes neurais atuando efetivamente como controladores. O conhecimento agregado com a modelagem de sistemas pode muito bem ser utilizado para implementação de redes como instrumentos de controle.

É importante frisar que utilizou-se como massa de dados os vetores de entrada e saída dos modelos fenomenológicos existentes e não dos sistemas físicos reais. Isto foi feito por uma questão de simplicidade na manipulação dos dados e uma vez que a estrutura de uma rede neural requer apenas os valores das entradas e das saídas é de se esperar que uma modelagem bem feita utilizando-se dados de simulação implique em um boa modelagem quando utiliza-se dados reais medidos em bancada de teste.

1.3) ESTRUTURA DO TRABALHO

No capítulo 2 são apresentados em detalhe os modelos fenomenológicos do motor e do dinamômetro, que neste caso representam as plantas a serem modeladas.

No capítulo 3 faz-se uma revisão do conhecimento adquirido a respeito das Redes Neurais.

O capítulo 4 descreve o processo de implementação das redes.

O capítulo 5 traz os resultados de modelagem obtidos.

No capítulo 6 comenta-se a utilização de Redes Neurais como controladores a partir das bibliografias que tratam a respeito do assunto.

No capítulo 7 são mostradas as conclusões do trabalho.

O anexo traz as listagens dos programas desenvolvidos em Pascal e no Matlab, acompanhadas de esclarecimentos sobre a estrutura e as funções utilizadas.

CAPÍTULO 2 : MODELO FENOMENOLÓGICO DO MOTOR A GÁS

2.1) EVOLUÇÃO DOS MODELOS

A modelagem da planta é o primeiro passo a ser tomado na implantação de uma estratégia de controle. Na busca de confeccionar modelos de MCI que servissem para a lei de controle diversos trabalhos apareceram desde 1960. Os pioneiros foram YU (1960) e SHWEITZER (1966). No início estes modelos serviram basicamente como auxiliares na análise de fenômenos relacionados com a dinâmica do MCI (homogeneização e indução da mistura ar-combustível, combustão, formação de gases de escape, etc.), não servindo para a utilização na malha de controle em função da complexidade dos cálculos envolvidos.

Foi a partir de meados dos anos 70 que começaram a aparecer modelos de MCI realmente voltados para a implementação do controle. Estes modelos eram em sua maioria do tipo caixas-pretas, onde procurava-se determinar coeficientes de uma curva a partir dos dados de entrada e saída, em geral através do método dos mínimos quadrados, curva esta que representaria a planta. O foco de estudo era o regime permanente.

O maior rigor da legislação ambiental americana foi um dos fatores que levou os pesquisadores a direcionarem seus estudos para o controle a nível de regime transitório. Um exemplo deste aumento de rigor foi a criação de ciclos de testes transitórios para veículos automotores urbanos por parte da EPA (Environmental Protection Agency).

Os modelos tipo caixas-pretas não representavam bem o MCI no transitório, e então a comunidade científica volta seus esforços para análise dos fenômenos físicos envolvidos na dinâmica dos motores, e portanto aparecem os chamados modelos fenomenológicos. Uma das características básicas de tais modelos é considerar os fenômenos caracterizados por parâmetros concentrados, o que permite a solução das equações em tempo real. Uma outra característica inerente a quase todos os modelos fenomenológicos que foram desenvolvidos é a divisão em subsistemas, definindo um aspecto modular. Assim sendo existem submodelos dinâmicos para o escoamento do ar sobre a válvula borboleta, para o escoamento no coletor de admissão, para a geração de torque via combustão, para a dinâmica rotacional e outros. O subsistema que mais tem sido estudado nos últimos 20 anos é o do coletor de admissão.

O desenvolvimento destes modelos fenomenológicos requer que sejam assumidas diversas hipóteses simplificadoras bem como que os modelos sejam linearizados para determinados pontos de operação.

2.2) REPRESENTAÇÃO DO MOTOR E AS HIPÓTESES SIMPLIFICADORAS

A figura 3 mostra um representação esquemática do MCI que foi modelado. Considera-se que a montante da entrada de ar a pressão é atmosférica e a temperatura é ambiente. A válvula borboleta age como uma perda de carga e considera-se o escoamento como sendo compressível, unidimensional e isoentrópico. O escoamento de combustível através da válvula borboleta é desconsiderado em favor do escoamento do ar. O escoamento através do coletor de admissão é considerado unidimensional com distribuições de pressão e temperatura uniformes ao longo de seu comprimento. A geração do torque é feita quando a mistura ar-combustível é admitida pelo cilindro e inicia-se a sequência de quatro tempos do motor. Ao ser expelida do cilindro, a mistura passa pelo coletor de exaustão para então atravessar o catalisador e ser jogada na atmosfera.

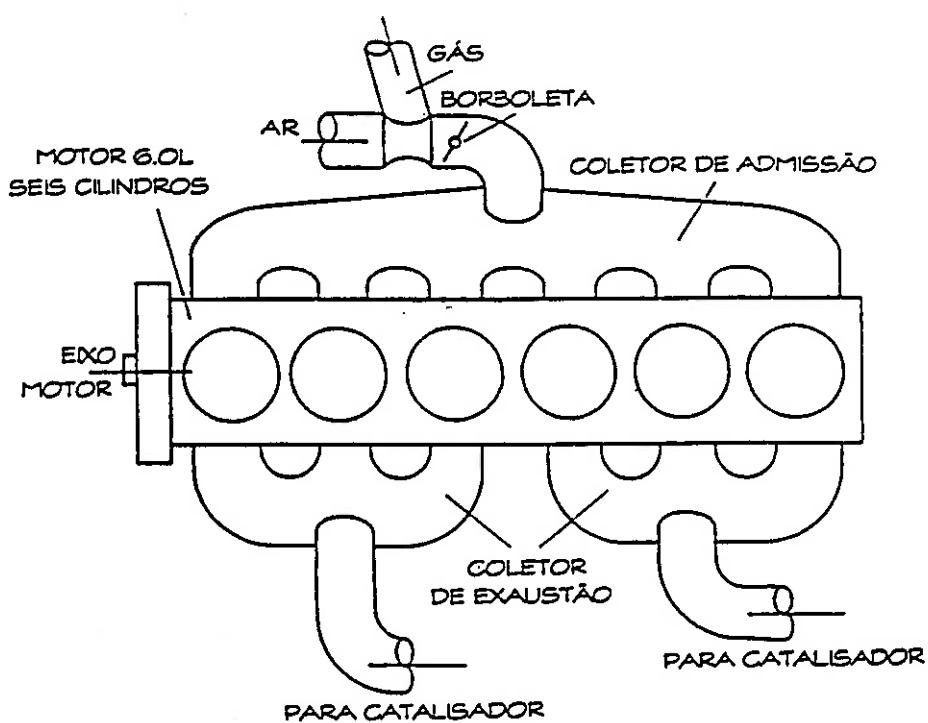


Figura 3 - Representação esquemática do motor

Não se considera mudança na qualidade do combustível, ou seja no seu PCI (Poder Calorífico Interior). Considera-se um motor pré-aquecido, onde não existe turbocompressor, intercooler ou recirculação dos gases de escape.

2.3) O MODELO DO MOTOR

Um modelo procura sempre definir uma relação entre as entradas de um sistema e suas saídas. Este modelo, de uma forma geral, relaciona as entradas de ar e combustível no motor com os estados de saída relevantes para o estudo das emissões, que são pressão no coletor e rotação (pois definem um ponto de operação do motor) as relações ar-combustível na entrada e saída da câmara de combustão. A relação ar-combustível na entrada da câmara (F_i_{in}) serve como valor de referência para a relação ar-combustível na saída da câmara (F_i_{out}). Todas estas saídas (pressão, rotação, F_i_{in} e F_i_{out}) são utilizadas para alimentar a unidade de controle.

O modelo foi construído no ambiente do Simulink, que é um módulo do software Matlab (da Mathworks). A figura 4 mostra o esquema geral deste modelo :

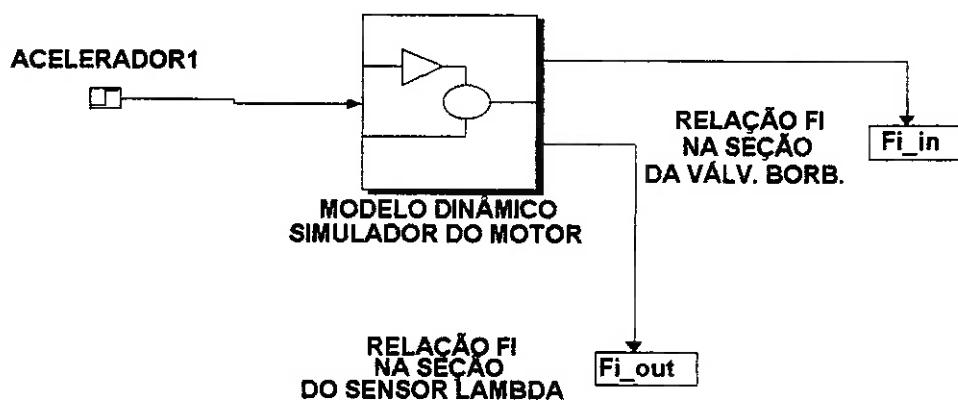


Figura 4 - Visão Geral do Modelo Dinâmico do Motor

A variável de entrada “acelerador” é um degrau, que significa uma variação no ângulo da borboleta de admissão do coletor. Esta entrada representa a admissão de ar no motor.

As variáveis de saída Fi_{in} e Fi_{out} são as relações ar-combustível na entrada do coletor de admissão e na saída, respectivamente.

O modelo é subdividido em três subsistemas, a saber :

- . Subsistema do coletor de admissão ;
- . Subsistema de combustão ;
- . Subsistema da dinâmica rotacional ;

Na figura 5 o bloco central está aberto, mostrando os três subsistemas.

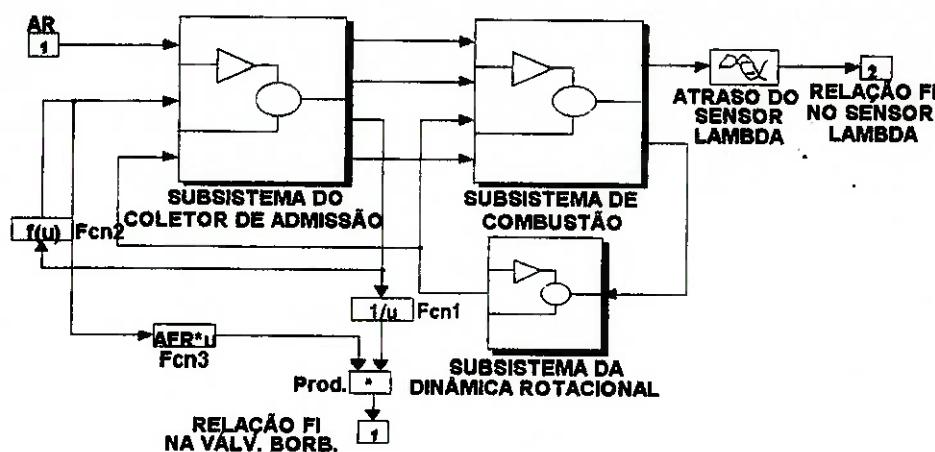


Figura 5 - Três Subsistemas do Modelo do Motor

2.3.1) Subsistema do Coletor de Admissão

Este subsistema modela basicamente três escoamentos :

- . escoamento do ar através da válvula borboleta ;
- . escoamento do ar através do coletor de admissão ;
- . escoamento do gás através do coletor de admissão ;

A figura 6 traz este subsistema em maiores detalhes.

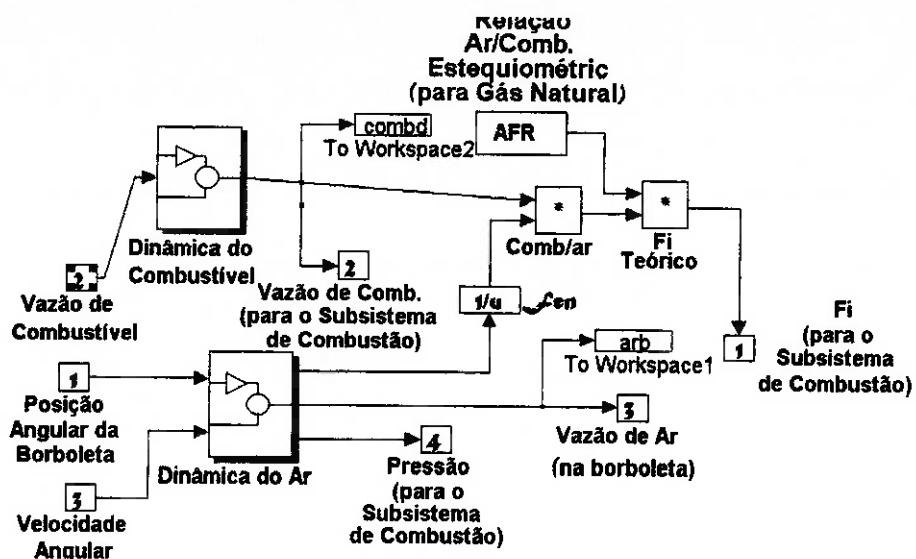


Figura 6 - Subsistema do Coletor de Admissão

Os escoamentos do ar através da válvula borboleta e através do coletor de admissão são modelados pelo bloco “Dinâmica do Ar”, conforme a figura 7 :

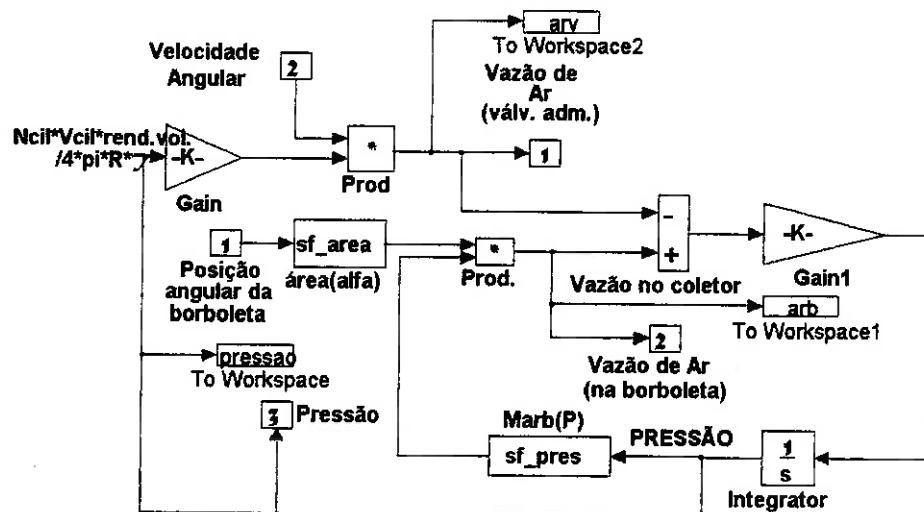


Figura 7 - Modelo da Dinâmica do Ar

Basicamente o que acontece neste bloco é o seguinte :

A vazão de ar através da borboleta é função do ângulo de abertura da mesma e da pressão no coletor. O seu valor é conseguido fazendo com que o ângulo passe pela função *sf_area* (que retorna o valor da área da seção transversal) e com que a pressão passe pela função *sf_press*. Multiplica-se o resultado e encontra-se o valor da vazão.

A vazão de ar através do coletor de admissão é função da velocidade angular do eixo e da pressão no coletor. Multiplicando-se a pressão pela constante K e pela velocidade angular obtém-se o valor desta vazão.

A pressão no coletor, que é uma das variáveis de interesse no nosso estudo, é obtida subtraindo-se da vazão de ar na borboleta o valor da vazão de ar no coletor, multiplicando-se por uma constante $K=RT/V$ e integrando-se este valor.

O escoamento do gás através do coletor de combustão é modelado pelo bloco “Dinâmica do Combustível” (figura 8) :

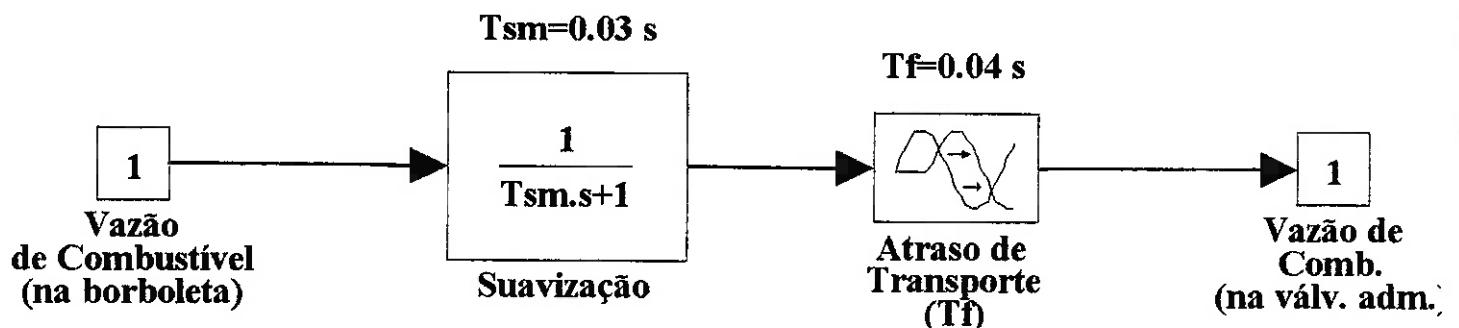


Figura 8 - Modelo da Dinâmica do Combustível

Os únicos fenômenos considerados para a dinâmica do combustível são um atraso de transporte ao longo do coletor e uma modificação no perfil de entrada do gás que pode ser encarado como uma suavização do escoamento.

Perceba-se que aparece aí a outra variável de entrada de interesse, que é a vazão de combustível. Neste modelo assume-se um carburador ideal, ou seja a vazão de combustível está relacionada diretamente com a entrada de ar (representada pela entrada degrau “acelerador”) através de uma fórmula matemática.

Para cada um dos escoamentos citados existem hipóteses simplificadoras mostradas a seguir.

. escoamento do ar através da válvula borboleta

Hipóteses simplificadoras: escoamento compressível unidimensional e isoentrópico; não há dissipação térmica; o diâmetro do eixo da articulação da borboleta não tem influência sobre a dinâmica do escoamento; a área da seção transversal da borboleta é aproximada para uma circunferência.

. escoamento do ar através do coletor de admissão

Hipóteses simplificadoras: o ar se comporta como um gás perfeito.

. escoamento do gás através do coletor de admissão

Hipóteses simplificadoras: o escoamento do gás não contribui na dinâmica da pressão dentro do coletor.

2.3.2) Subsistema de Combustão

Este subsistema é responsável por fornecer o valor do torque produzido pelo motor. Sua representação é mostrada na figura 9.

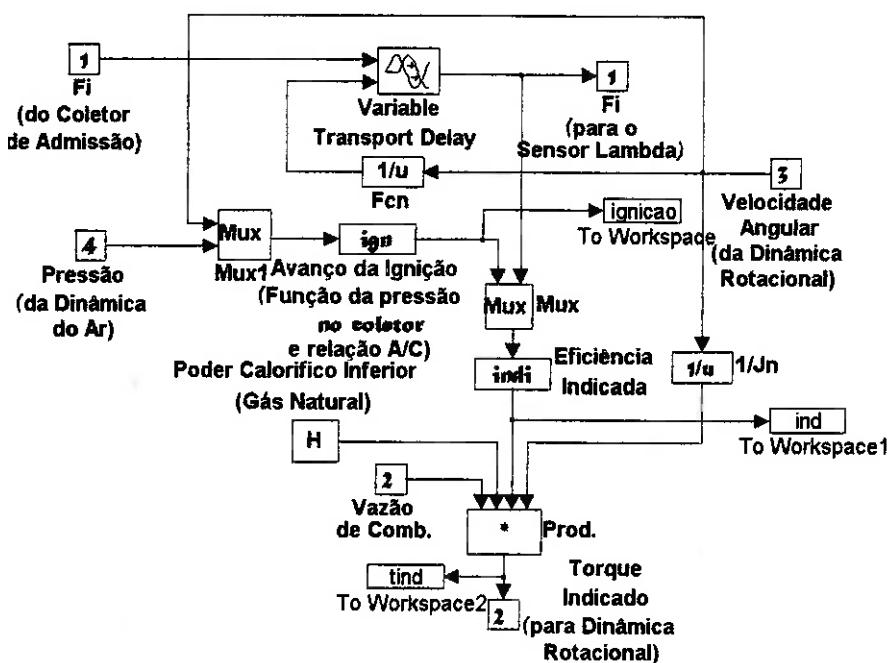


Figura 9 - Subsistema de Combustão

O torque é função da vazão de gás, da rotação do eixo e da energia específica do gás. A função *indi* representa um mapa de eficiência indicada que está relacionado com a energia disponível que a combustão transforma em torque. A função *ign* representa um mapa de ignição estático, que relaciona o avanço de ignição com a rotação e o torque.

Hipótese simplificadora: A eficiência indicada foi relacionada simplesmente com o avanço de ignição e com a relação ar-combustível, quando na verdade ela também depende da rotação e da pressão no coletor.

2.3.3) Subsistema da Dinâmica Rotacional

Este subsistema é responsável por fornecer o valor da rotação (velocidade angular), que é uma outra variável de saída de interesse. A figura 10 mostra este subsistema.

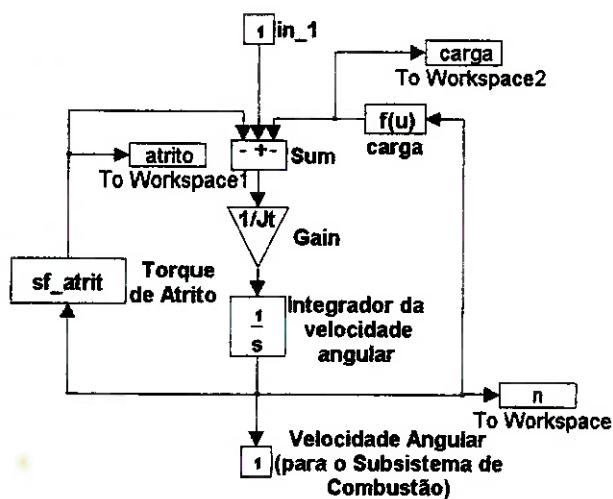


Figura 10 - Subsistema da Dinâmica Rotacional

O torque fornecido pelo motor é subtraído dos torques provocados pela carga externa e pelo atrito. O resultado desta conta é o torque total, que dividido pela inércia total do sistema fornece a aceleração angular. Vale ressaltar que este valor de inércia

possuir o valor de 140 Kg.m^2 (correspondente a um veículo de 10 toneladas em quarta marcha). Integrando-se a aceleração angular obtém-se a rotação (velocidade angular).

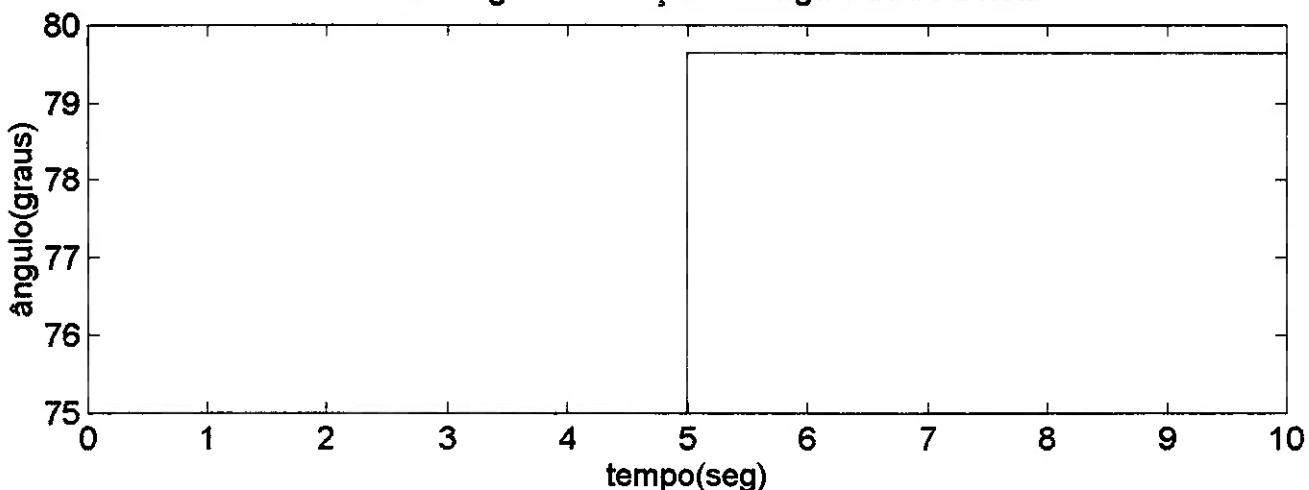
Hipóteses simplificadoras : O torque de atrito bem como a carga (torque externo) são considerados funções lineares da rotação.

2.4) A DINÂMICA DO MOTOR

Para melhor compreender a dinâmica do motor modelado, foi feita uma simulação colocando como entrada de aceleração um variação do ângulo da borboleta de 75 a 80 graus e observadas as variáveis de saída de interesse : pressão, rotação, f_i_{in} e f_i_{out} . Como já foi mencionado, a outra entrada de interesse (vazão de combustível) é definida a partir da entrada de ar a partir de uma equação matemática. Os resultados desta simulação são mostrados a seguir, nas figuras 11 e 12.

ENTRADAS

Entrada degrau - Variação no ângulo da borboleta



Vazão de combustível

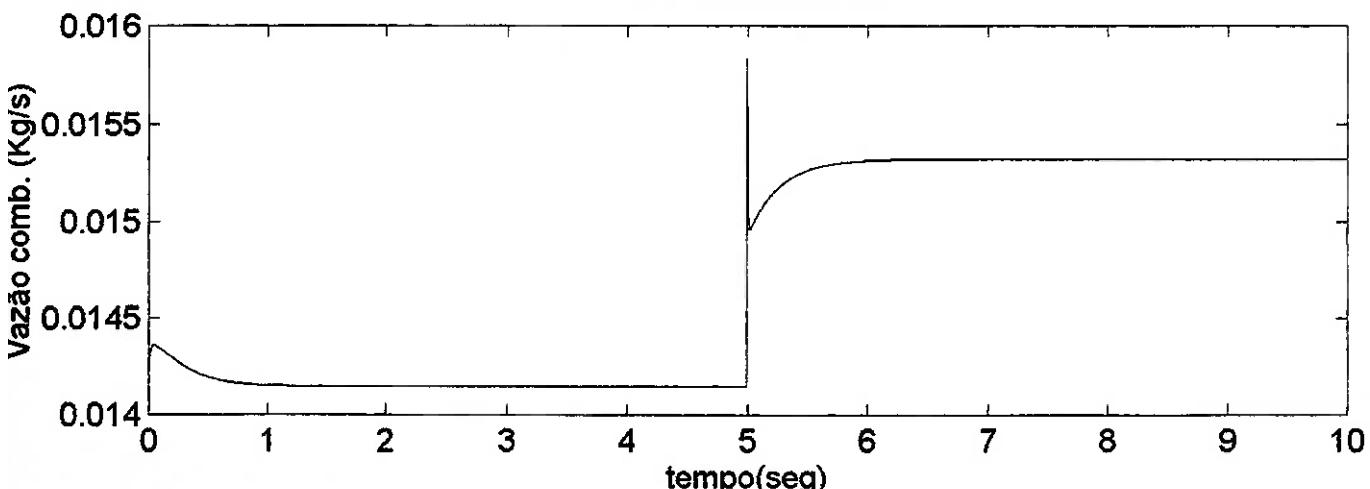


Figura 11 - Entradas de simulação para o modelo do motor

SAÍDAS

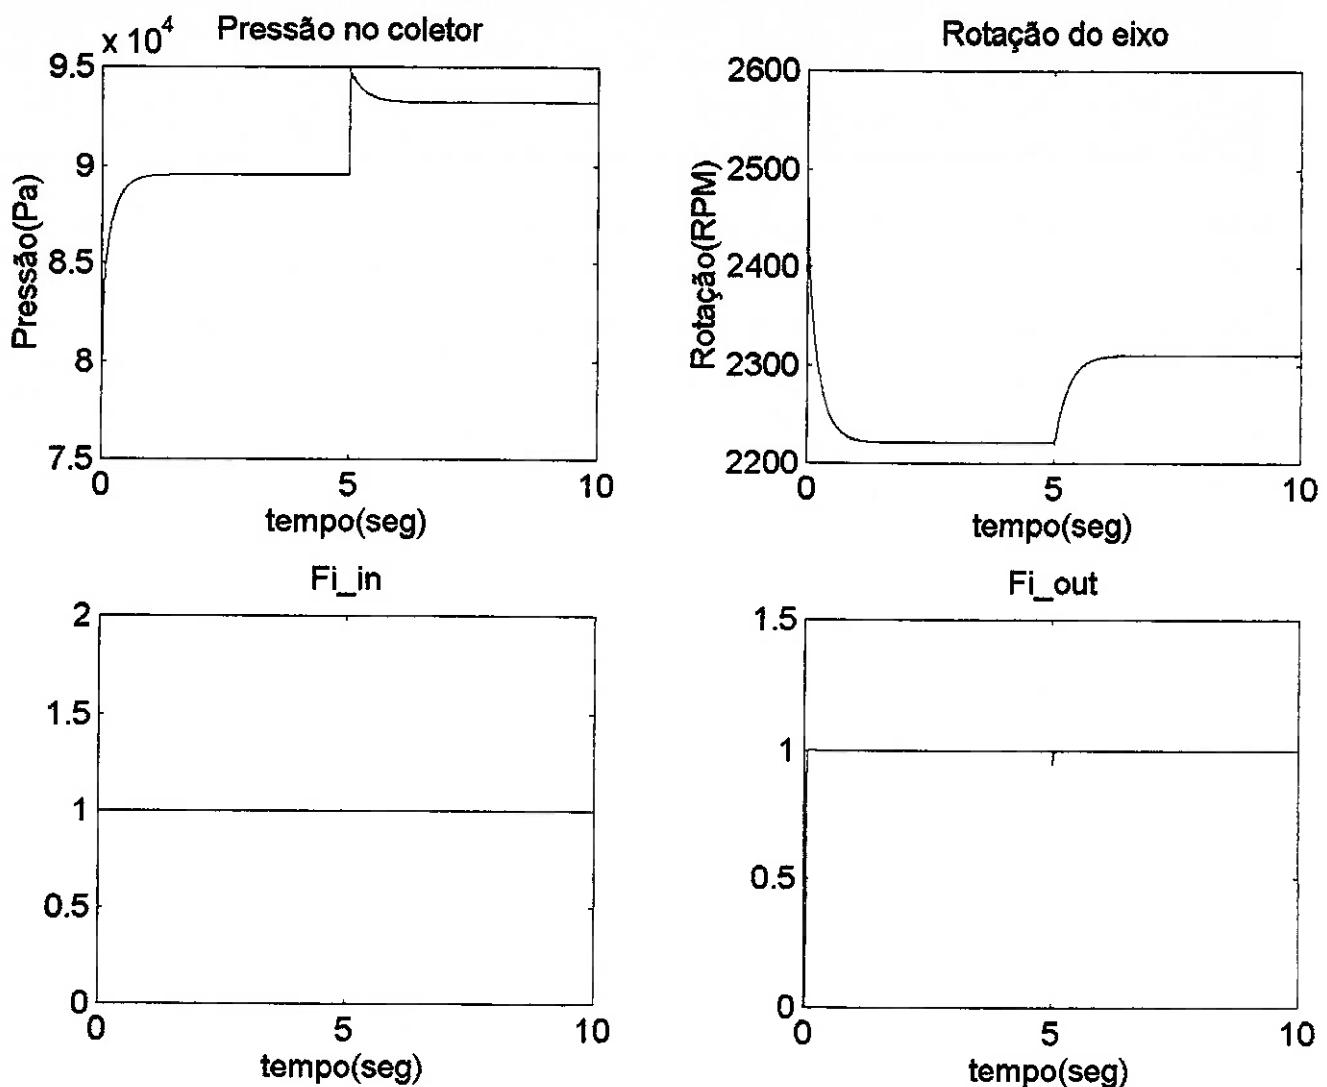


Figura 12 - Saídas do modelo do motor para a simulação feita

CAPÍTULO 3 : MODELO FENOMENOLÓGICO DO DINAMÔMETRO

O papel do dinamômetro ou freio dinamométrico no projeto do motor à gás é oferecer condições para que se simulem situações de carga(torque) e de rotação, fixas ou variáveis, para o funcionamento do motor. Ou seja, tenta simular no laboratório, condições reais de operação de um motor, como por exemplo, subidas e descidas, desde as mais suaves até as mais íngremes.

O freio dinamométrico Schenk, modelo D360-2 como a maioria dos existentes no mercado apresenta dinâmicas lentas quando comparadas à do motor a ele acoplado. Deste modo é difícil precisar e medir o momento das variações dos parâmetros de pesquisa.

O estudo do controle destas variações, ou seja, a busca pelo conhecimento das dinâmicas envolvidas no transitório exige que o dinamômetro, bem como todos os demais equipamentos acoplados aos motores, tenham suas características conhecidas em detalhes. Assim, faz-se necessário o levantamento de modelos dinâmicos que simulem e reproduzam os transitórios preestabelecidos com erros de medições conhecidos.

Entretanto, antes de mostrar o modelo do dinamômetro, convém apresentar o funcionamento do dinamômetro (figura 13), para uma melhor compreensão das variáveis e funções existentes no modelo.

A água entra (2) e se dirige às câmaras de turbilhonamento(3) através de orifícios existentes no estator(6). Nessas câmaras ocorrem redemoinhos de água provocados por um rotor (4) e consequente frenagem do eixo do motor; já que o eixo se encontra parcialmente mergulhado na água da câmara.

A energia despendida na frenagem se transforma em calor. A água absorve o calor e sai por fendas existentes no estator e rotor; passa, então, pelo sistema da válvula e finalmente escoa para o sistema de drenagem. Verifica-se, portanto, que a água além de funcionar como fluido de frenagem, funciona também como fluido de refrigeração.

A pressão é o parâmetro de comando do dinamômetro, ou seja, o turbilhonamento da câmara provoca um aumento da pressão. Para voltar à condição estipulada de vazão constante, a válvula borboleta(11) deve ser aberta para que juntamente com o pistão(12) atue de forma a manter a estabilidade do sistema.

De fato, para condição de velocidade ou vazão de entrada constante, o torque resistivo que o dinamômetro oferece depende do nível de enchimento das câmaras de turbilhonamento, sendo que o nível é regulado pela válvula borboleta e pelo pistão que se encontram à saída das câmaras de turbilhonamento. Quanto mais cheio a câmara maior o torque resistivo imposto ao eixo. Pode-se afirmar, portanto, que para uma rotação de referência estipulada, o nível de água estabelece uma carga(torque) ao eixo.

O conjunto válvula/pistão é controlado por um PID que aciona um potenciômetro de valor real conectado a um motor responsável pela abertura da saída das câmaras de turbilhonamento.

O PID é acionado e informado através da realimentação proveniente do sinal de rotação do transdutor de rotação para o caso de operação rotação de referência ou sinal de força(célula de carga) para o modo torque de referência. A carga resistiva necessária deve ser estabelecida pelo PID, portanto, a partir das curvas de referência e da curva característica do motor.

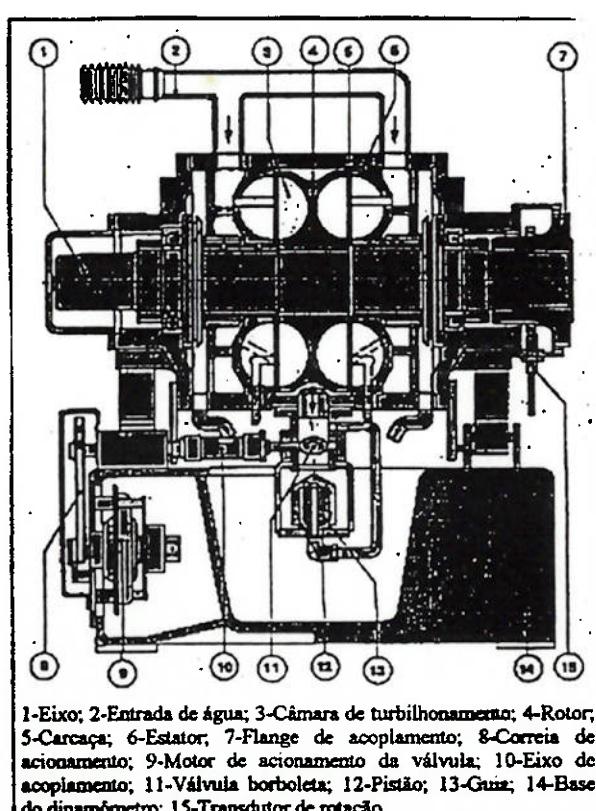


Figura 13 - Esquema geral do dinamômetro

3.1) O MODELO DO DINAMÔMETRO

O modelo do dinamômetro referente ao sistema dinâmico apresentado acima é o descrito a seguir, na figura 14.

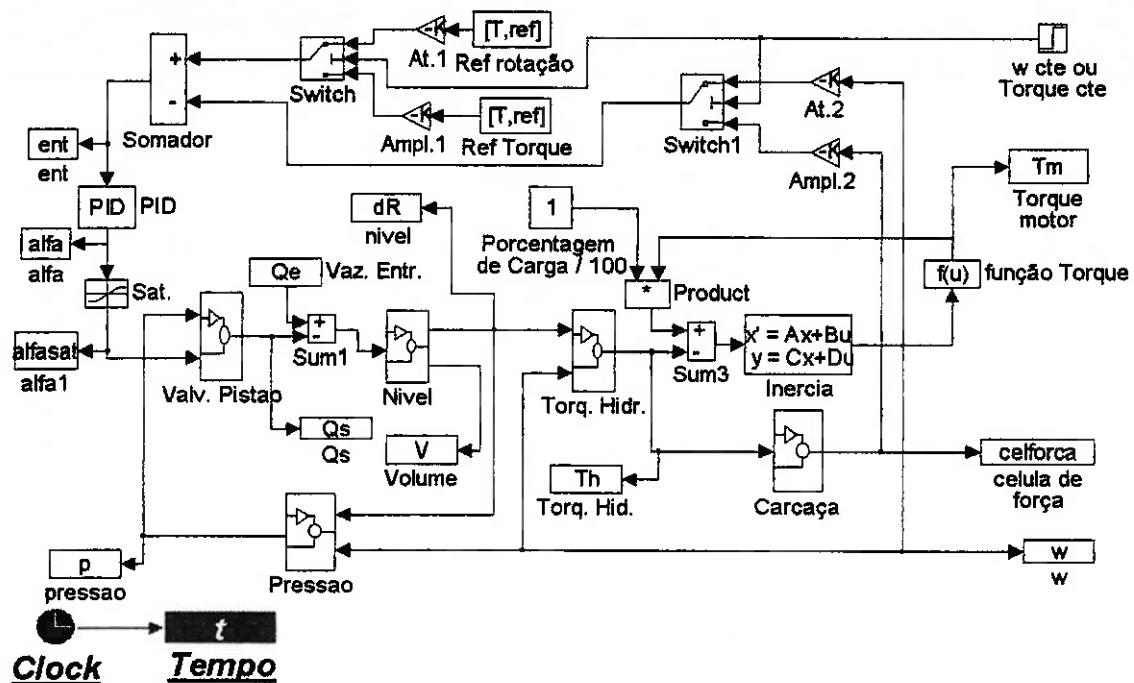


Figura 14 - Modelo fenomenológico do dinamômetro

Existem dois modos de operação: Torque constante ou rotação constante. Seguindo pela esquerda dos blocos referentes a torque e rotação constante tem-se o bloco do PID, este é responsável por controlar a maior ou menor vazão da câmara de turbilhonamento a partir da curva de referência exigida e da curva do motor existente, e deste modo estipular uma carga resistiva na saída do sistema.

A saturação existente logo a seguir refere-se a abertura da válvula borboleta entre 0 e 90°.

A Valv.Pistão regula a vazão na saída Q_s . A diferença vazão de entrada e vazão de saída é que estipula o nível de água na câmara de turbilhonamento que pode ser lido por dR . Dependendo do nível, o dinamômetro oferece um valor de torque para o eixo do motor.

O torque hidráulico do eixo proveniente da câmara de turbilhonamento é associado à porcentagem de carga do motor e estabelece o torque recebido pelo motor.

Caso estejamos operando no modo torque de referência, o torque hidráulico é avaliado juntamente com o torque proveniente da inércia da carcaça e enviado para a saída através da célula de força que vai realimentar novamente o sistema.

No bloco pressão estipula-se a pressão dinâmica da água na câmara de turbilhonamento.

$$\Delta P = \rho \omega^2 R_m \Delta R$$

O bloco torque hidráulico do motor transmitido à carcaça pela água é:

$$T_c = \rho R^3 \omega^2 2\pi R_m \Delta R,$$

onde R- raio interno da carcaça

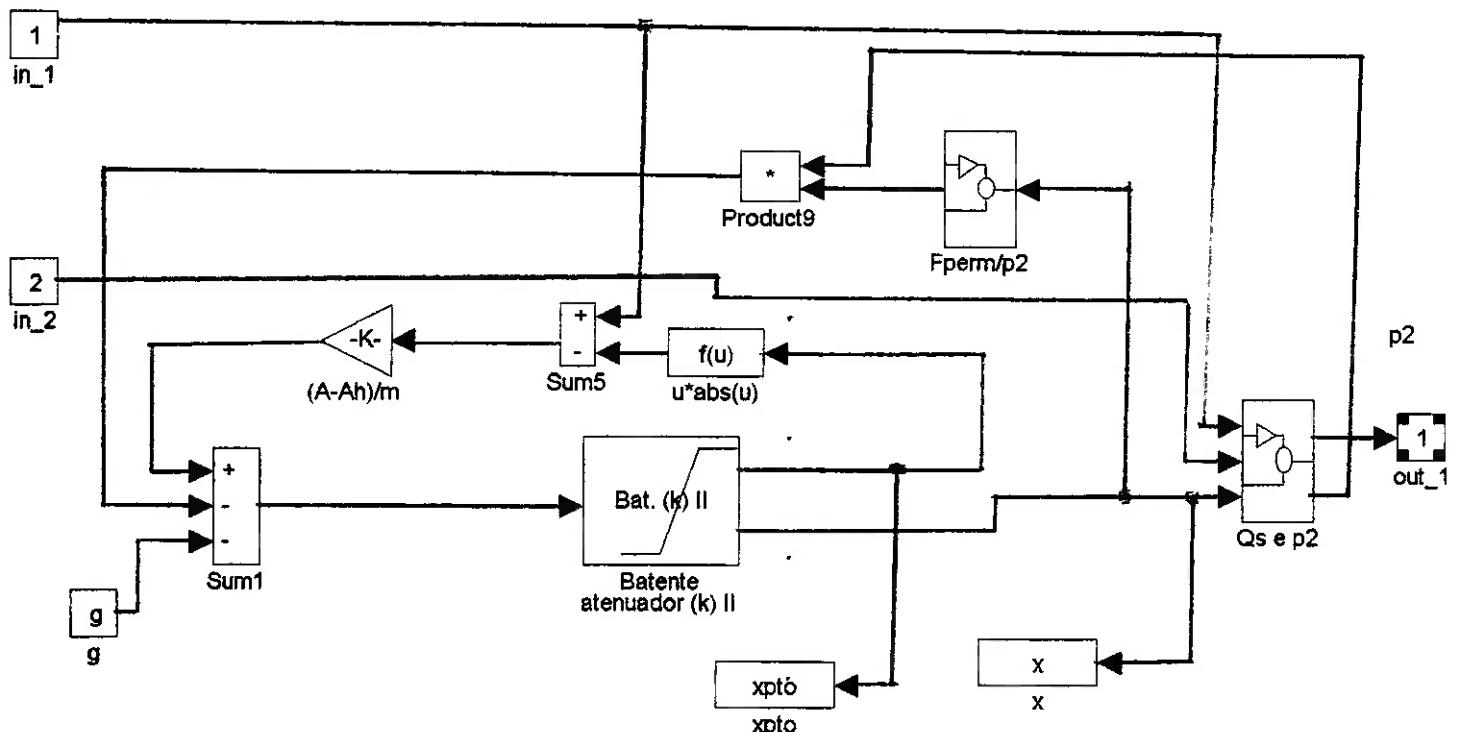


Figura 15 - Bloco Valv. Pistão

O bloco Valv.Pistão contém a equação referente à pressão na câmara interna do pistão.

$$p_3 = p_1 - 9.06e5 x_{pto} / x_{pto}$$

No bloco Fperm/p2 encontramos fórmulas referentes a pressão na saída da válvula borboleta e a força permanente que representa a reação à força que o pistão provoca na água causadora da mudança de direção do escoamento.

$$p_2 = p_1 C_v A_v^2 / (F(x) + C_v A_v^2)$$

onde:

p_1 é a pressão na entrada da válvula borboleta

$$F(x) = [1 - (4C_d^2 A(x))^2] / F_d(x)$$

$$F_d(x) = 1 - (4 C_d A(x) / D^2 \pi)^2$$

$$C_v A_v = [0.78(1-\cos\alpha)/1-0.78(1-\cos\alpha)] \pi D^2 / 4$$

sendo α a posição angular da borboleta

$C_v A_v$ é a área equivalente de escoamento pela válvula borboleta

$F(x)$ e $F_d(x)$ são funções auxiliares, associadas à perda de carga no orifício de saída

$$F_{perm} = [\pi D^2 / 4 + 8F(x) / \pi D^2 / 4 - C_d A(x) 2 \cos(69^\circ) / F_d(x)] p_2$$

No bloco QsP2 está modelada a equação que rege a vazão através do orifício de saída, considerando pressão atmosférica nula.

$$Q_s = C_d A(x) (2p_2 / \rho)^{1/2} / [1 - (4C_d / \pi D^2) A(x)]^{1/2}$$

onde C_d é o coeficiente de descarga do orifício nas condições de escoamento da água

$A(x)$ é a área de passagem pelo orifício, definida pela posição x do pistão

D é o diâmetro do pistão

Dentro do bloco valv. pistão encontramos uma saturação que se refere a limitação de percurso do pistão.

Todas as fórmulas citadas acima podem ser encontradas no artigo sobre MODELAGEM E SIMULAÇÃO DE UM FREIO DINAMOMÉTRICO HIDRÁULICO escrito pelo Agrupamento de Sistemas de Controle e Agrupamento de Motores do IPT, ver Referências bibliográficas.

3.2) DINÂMICA DO DINAMÔMETRO

Serão demonstradas a seguir algumas simulações feitas com este modelo para uma idéia de sua dinâmica. Estes mesmos gráficos podem ser mais tarde comparados com as saídas dos modelos de redes neurais. A figura 16 refere-se à entrada dada ao sistema e as figuras 17,18 e 19 referem-se às respostas do modelo.

Condições iniciais:

- Carga do motor: 100%
- Vazão de entrada: 0,3 l/s
- Rotação inicial: 700 rpm
- Rotação final: 1600 rpm
- Tempo: 70 s.
- Transitório: 30 a 40 s

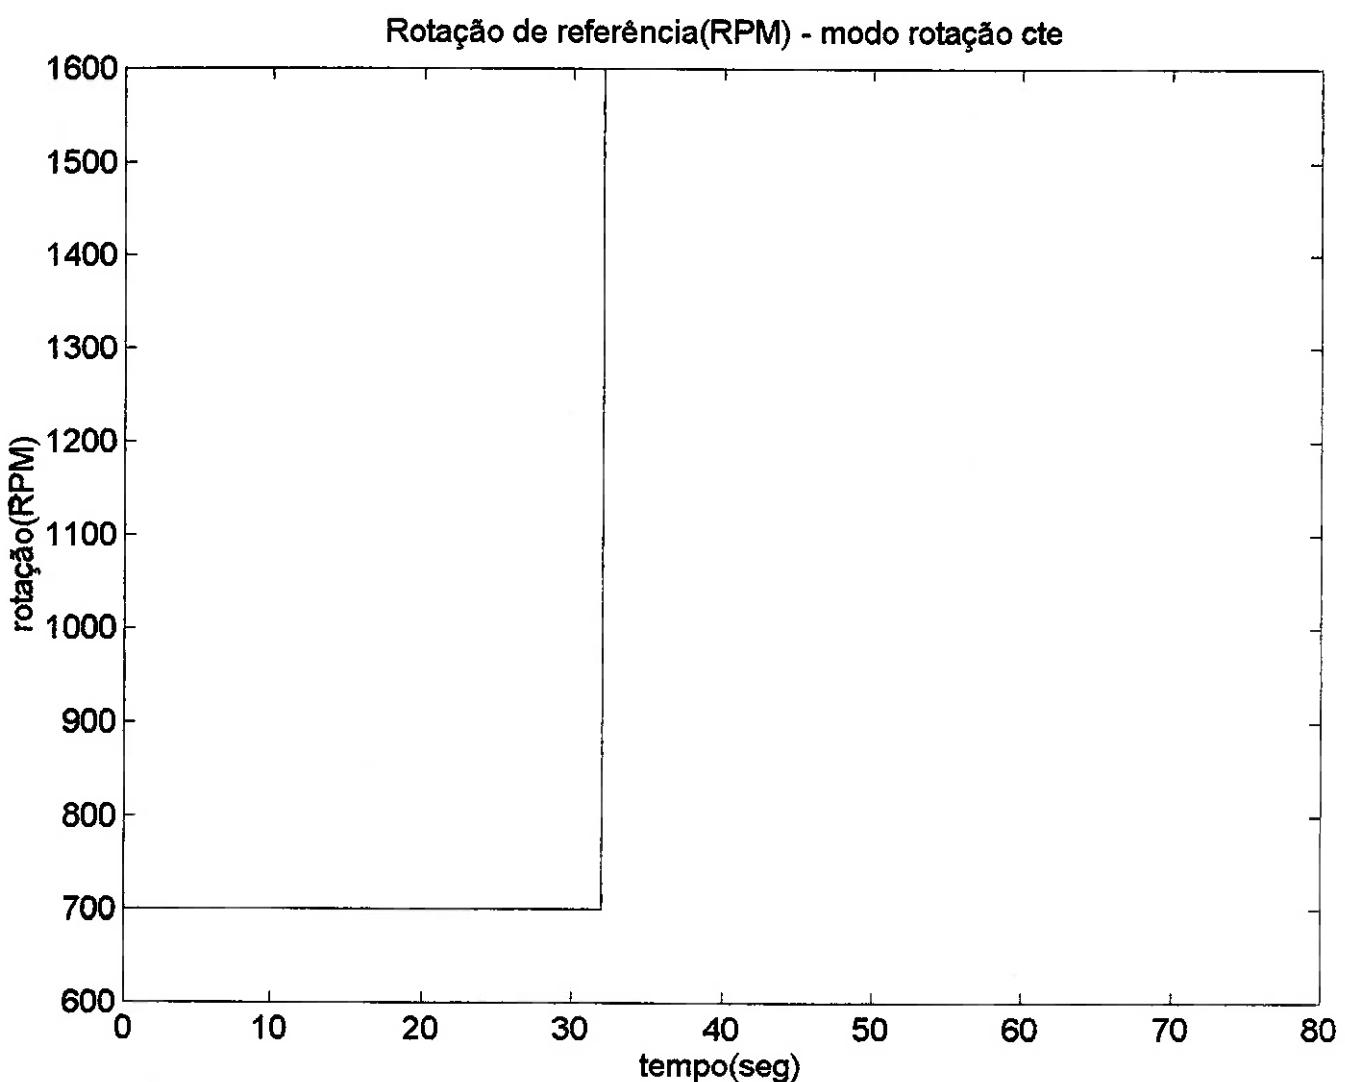


Figura 16 - Entrada de simulação ao modelo do dinamômetro

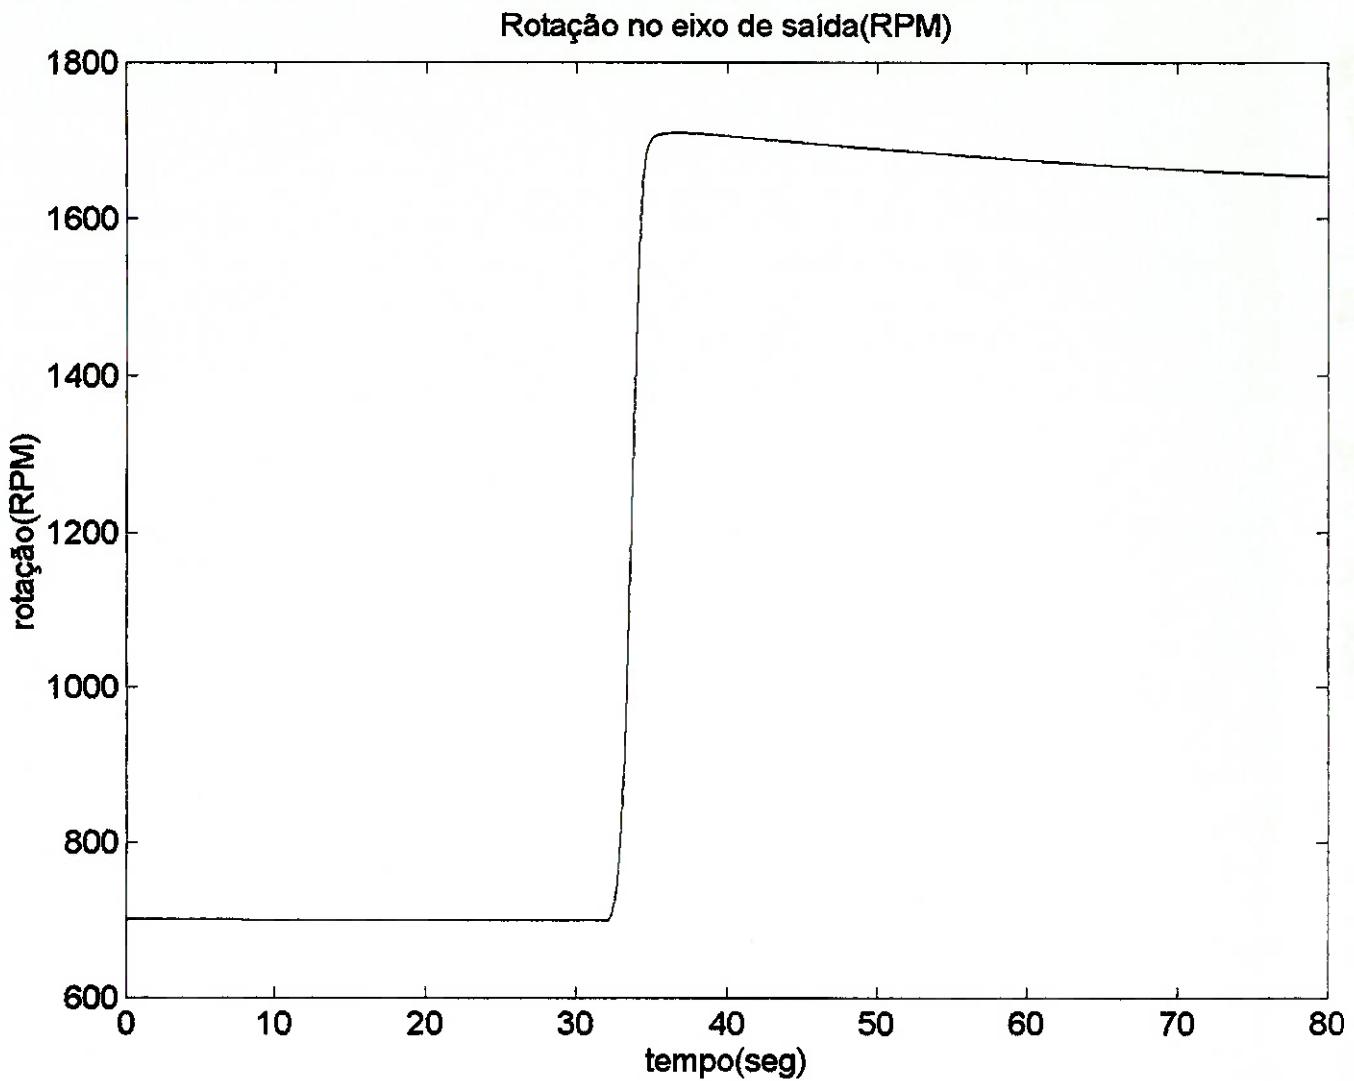


Figura 17 - Rotação

Nota-se que a curva de resposta do modelo, segue bem a curva de referência exigida para a rotação. Com uma excelente aproximação, mesmo no regime transitório.

Tal rotação de saída se refere a resposta do eixo quando é variado pelo usuário o potenciômetro do dinamômetro.

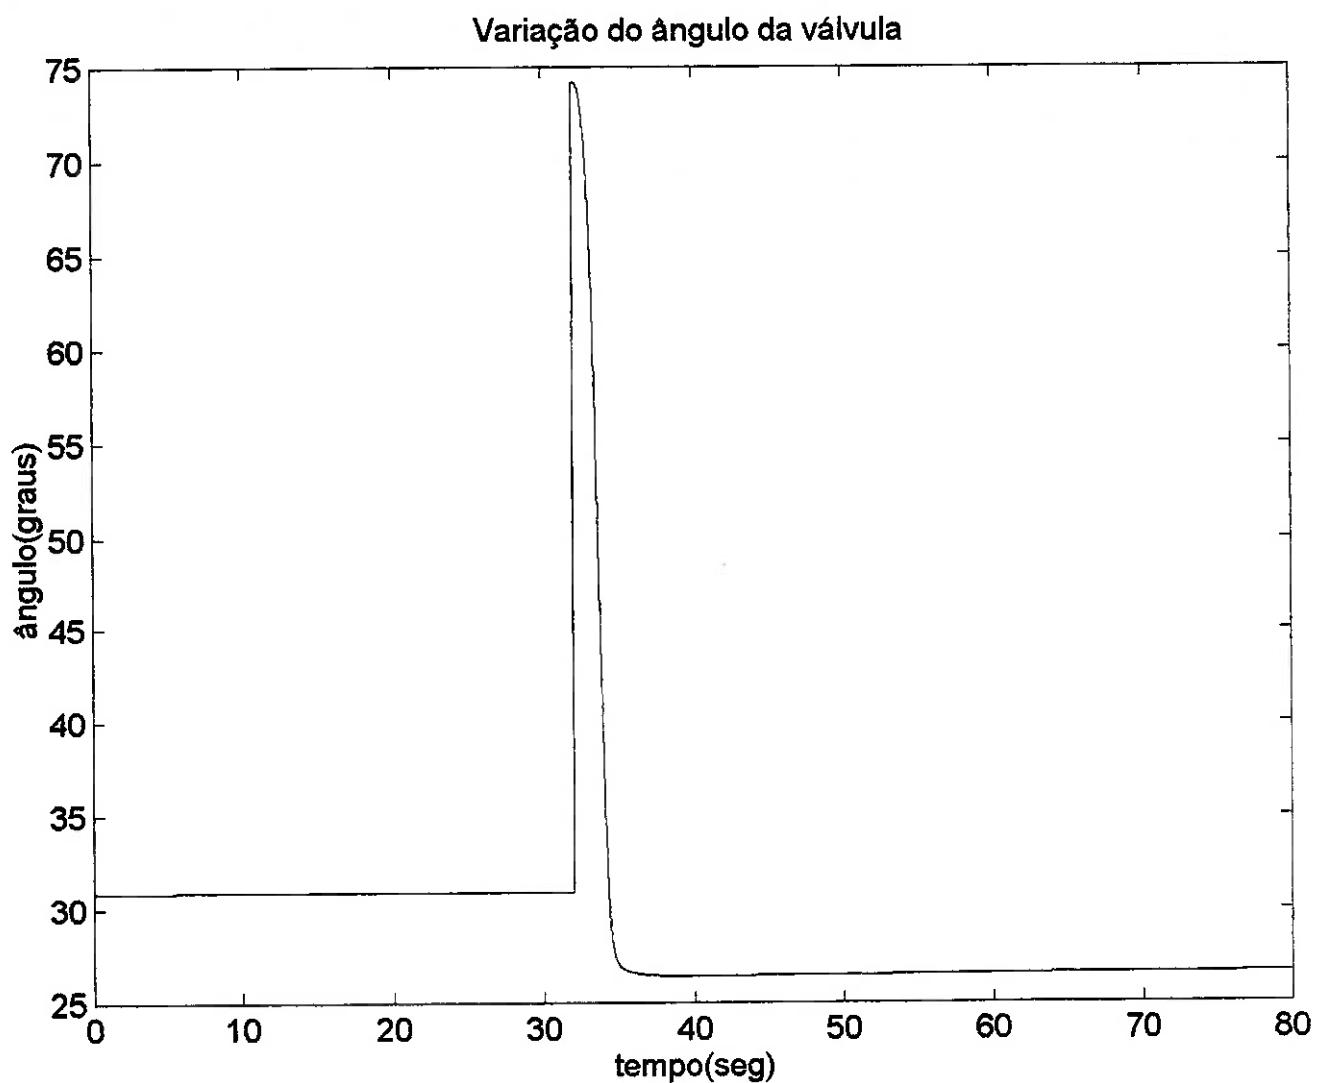


Figura 18 - Variação no ângulo da válvula (alfa)

Para o aumento de rotação o que era de se esperar era o fechamento da válvula borboleta para manter a vazão de saída de 0,3 l/s. Isto foi verificado.

O pico próximo a 30 seg. se refere ao regime transitório, onde há uma variação da válvula até conseguir se ajustar adequadamente.

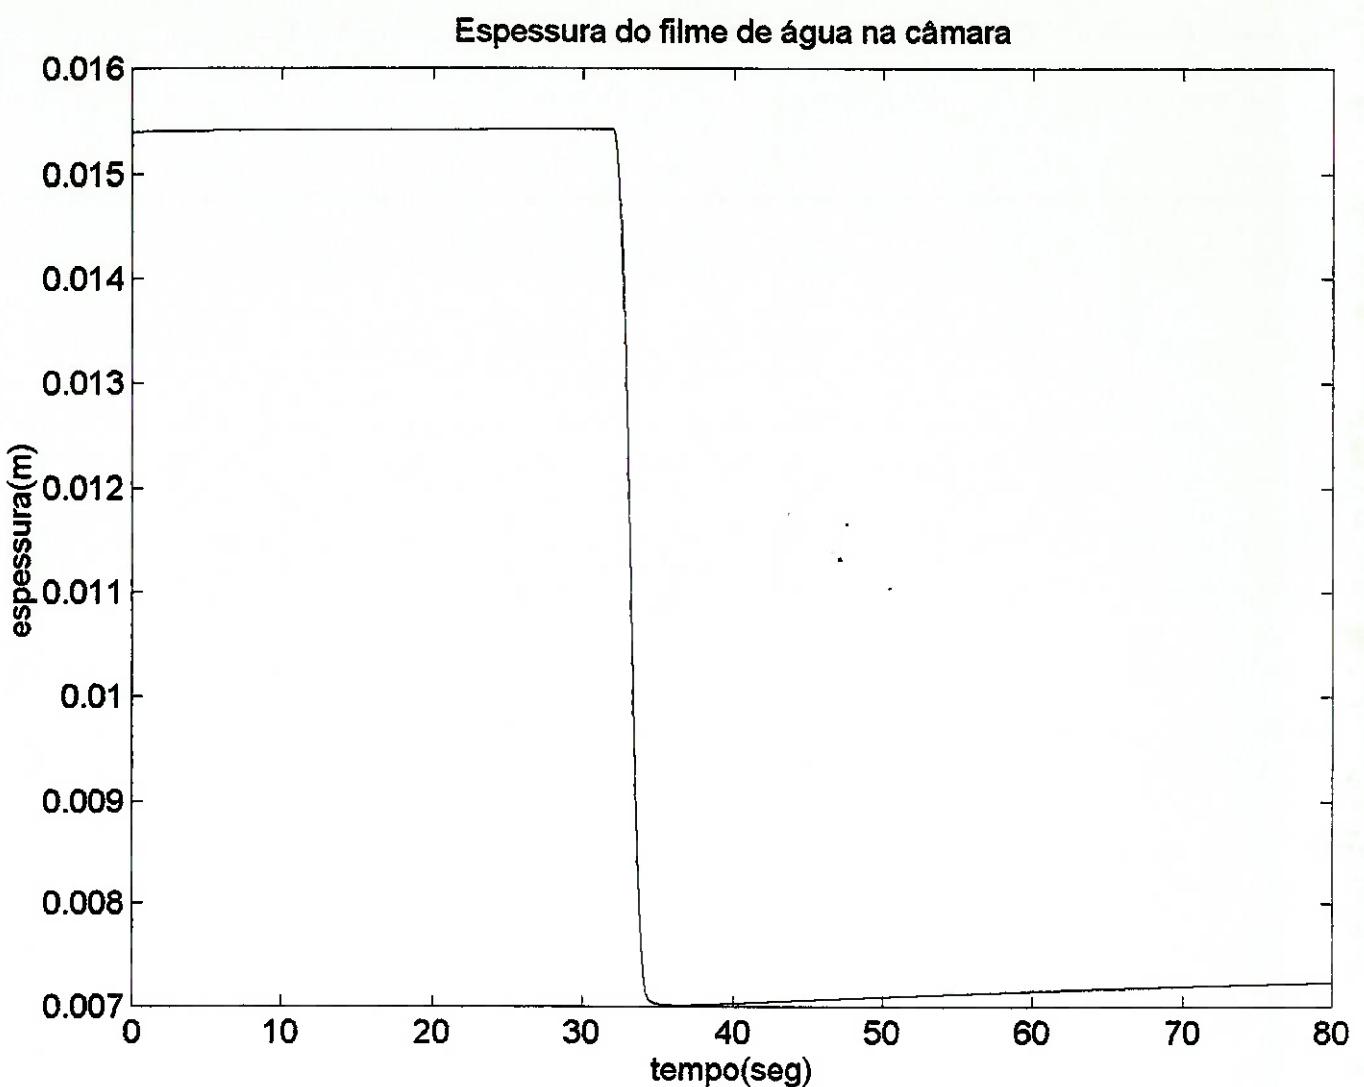


Figura 19 - Espessura do filme de água na câmara de turbilhonamento

Os exemplos mostrados acima são algumas variáveis que podem ser obtidas do modelo do dinamômetro.

Apesar da alta não linearidade do sistema, o modelo responde bem às exigências a ele atribuída, e deste modo, permite a compreensão de aspectos importantes da dinâmica do dinamômetro, inclusive no regime transitório.

Espera-se que se a rede neural implementada reproduzir bem às curvas do modelo, provavelmente ela também reproduzirá bem às curvas do dinamômetro real, já que o modelo implementado apresenta uma reprodução bem próxima do existente na realidade.

- Em 1982, John Hopfield, apresentou um "paper" para a National Academy of Sciences. Utilizando de seu prestígio e carisma, ele apresentou uma combinação de elementos interconectados em "layers" que resolia os problemas insolúveis citados em 1969; deste modo, trouxe de volta o interesse pelo estudo de redes neurais e também os incentivos e patrocínios para o desenvolvimento da área.

Os fatos descritos servem para se ter uma noção dos altos e baixos momentos ocorridos durante o estudo de redes. Hoje em dia a rede neural está em alta e muitas pesquisas vem sendo realizadas nas mais diversas áreas. A curiosidade e mesmo utilização como ferramenta auxiliar têm proporcionado um grande investimento pessoal em variados campos de pesquisa.

4.2) FUNCIONAMENTO BÁSICO

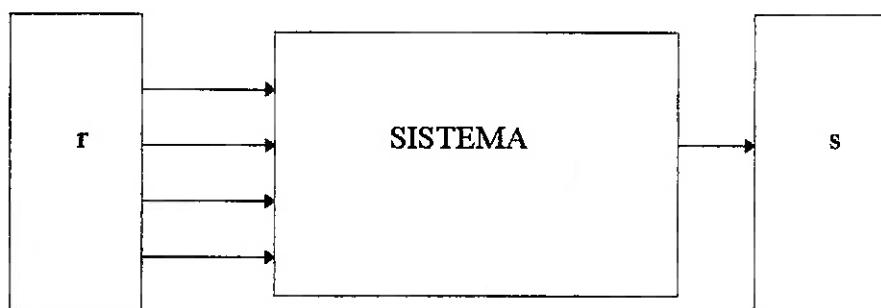
O cérebro humano é um dos objetos de estudos mais complexos e desconhecidos pelo homem. Sua capacidade de calcular, lembrar e solucionar problemas tem instigado o homem a tentar imitá-lo .

As redes neurais, obviamente, estão muito distantes dos neurônios reais; entretanto a forma permite realizar uma analogia entre eles.

Para uma melhor compreensão desta ferramenta e sua analogia com o real, é necessário conhecê-la melhor.

A seguir será explicado como utilizar a rede neural como ferramenta de modelagem de sistemas reais existentes. É conveniente salientar que esta não é a única aplicação para redes, e sim, uma das diversas possíveis.

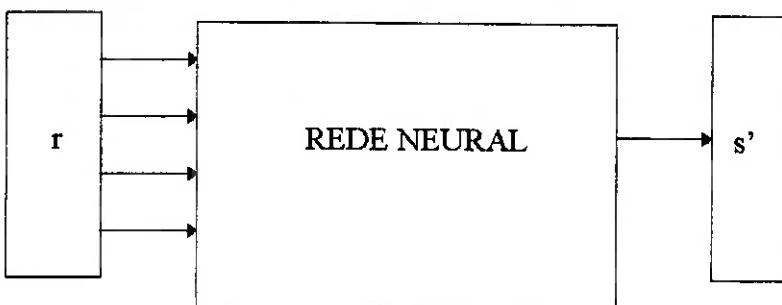
Seja a seguinte situação:



Um sistema com vetor de entrada r e vetor de saída s .

Deseja-se que a rede neural comporte-se exatamente como este sistema.

Assim sendo, fornecendo a mesma entrada r para a rede neural, ela deve fornecer uma saída s' muito parecida e próxima de s .



A seguir será mostrado o que existe dentro do bloco "rede neural", para melhor compreensão de como fornecer saídas próximas as desejadas utilizando as mesmas entradas.

Na figura 20a. pode-se ver o chamado neurônio:

As entradas $r_1, r_2, r_3\dots$ são multiplicadas por pesos $w_1, w_2, w_3\dots$, e somados com um bias, ou seja, $r_1w_1 + r_2 w_2 + r_3w_3\dots + \text{bias}$, este resultado passa por uma função de transferência e fornece uma saída.

Podem existir diversos neurônios dispostos em uma coluna. É o chamado layer ou camada (figura 20b.).

Um segundo neurônio logo abaixo do primeiro "pegaria" as mesmas entradas só que existiriam novos pesos e bias.

A função de transferência normalmente é a mesma para todos os neurônios, entretanto pode ser diferente.

Pode haver mais de uma camada, onde a entrada da segunda camada será a saída da primeira.

O conjunto de neurônios e camadas é o que se chama rede neural (figura 20c.)

NEURÔNIO

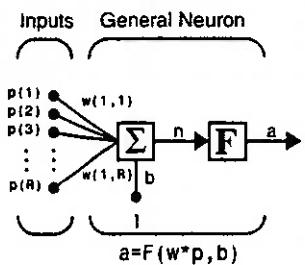


Figura 20a - Neurônio

CAMADA DE NEURÔNIOS (LAYER)

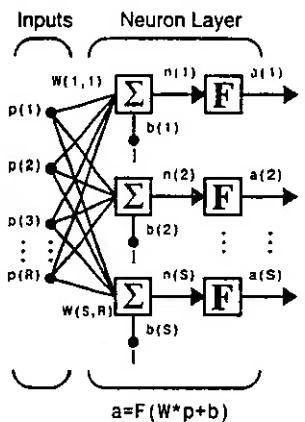


Figura 20b - Camada de neurônios

REDE NEURAL

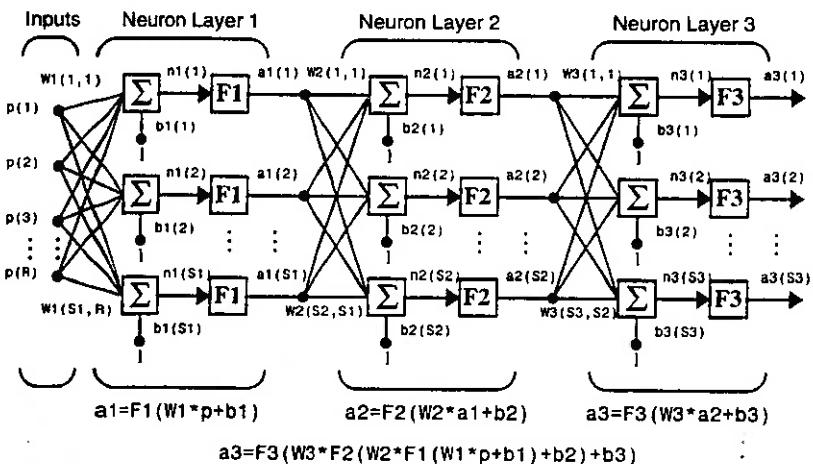


Figura 20c - Rede Neural

Até agora foi comentado sobre a estrutura da rede neural, a seguir, será descrito como um conjunto de contas e funções matemáticas fornece uma saída próxima a desejada.

Isso é feito através do treinamento ou aprendizado de uma rede, ou seja, é fornecido para a rede, a entrada e saída do sistema.

A rede "pega" a entrada como visto acima, e fornece uma saída. A saída da rede é comparada com a saída do sistema, a diferença é o erro.

Este erro passa por um algoritmo de aprendizado que modifica os valores dos pesos e do bias, fornecendo uma nova saída. A nova saída é novamente comparada, e o novo erro passa pelo mesmo algoritmo e fornece novos pesos e bias. Diversas iterações ocorrem até que o erro seja menor do que o estipulado, ou seja, o erro é considerado aceitável.

Quando este processo termina, pode-se dizer que a rede "aprendeu", ou então, ela está treinada.

Desse modo, se for fornecido uma nova entrada diferente das usadas para o treinamento, a rede neural fornecerá uma saída que deverá ser a mesma que o sistema forneceria.

Uma melhor aproximação, ou então, iterações mais rápidas podem ser obtidos alterando os diversos componentes de uma rede neural: número de camadas, número de neurônios, algoritmo de aprendizado, função de transferência, pesos e bias iniciais, ou mesmo, pontos de operação dos vetores de entrada e saída.

As características de cada uma delas vai ser visto a seguir.

Número de Camadas

Será usado no trabalho, uma rede neural com duas camadas. Já que o sistema é altamente não linear, e uma camada não é suficiente.

Esta escolha é baseada no teorema de Kolmogorov, que diz que duas camadas são suficientes para mapear um vetor de entrada de dimensão n num vetor qualquer de saída de dimensão m, portanto mais que duas é desnecessário.

Número de Neurônios

O mesmo teorema de Kolmogorov, diz que para um vetor de entrada de dimensão n, $2n + 1$ neurônios na primeira camada é suficiente para realizar o

mapeamento num vetor de saída de dimensão m(na segunda camada devemos ter m neurônios).

Dentre os $2n+1$ neurônios, pode-se testar se um neurônio é descartável ou não, da seguinte forma. Se este neurônio for combinação linear dos demais neurônios da rede, aquele é um candidato a ser retirado da rede, ou seja, se a saída que ele produz pode ser representado por uma combinação linear das saídas dos demais neurônios, ele poderá ser retirado.

Lembrando que quanto maior for o número de neurônios, mais tempo será gasto na simulação da rede, sendo importantíssimo, portanto o estudo de neurônios excedentes.

Algoritmos de Aprendizado

Convém ressaltar que, decidiu-se utilizar o algoritmo de aprendizado back-propagation, já que este, segundo a literatura(manual do toolbox do matlab, por exemplo) é usado em aproximadamente 85% das aplicações práticas, pois é uma ferramenta muito poderosa capaz de mapear vetores de entrada em saídas para quase todas as aplicações.

A figura 21 mostra um esquema simplificado deste algoritmo de aprendizado.

O Back-Propagation consiste em corrigir primeiro os pesos da última camada(saída), para depois corrigir os pesos da primeira camada(camada escondida). A figura 9 mostra a estrutura deste algoritmo, ressaltando como é feita a correção dos pesos.

Primeiro corrige-se os pesos da camada 2 (saída) a partir da fórmula :

$$\Delta W^* = \eta \cdot d^* \cdot S$$

onde : ΔW^* = acréscimo feito a cada peso em cada iteração

η = coeficiente de velocidade de aprendizado (é um valor constante)

S = saída de cada neurônio da última camada em cada instante

$d^* = (T-S) \cdot S \cdot (1-S)$; T = Target (saída desejada em cada instante)

A expressão do erro, dada por d^* é então “back-propagada” para a camada 1 (escondida), para que a correção dos pesos desta camada seja feita :

$$\Delta W = \eta \cdot d \cdot S$$

onde : ΔW = acréscimo feito a cada peso em cada iteração

η = coeficiente de velocidade de aprendizado (é um valor constante)

S = saída de cada neurônio da última camada em cada instante

$$d = (\sum d^* \cdot W^*) \cdot S \cdot (1-S)$$

Funções de transferência

As funções utilizadas são a ‘tansig’, ou melhor uma tangente sigmóide hiperbólica que mapeia uma entrada que varia de um intervalo $(-\infty, +\infty)$ para um intervalo $(-1, +1)$.

Seu uso é eficaz quando se usa como algoritmo de aprendizado o back-propagation.

Na segunda camada a função utilizada é a purelin. É uma função linear que é muito utilizado quando se treina uma rede com Widrow-Hoff ou com a back-propagation. Esta função simplesmente transfere um vetor de entrada para a saída, alterado apenas pela soma do bias.

As funções acima foram as que apresentaram os melhores resultados para estes tipos de sistemas.

Pesos e bias iniciais

Verifica-se que além de estarem no intervalo $(-1, +1)$, os pesos e bias iniciais dependem da combinação entre eles. Uma boa combinação de pesos e bias iniciais é conveniente para melhor funcionamento da rede.

Pontos de operação dos vetores de entrada e saída.

Durante a execução do programa verificou-se que é importante que este tipo de rede seja treinada com entradas e saídas com a mesma ordem de grandeza.

Ao mesmo tempo, notou-se que é interessante manter os vetores com uma ordem de grandeza de 10^{-1} . A não utilização deste campo de grandeza para as funções determinadas acima pode provocar a divergência da rede.

Back Propagation

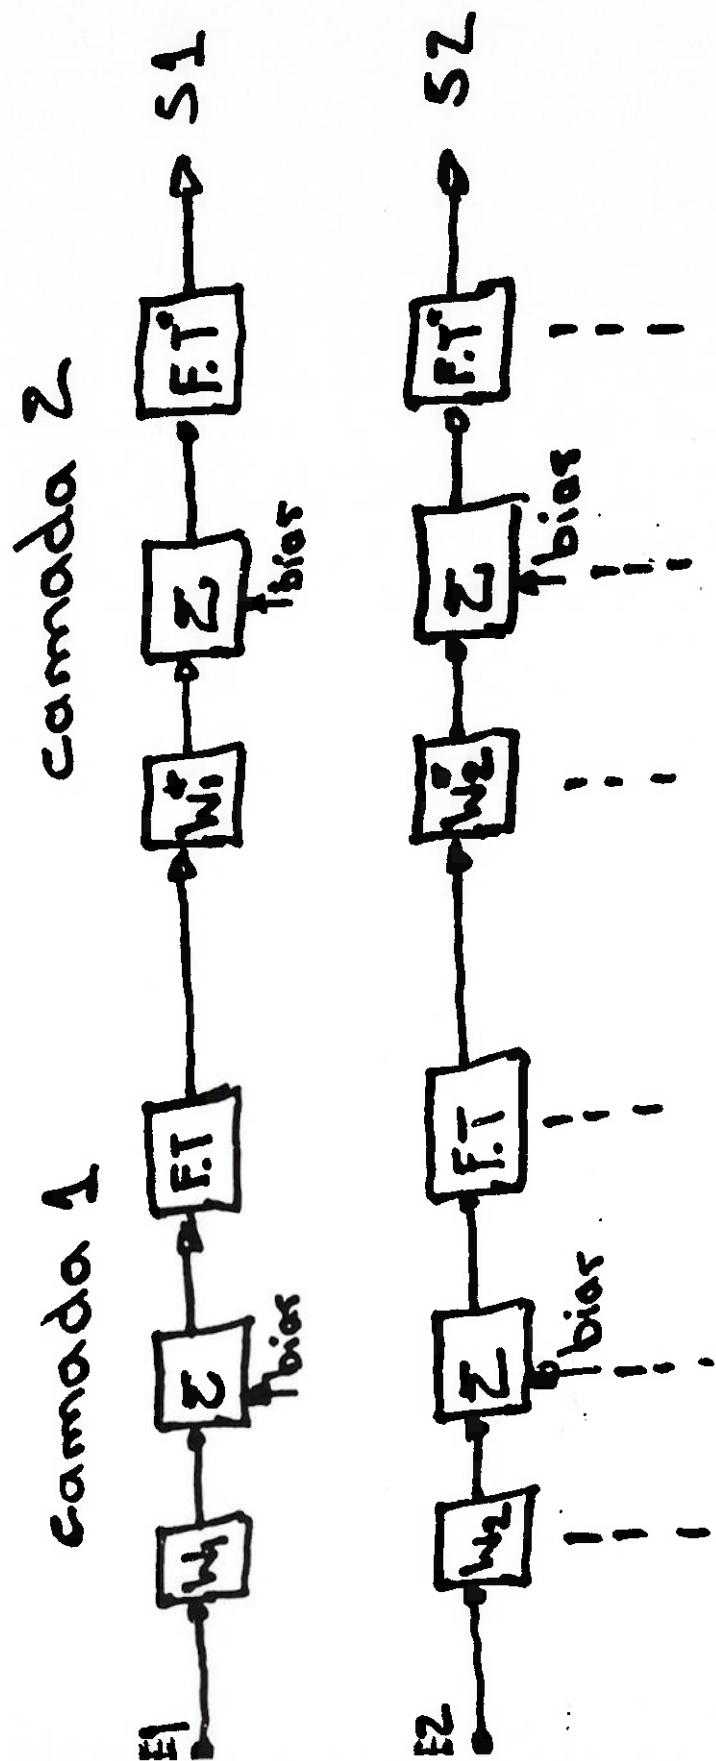


Figura 21 - Back Propagation

$$\Delta w^{nr} = \eta \cdot d^* \cdot s \quad \text{onde } d^* = (\tau - s) \cdot s \cdot (1-s)$$

$$\Delta w = \eta \cdot d \cdot s \quad \text{onde } d = (\Sigma \cdot d^*) \cdot s \cdot (1-s)$$

CAPÍTULO 4 : REDES NEURAIS

4.1) HISTÓRIA

A seguir um breve resumo do surgimento e do desenvolvimento das redes neurais até os dias de hoje.

- Em 1943, um neurobiologista, Warren McCulloch, e um estatístico, Walter Pitts, publicam um "paper" intitulado "Um cálculo lógico de idéias eminentes na atividade nervosa." Este estudo serviu de inspiração para o desenvolvimento de diversos campos como: Computadores digitais(John von Neumann), Inteligência artificial(Marvin Minsky) e perceptron(Frank Rosenblatt).
- Em 1956, numa conferência de inteligência artificial, patrocinada pela fundação Rockefeller, é discutido a potencialidade dos computadores de aprenderem. Nathaniel Rochester, da IBM research, apresenta uma rede neural que ele vinha desenvolvendo. Apesar de Rochester não saber interpretar as informações ainda, este foi o primeiro software de simulação de redes neurais conhecido.
- Em 1957, Frank Rosenblatt, publicou o primeiro grande projeto na área de computação neural, o perceptron. Trata-se de um modelo(rede neural) capaz de aprender, emitindo como saída valores com dois estados, binários(1 ou 0) por exemplo.
- Em 1959, Bernard Widrow, de Stanford, desenvolveu as chamadas Adaline e Madaline. Widrow usou este algoritmo para desenvolver um filtro adaptativo que eliminava ecos nas linhas telefônicas. Foi a primeira vez que um sistema neural era aplicado em um problema real.
- A partir de 1960, Marvin Minsky e Seymour Papert, do laboratório de pesquisas eletrônicas do MIT, começaram a desenvolver uma profunda crítica ao perceptron. No livro *Perceptron*, lançado em 1969, eles publicaram uma detalhada análise matemática do perceptron. A conclusão era de que as redes neurais não eram objetos interessantes de estudo; já que não resolviam problemas como o Exclusive(OR function). O resultado foi o declínio de fundos e consequentemente pesquisas neste campo.

CAPÍTULO 5 : O PROCESSO DE IMPLEMENTAÇÃO DAS REDES

Foi decidido trabalhar com o Tool Box de Redes Neurais do Matlab, que possui diversas funções predefinidas de aprendizado e de montagem de estrutura de rede. O processo de implementação foi bastante gradativo, ou seja optou-se por procurar entender exatamente o que se passa dentro da rede neural, tanto a nível de aprendizado quanto a nível de simulação antes de usar as funções predefinidas para modelar direto o motor e o dinamômetro.

5.1) PRIMEIRO PASSO : ALGORITMO EM PASCAL

O primeiro passo foi desenvolver um algoritmo de aprendizado de rede utilizando linguagem Pascal com um objetivo sobretudo didático. O sistema que foi modelado não tinha nenhuma relação com o motor ou o dinamômetro, e foi retirado de um exemplo do Matlab. Este sistema não era dinâmico e nem tão pouco não-linear. O que se fez foi um simples mapeamento estático a partir dos vetores de entrada e saída. O algoritmo de aprendizado implementado tinha a lei de formação baseada num algoritmo consagrado denominado “perceptron”.

Com esta tarefa pode-se adquirir uma noção de como as variáveis de aprendizado (valores iniciais de pesos e bias, coeficiente de aprendizado, número de iterações, etc.) influenciam na convergência da resposta da rede.

Constatou-se algumas afirmações da literatura, como o fato de que os pesos iniciais não devem estar fora do intervalo [-1,1] sob pena de não haver convergência. Outro aspecto observado foi que coeficientes de aprendizado menores, apesar de diminuírem a velocidade de convergência, garantem respostas mais precisas.

A listagem deste programa encontra-se no anexo, no final do trabalho.

5.2) SEGUNDO PASSO : IDENTIFICAÇÃO DE SISTEMAS LINEARES DINÂMICOS

Um sistema dinâmico é aquele cujos estados atuais dependem dos estados anteriores e das entradas anteriores.

Montou-se no ambiente do Simulink um sistema linear e dinâmico bem simples, com apenas uma entrada e uma saída, cuja saída dependia de duas entradas anteriores e

de uma saída anterior , como mostra a figura 22.

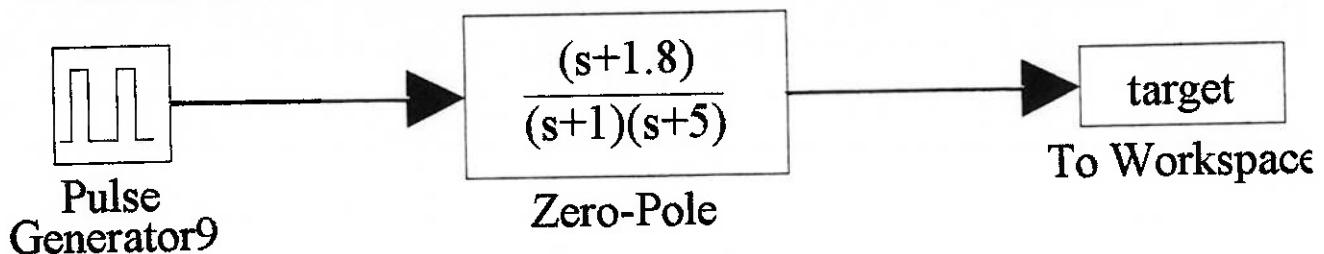


FIGURA 22 - Sistema linear dinâmico

A partir deste momento passou-se a utilizar os algoritmos de aprendizado predefinidos do Toolbox de redes neurais. Foi construída uma rede de apenas uma camada de neurônios e o algoritmo de aprendizado escolhido foi o chamado “purelin”(puramente linear), que apresentou resultados bem satisfatórios.

Após aumentar o número de entradas e saídas, tanto o aprendizado quanto a posterior simulação continuavam a mostrar resultados satisfatórios.

A nível de aprendizado não houve problema. No momento de utilizar a rede com uma outra entrada qualquer, era necessário promover uma realimentação, ou seja, era preciso que a saída em determinado instante fosse utilizada como entrada em instantes posteriores. Entrando no detalhe do funcionamento da rede, foi montado um programa no Matlab que utilizava toda matriz de pesos, todas as entradas e todas as saídas.Fucionou.

5.3) TERCEIRO PASSO : IDENTIFICAÇÃO DE SISTEMAS NÃO-LINEARES E DINÂMICOS

Ainda no ambiente do Simulink, foi colocado blocos de não-linearidades acoplados ao exemplo anterior, de forma a criar um sistema não-linear (figura 23).

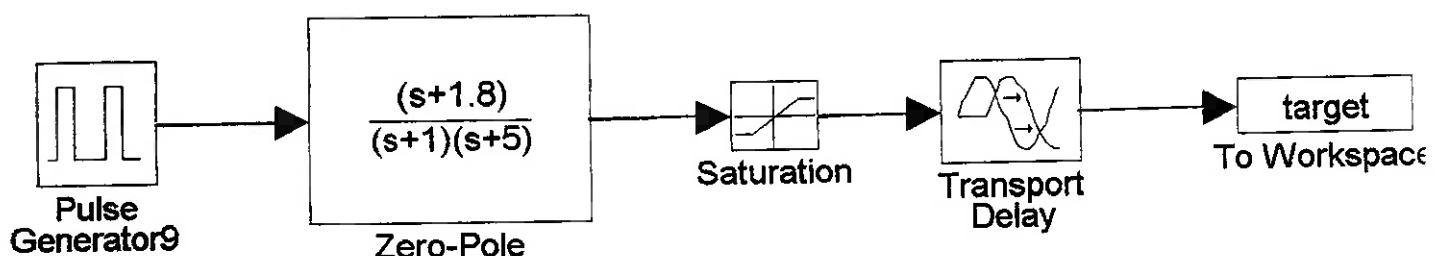


FIGURA 23 - Sistema não-linear dinâmico

Verificou-se aí um sistema que depende de uma entrada anterior e de duas saídas anteriores, cuja não-linearidade está nos blocos de saturação (“saturation”) e de

atraso de transporte (“transport delay”). Grande parte das experiências foram feitas em cima deste exemplo, mudando o tipo de entrada, as constantes, os tipos de não-linearidades, etc.

Verificou-se que um rede com apenas uma camada de neurônios e treinada com o algoritmo “purelin” não era capaz de aprender. Como recomendava a literatura, montou-se uma rede com 2 camadas e submeteu-se esta a um algoritmo de aprendizado chamado de back-propagation. Os resultados de aprendizado foram muito bons, ou seja para aquela mesma entrada a resposta da rede bem a resposta do sistema. Entretanto a rede não conseguia reproduzir corretamente a resposta a uma entrada de formato diferente daquela para a qual ela foi treinada.

O que ocorria, na verdade, é que foi superestimado a capacidade da rede. A rede foi ensinada com uma entrada senoidal e havia a expectativa que ela fosse capaz de responder bem a um degrau por exemplo. O problema encontrava-se no domínio da frequência: uma senóide excita apenas uma frequência, enquanto que um degrau excita algumas. Descobriu-se que um bom sinal de entrada para aprendizado seria um ruído branco, que é capaz de excitar várias frequências. Foi feito então o treinamento da rede com um ruído branco e ela foi capaz de reproduzir com boa precisão a resposta de entradas senoidais, degraus, impulsos, trem de pulsos, etc.

Acrescentou-se um ruído numa entrada degrau utilizada para aprendizado e verificou-se que desta forma a rede conseguia acompanhar bem as respostas para outras entradas degrau de tamanhos diferentes.

A partir daquele momento tudo estava preparado para realizar a implementação das redes que iriam modelar o motor e o dinamômetro.

5.4) QUARTO PASSO : MODELAGEM FINAL DOS MODELOS DO MOTOR E DO DINAMÔMETRO

5.4.1) ETAPA 1 : Definição das variáveis de entrada e saída que se deseja modelar

MOTOR

Entradas : Aceleração ou variação no ângulo da borboleta (entrada degrau)

Vazão de combustível

Saídas : Pressão no coletor

Rotação do eixo

As duas entradas representam a admissão de ar e combustível no motor. As duas saídas definem o estado do motor durante e depois do transitório, ou sejam definem o ponto de operação. São saídas relevantes pois a unidade de controle precisa desses valores para controlar a relação ar-combustível.

No momento do aprendizado a entrada degrau (aceleração) é acrescida de um ruído branco, o que permite que a rede responda satisfatoriamente a degraus de entrada de intensidades diferentes.

DINAMÔMETRO

Entradas : Perfil de rotação (entrada degrau)

Saídas : Rotação

Nível de água na câmara de turbilhonamento

Abertura da válvula borboleta

A entrada degrau (perfil de rotação) é acrescida de um ruído branco pela mesma razão explicada anteriormente para o motor.

5.4.2) ETAPA 2 : Definição da estrutura das redes

MOTOR

Definiu-se uma única rede neural capaz de reconhecer as duas saídas desejadas (pressão e rotação).

Número de camadas de neurônios : 2

Número de neurônios da primeira camada : 8. Chegou-se a este número de uma maneira empírica, realizando diversos aprendizados com diferentes números de neurônios.

Número de neurônios da segunda camada : 2. Este número está relacionado com o número de saídas da rede, que são duas.

Função de transferência da primeira camada : tansig.

Função de transferência da segunda camada : purelin.

DINAMÔMETRO

Definiu-se três redes neurais, uma para cada tipo de saída (rotação, nível de água e ângulo da borboleta).

Todas as três redes apresentam duas camadas de neurônios, 1 neurônio na segunda camada e funções de transferência tansig e purelin para a primeira e segunda camada respectivamente.

A diferença está no número de neurônios da primeira camada. Para a rede 1 (rotação) o número de neurônios é 6. Para as outras duas o número é 5.

5.4.3) ETAPA 3 : Definição do algoritmo de aprendizado

O algoritmo utilizado foi uma variação mais veloz do backpropagation, chamado de Levenberg-Marquardt.

5.4.4) ETAPA 4 : Definição de quantas entradas e saídas anteriores deveriam ser informadas para o treinamento das redes

Ambos os sistemas são dinâmicos (estados atuais dependem de estados e entradas anteriores). Este aspecto deve ser considerado quando informa-se para a rede as entradas e saídas de aprendizado. Deve-se informar, além das entradas e saídas atuais, entradas e saídas atrasadas no tempo para que a rede reconheça a dinâmica do sistema.

MOTOR

Informou-se 3 entradas anteriores e 3 saídas anteriores.

DINAMÔMETRO

Rede 1 (rotação) - 4 entradas anteriores e 4 saídas anteriores

Rede 2 (nível de água) - 3 entradas anteriores e 5 saídas anteriores

Rede 3 (ângulo da válvula de saída) - 3 entradas anteriores e 5 saídas anteriores

Assim como o número de neurônios da primeira camada, os valores de atraso das entradas e das saídas também foram determinados de forma empírica, através de tentativas.

As listagens dos programas de aprendizado e simulação das redes encontram-se em anexo no final do trabalho.

CAPÍTULO 6 : RESULTADOS OBTIDOS

6.1) MOTOR

Treinou-se a rede para um degrau de variação de 75 graus a 80 graus no ângulo da borboleta. Os gráficos mostram uma comparação entre a resposta do modelo e resposta da rede, para várias entradas degraus diferentes.

Gráfico 1) Entrada degrau de 75° a 80° (Degrau para cima)

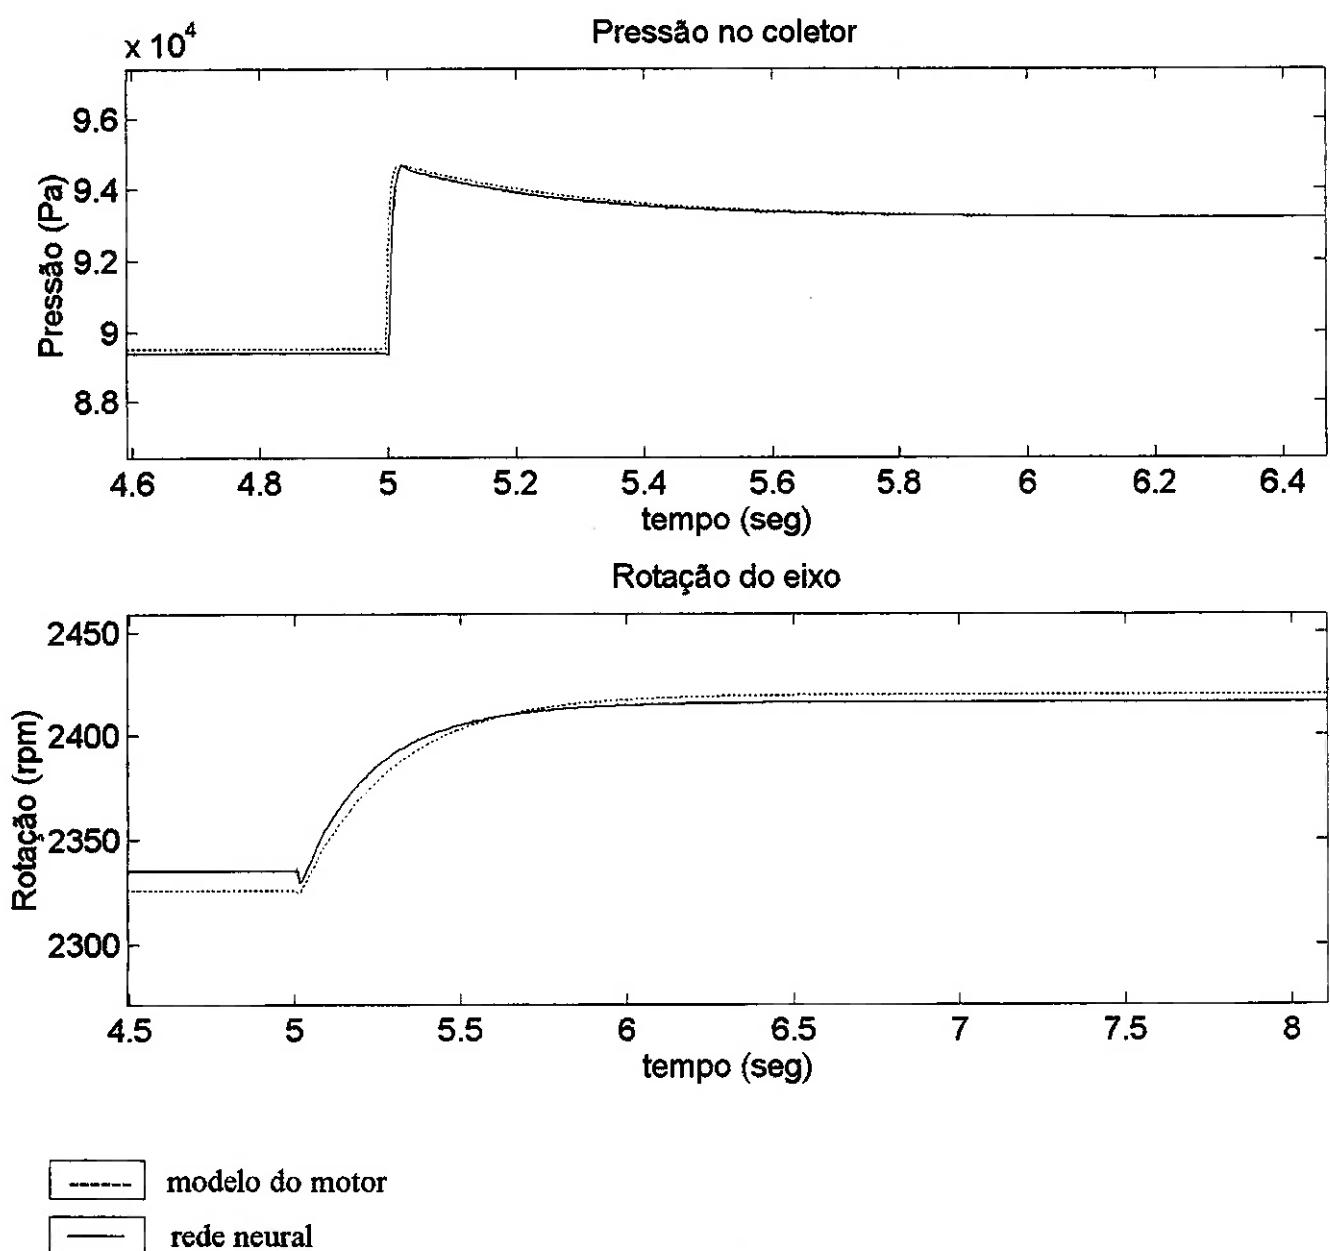


Gráfico 2) Entrada degrau de 75º a 85º (Degrau para cima)

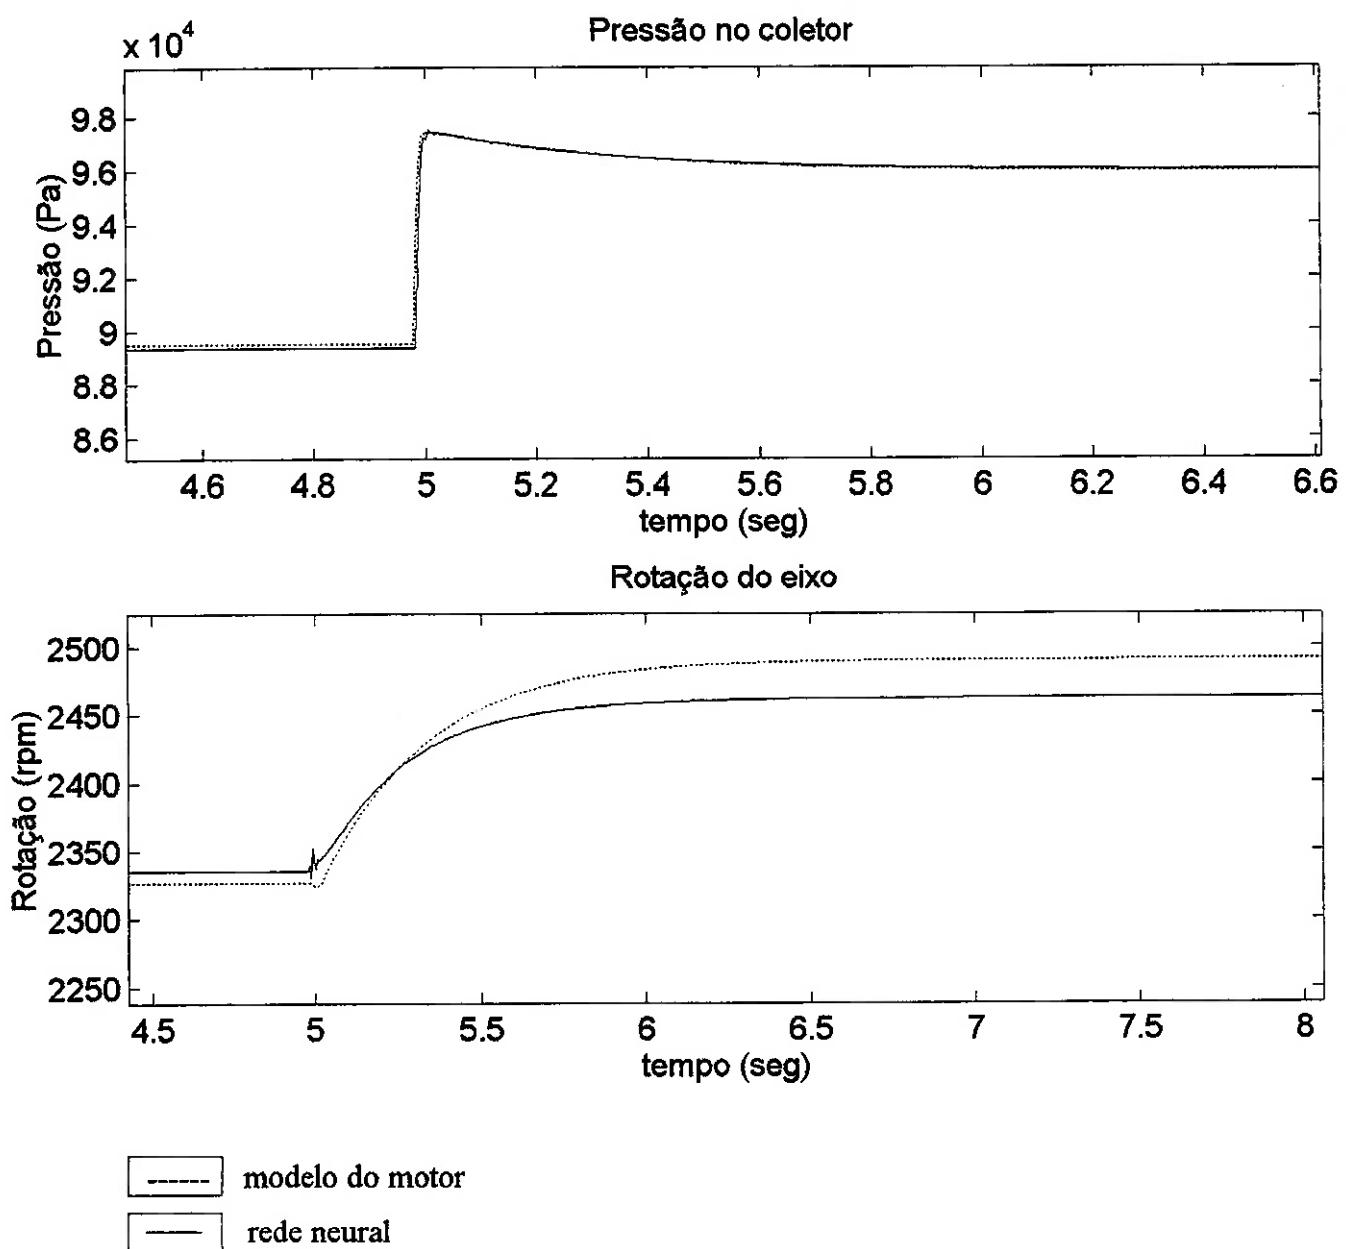


Gráfico 3) Entrada degrau de 75° a 90° (Degrau para cima)

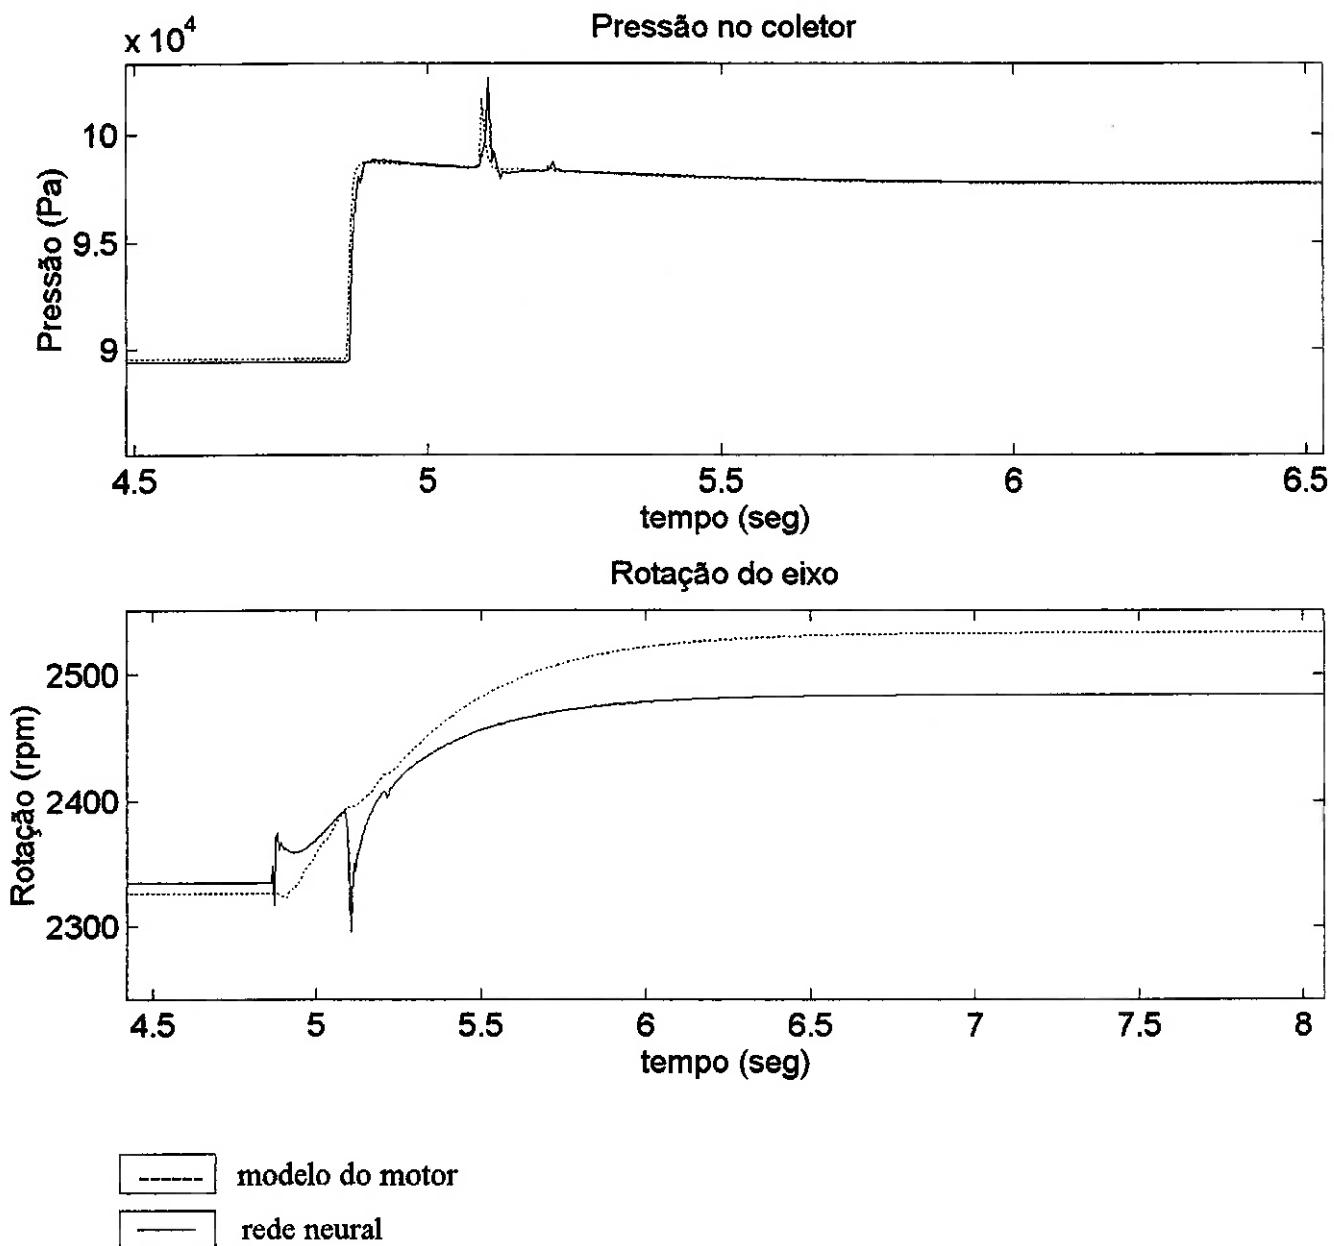


Gráfico 4) Entrada degrau de 80° a 75° (Degrau para baixo)

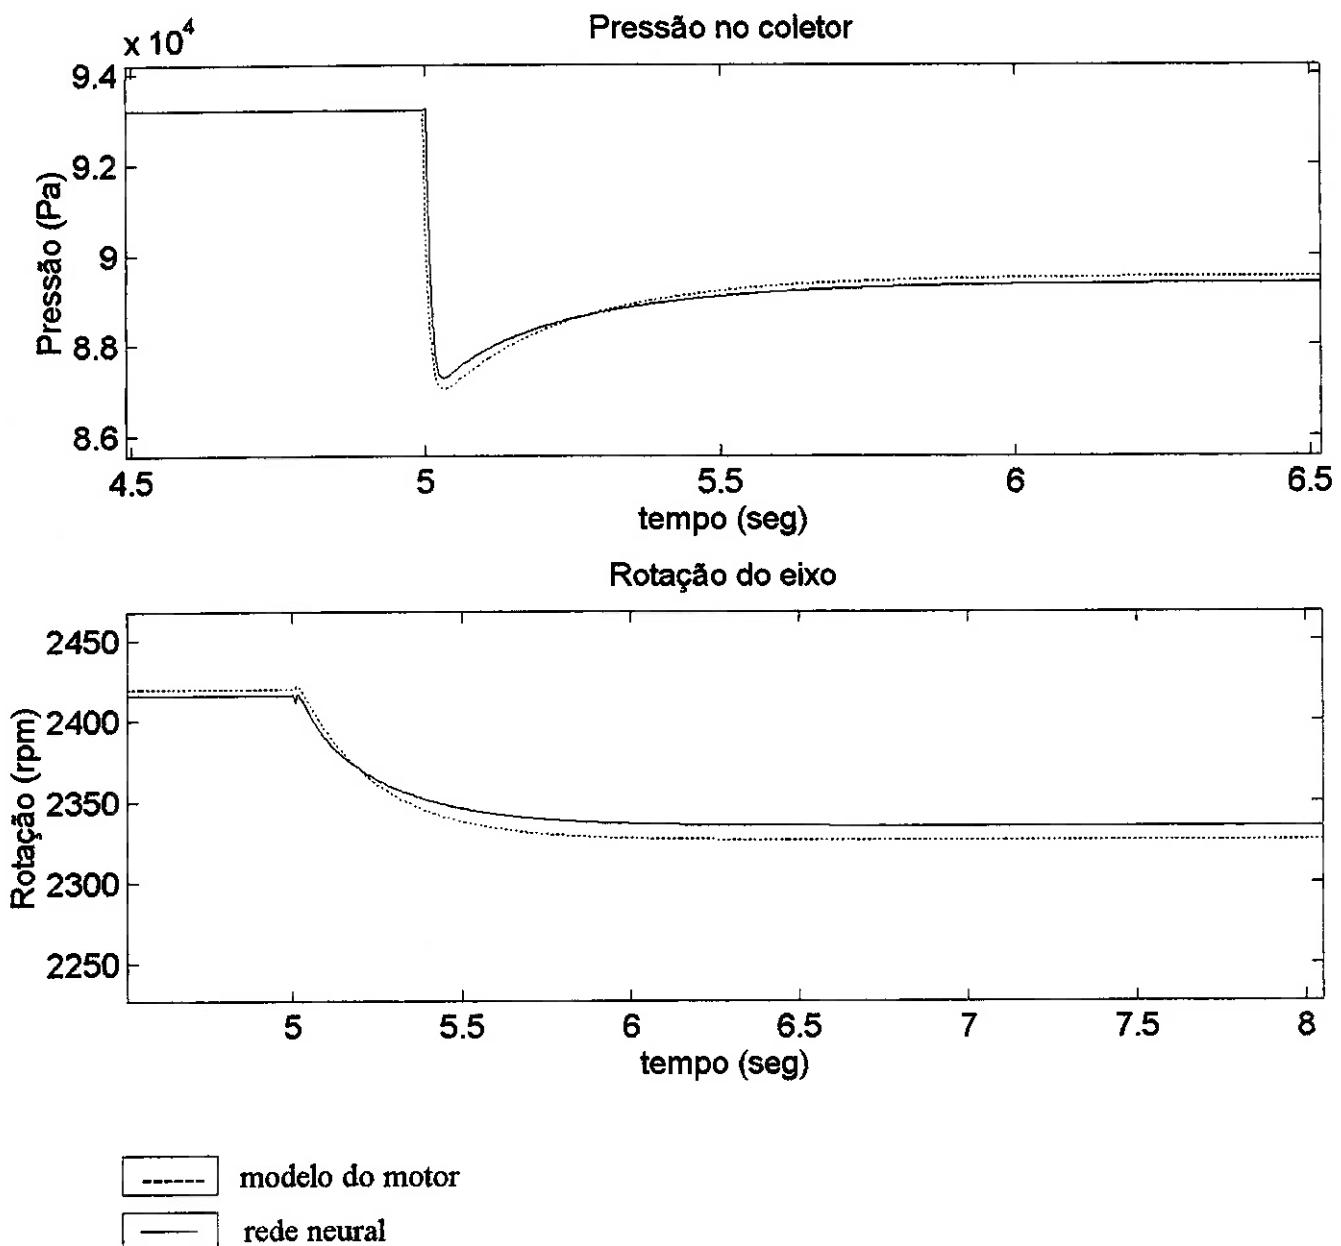


Gráfico 5) Entrada degrau de 85° a 75° (Degrau para baixo)

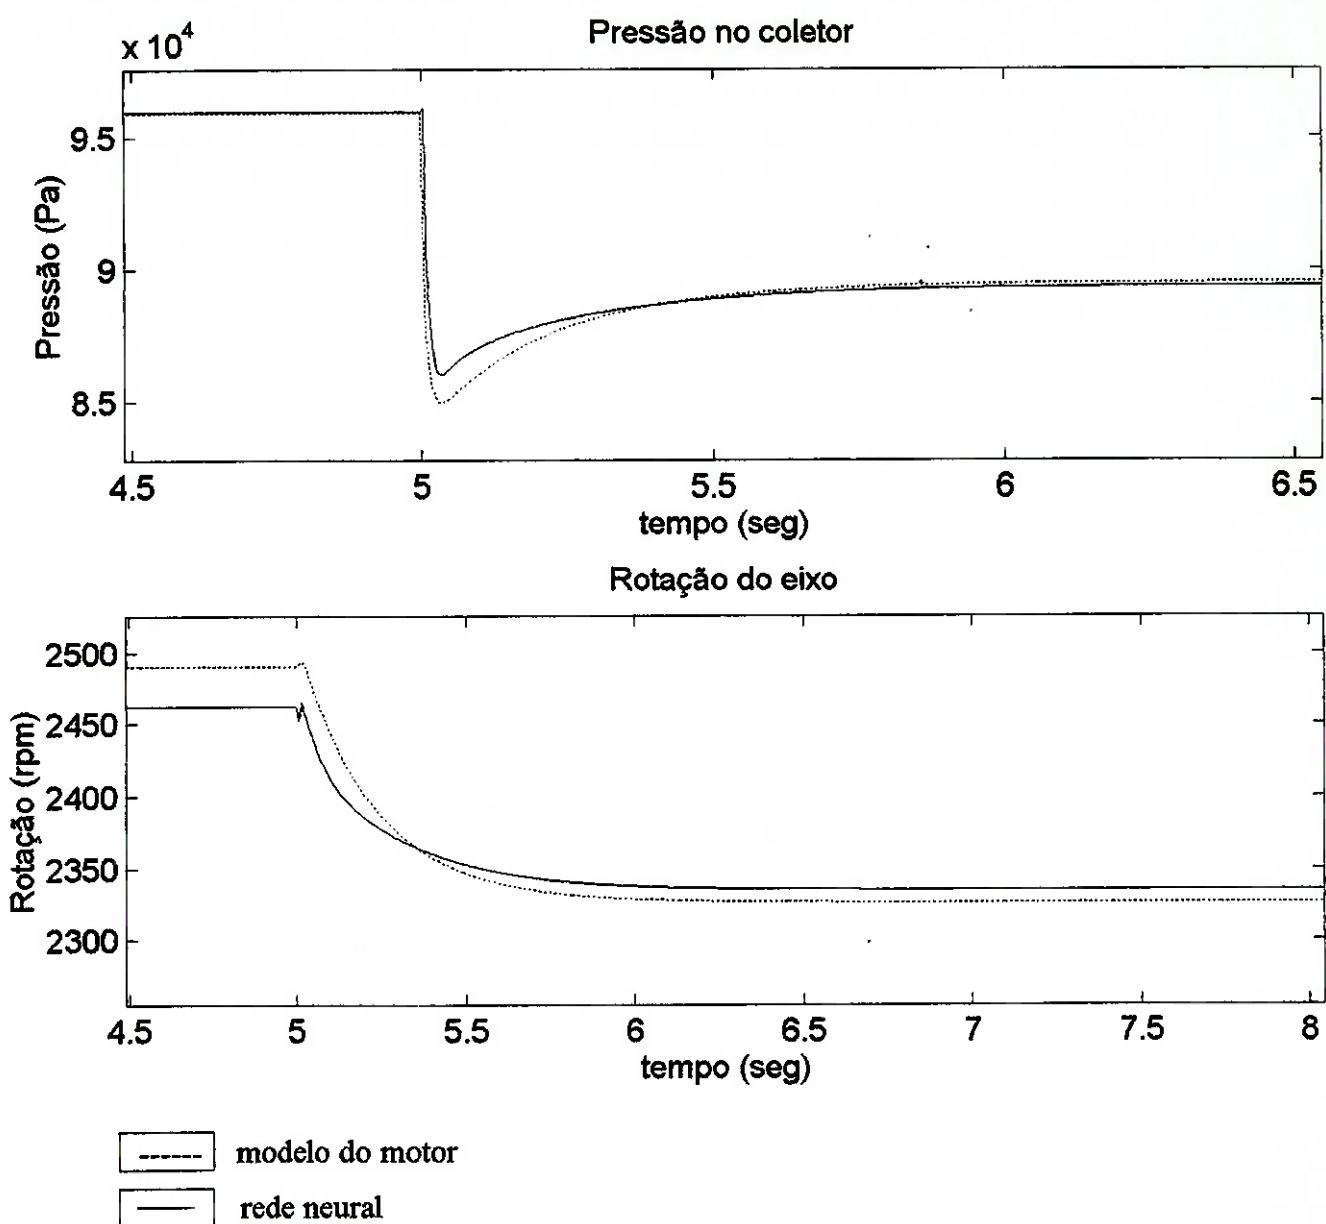
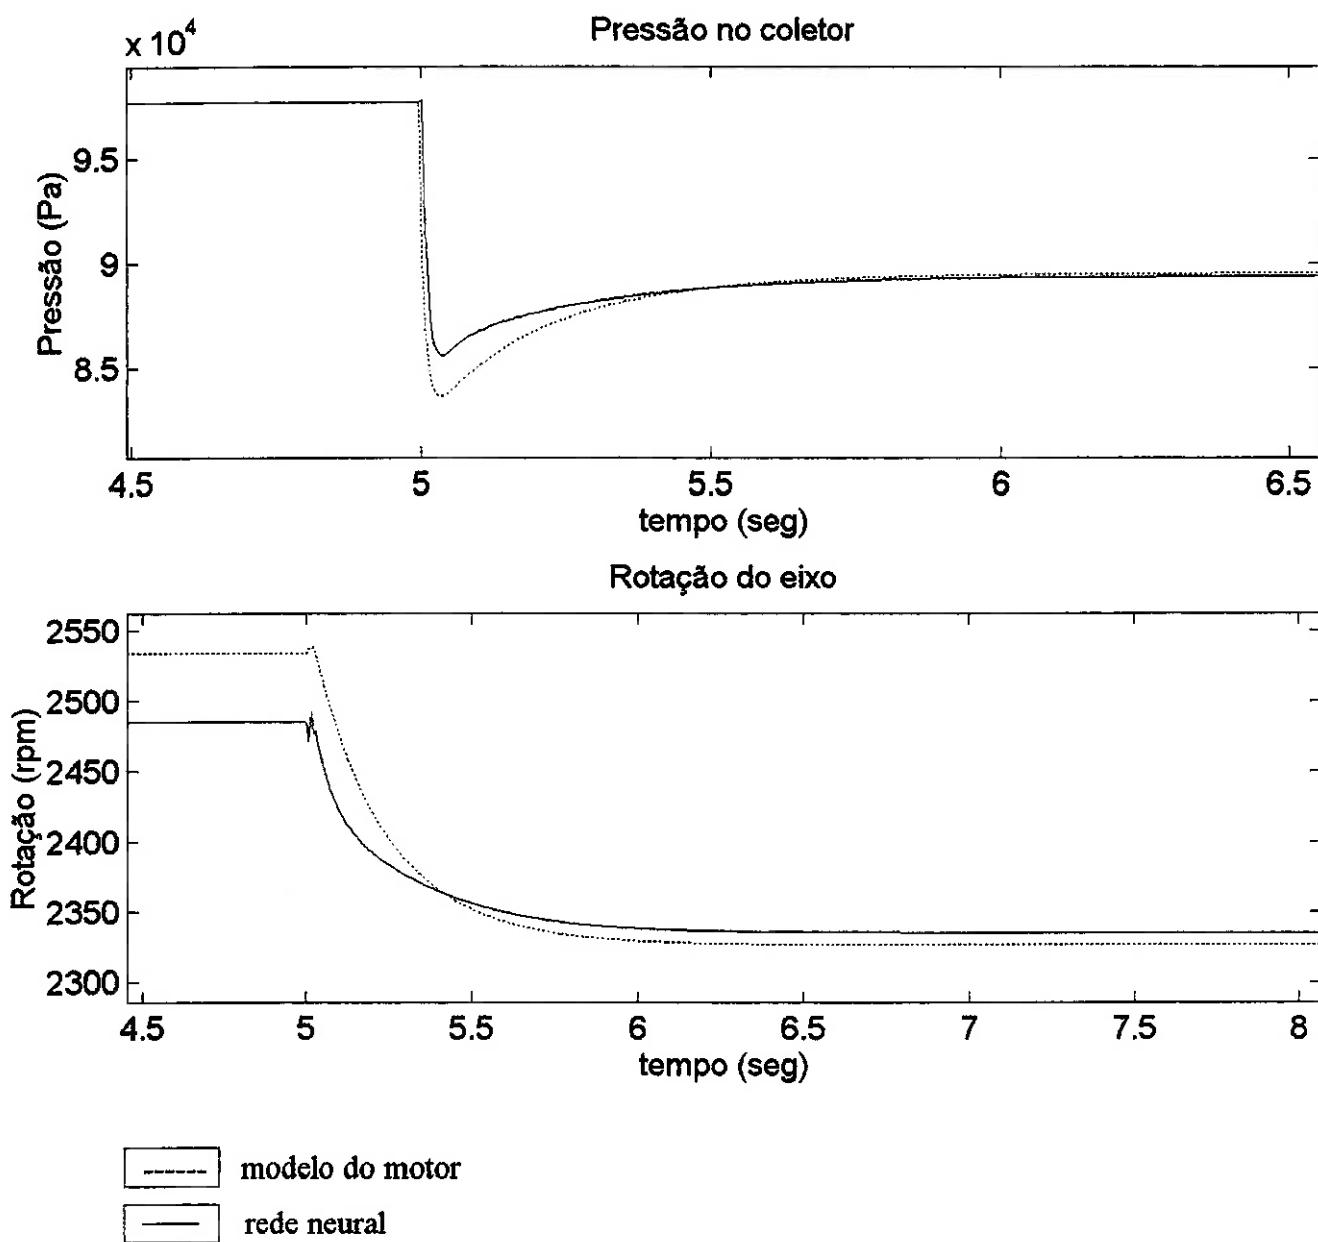


Gráfico 6) Entrada degrau de 90° a 75° (Degrau para baixo)



6.2) DINAMÔMETRO

Treinou-se as três redes para um degrau de variação de 700 rpm a 1600 rpm na rotação de referência. Os gráficos mostram uma comparação entre a resposta do modelo e resposta da rede, para várias entradas degraus diferentes.

Gráfico 7) Entrada degrau de 700 rpm a 1600 rpm

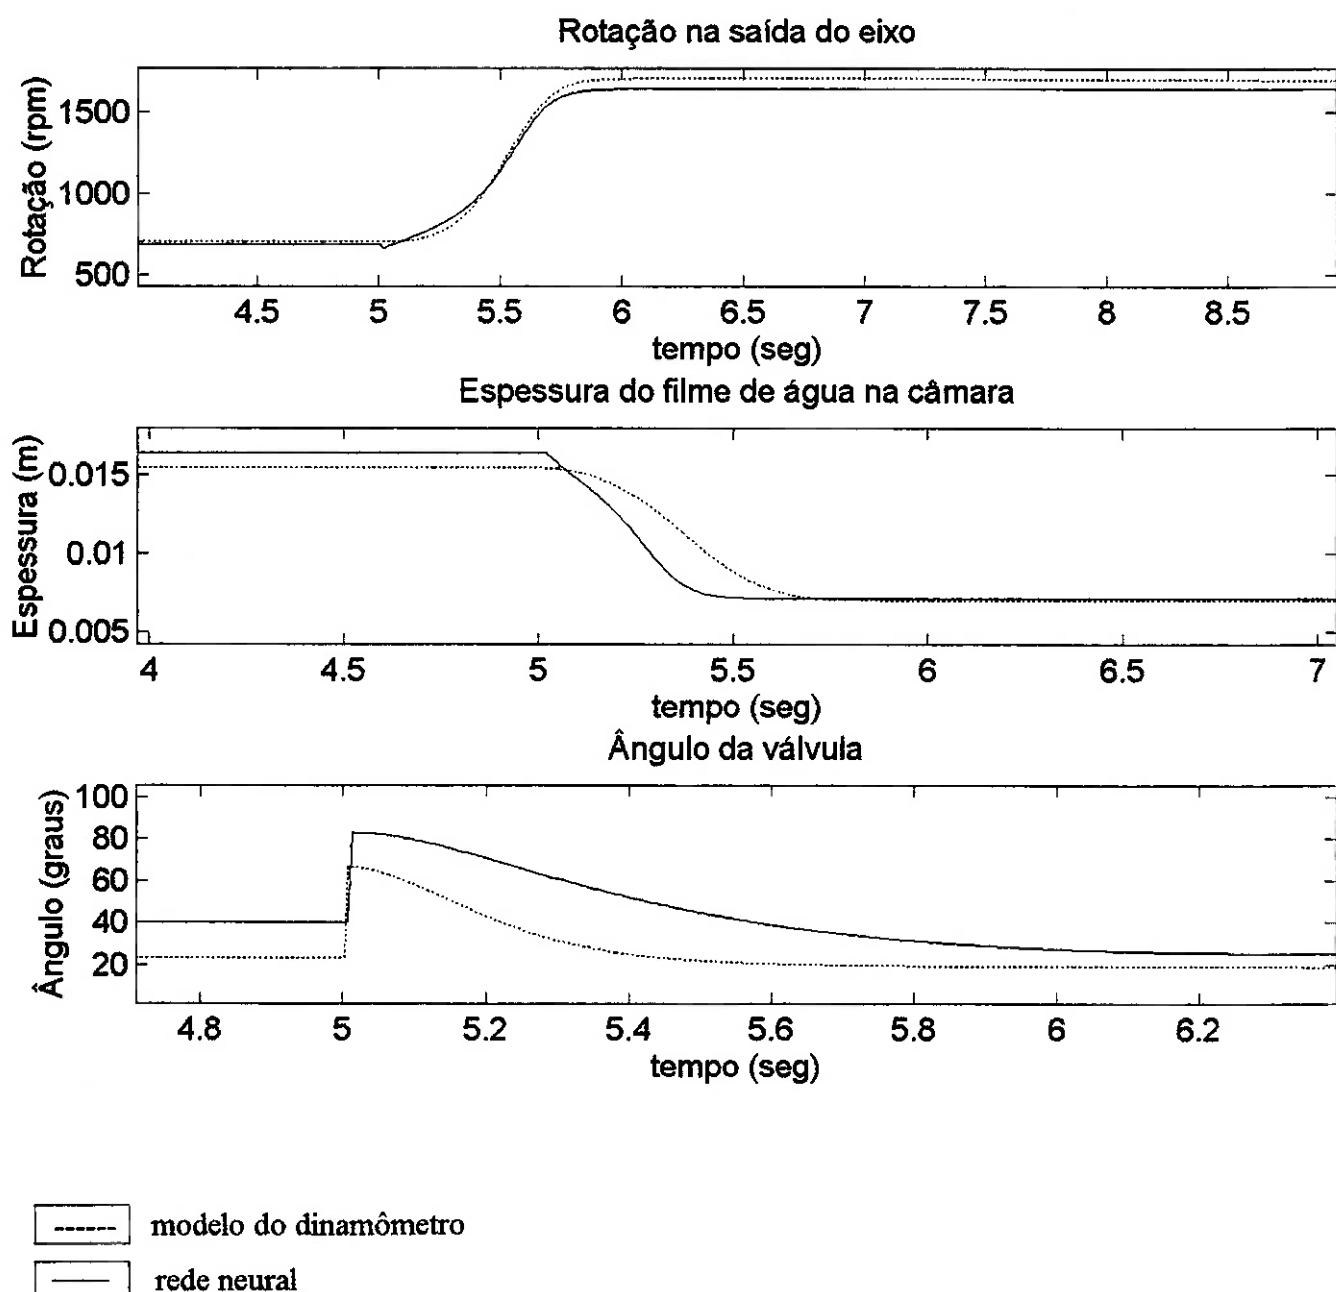


Gráfico 8) Entrada degrau de 700 rpm a 1650 rpm

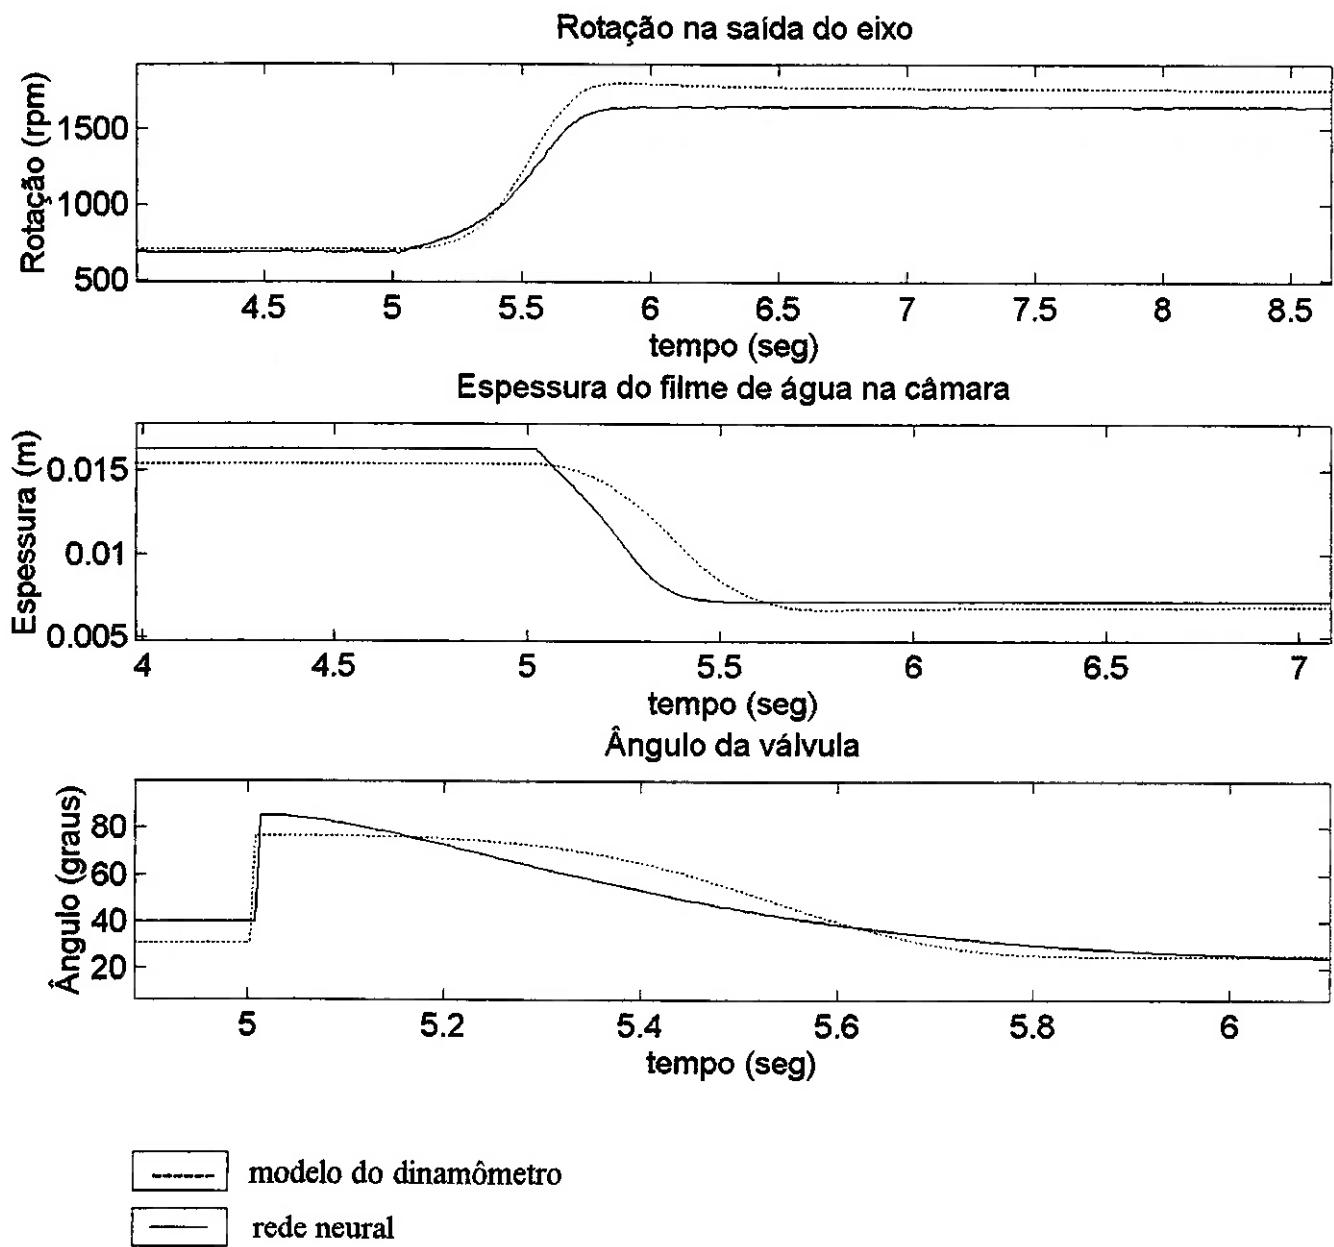


Gráfico 9) Entrada degrau de 700 rpm a 1700 rpm

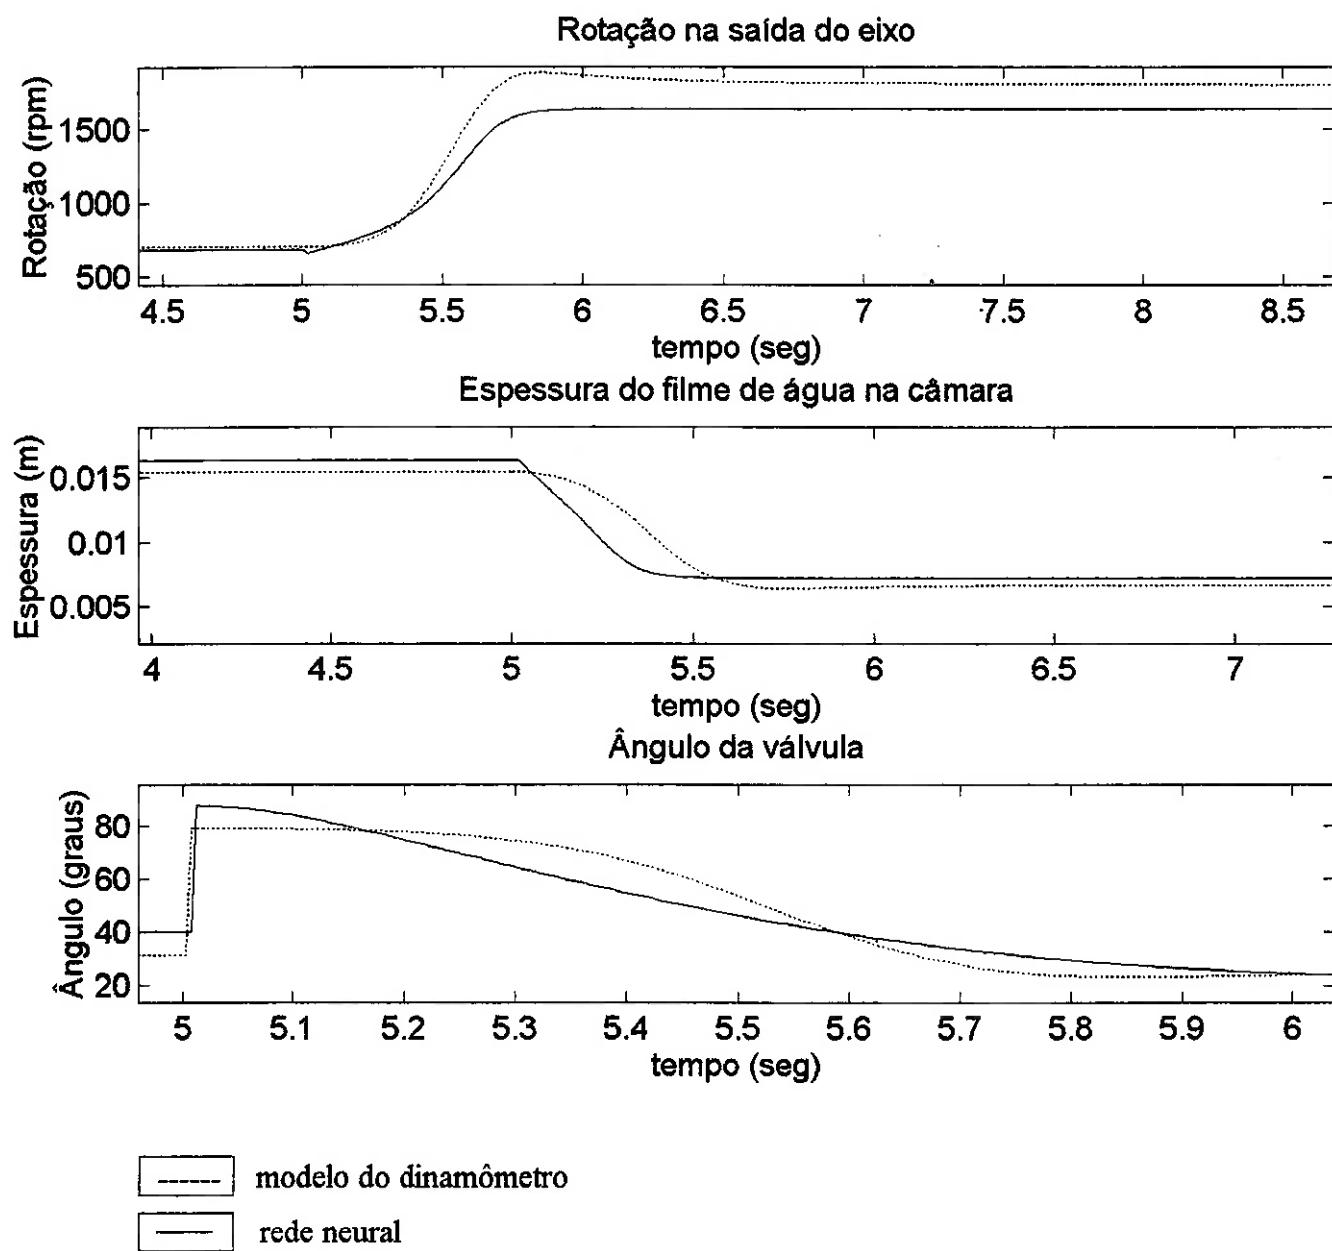
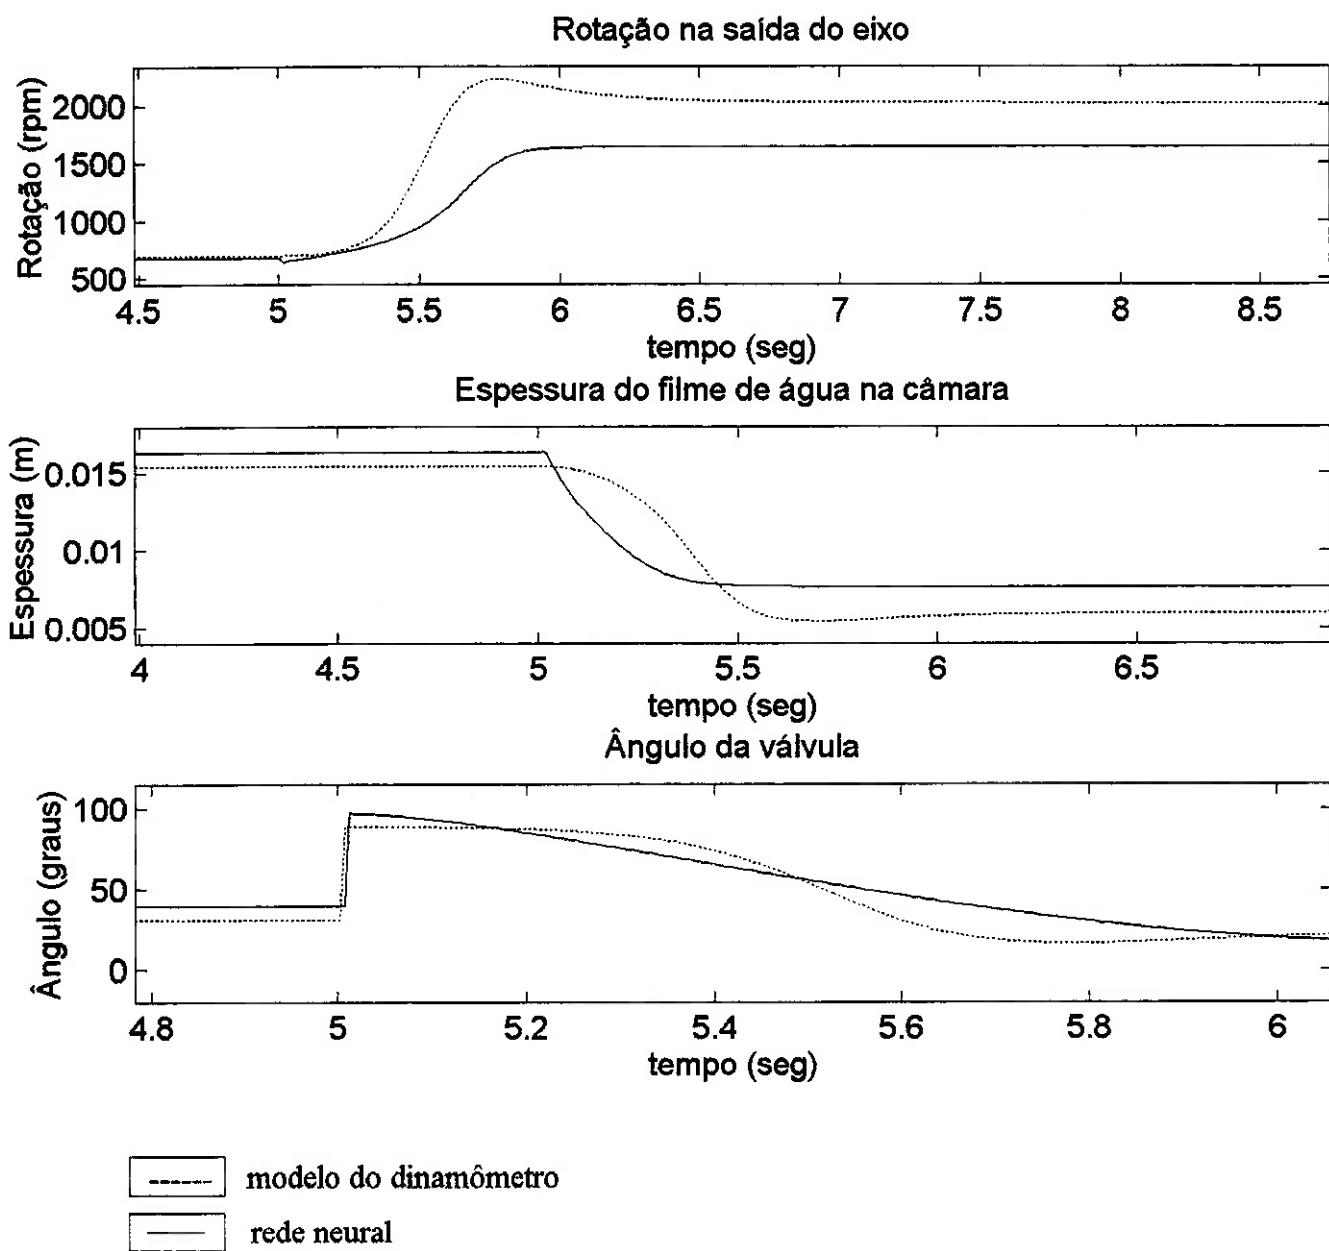


Gráfico 10) Entrada degrau de 700 rpm a 1900 rpm



CAPÍTULO 7 : CONTROLE ATRAVÉS DE REDES NEURAIS

Aqui serão tratadas propostas ou idéias para a realização do controle da relação estequiométrica (f_i). Notem que estas idéias não foram implementadas e são baseadas em literaturas existentes no mercado. Espera-se que o tópico em questão sirva de base para eventuais tentativas de controle por redes neurais partindo dos modelos aqui apresentados.

Comenta-se que a rede neural tem apresentado resultados bem satisfatórios no que se refere ao aprendizado de sistemas extremamente não-lineares e também para casos nos quais existem atrasos de tempo significantes devido aos sensores do sistema.

A tentativa de controle por redes neurais está baseada no fato de que pode-se obter o controle do valor estequiométrico em tempo real.

O objetivo do controle da relação ar-combustível é manter a relação dentro de um campo de variação de mais ou menos 1%; já que, para uma variação de 1% a eficiência do catalisador já decai aproximadamente 50%.

Será agora comentado um estudo feito nesta área.

Já existem vários testes com redes neurais; um deles, é o chamado CMAC(Cerebellar modelo articulation controller) que é usado como um controle adaptativo da relação ar-combustível. Este estudo possui as seguintes nuâncias.

Existem n entradas, para cada relação das entradas com os pesos fala-se que há uma localização C .

Podem os pesos se relacionarem com as mesmas entrada, produzindo uma correspondência C .

A resposta da saída é a soma dos pesos referentes às entradas ativadas, ou seja, as entradas existentes não se correspondem com todos os pesos. Só àqueles pesos que possuem correspondência com entradas são considerados.

A possibilidade de mesma entrada com mesmos pesos se multiplicarem várias vezes proporcionando uma saída similar é o que se chama de generalização local. Mesmo que o CMAC seja treinado sob condições específicas, a rede consegue aprender mais do que foi estipulado no treinamento.

O algoritmo de aprendizado envolvido com esta rede é

$$\Delta\omega = \beta_i(d-y)/C$$

onde β_i é a taxa de aprendizado que varia de -1 a 1

O ajustamento on-line permite modificar pesos a medida que o sistema é alterado.

A idéia de controle deste tipo de rede é que a rede recebe a mesma entrada do sistema. Para saídas diferentes o erro é corrigido. Todas os campos de hipóteses são cobertos, até o momento que a partir de uma entrada a rede sabe quanto que vai ter que fornecer na saída para não existir erro. Ou seja, a partir do momento que tenho pesos fixos a rede prevê o possível erro a partir da entrada.

Em suma, os modelos servem para estipular os diferentes erros para as diversas entradas. As entradas do controlador são as mesmas da rede, a saída do controlador é o valor necessário para corrigir o erro; sendo que o erro é a diferença entre a saída do modelo e a saída ideal.

Espera-se que após serem fornecidas ao controlador diversas entradas com as respectivas saídas, a rede neural referente ao controlador “aprenda” e para uma entrada diferente das usadas para treinamento o controlador seja capaz de prever o valor que deve ser fornecido para a planta corrigir o erro. Ou seja, a correção é feita on-line sem a necessidade de realimentação.

A realimentação só é necessária a nível de treinamento, ou seja, comparar saídas da planta e saídas ideais e só então, fazer a correção é importante apenas até a rede aprender o sistema. A partir daí a rede antevê o valor a ser corrigido para uma determinada entrada.

Nota-se que para a execução desta idéia, não é necessário utilizar o algoritmo de aprendizado citado acima. Convém inclusive utilizar uma algoritmo conhecido, podendo ser inclusive o back-propagation. A citação do algoritmo usado na CMAC foi apenas com o propósito de citar um tipo de pesquisa que está sendo realizado. Espera-se que resultados satisfatórios sejam obtidos com algoritmos de aprendizado mais usuais.

Na figura 24 há um exemplo de como pode ser implementado um controlador através de redes neurais com duas camadas para sistemas não-lineares.

Após ser realizado o treinamento da rede, são estipulados bias e pesos fixos, ou seja, os boxes referentes à tansig e purelin possuem bias(b_1 e b_2) e pesos(w_1 e w_2) fixos.

Essa rede já fornece na saída valores para corrigir os erros. A entrada do sistema não-linear já é um valor corrigido que fornecerá na saída do sistema “antena-model” o valor desejado.

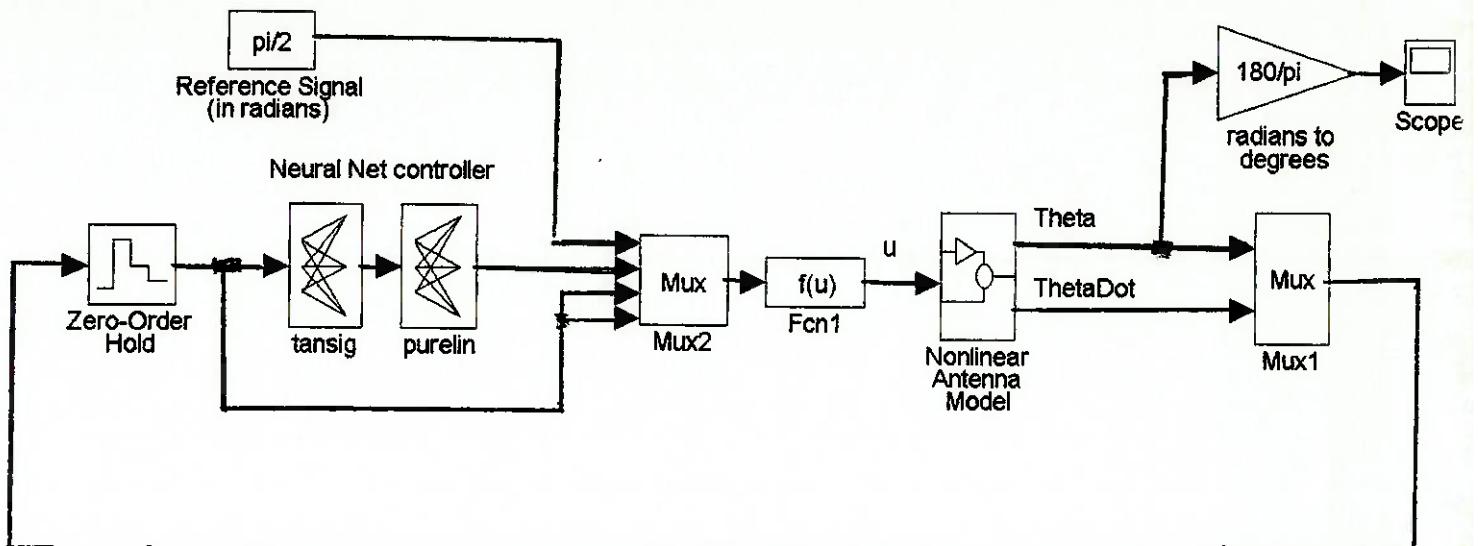


Figura 24 - Sistema controlado via redes neurais

A figura 25 mostra o gráfico da resposta do sistema controlada ao redor do valor de 90 graus.

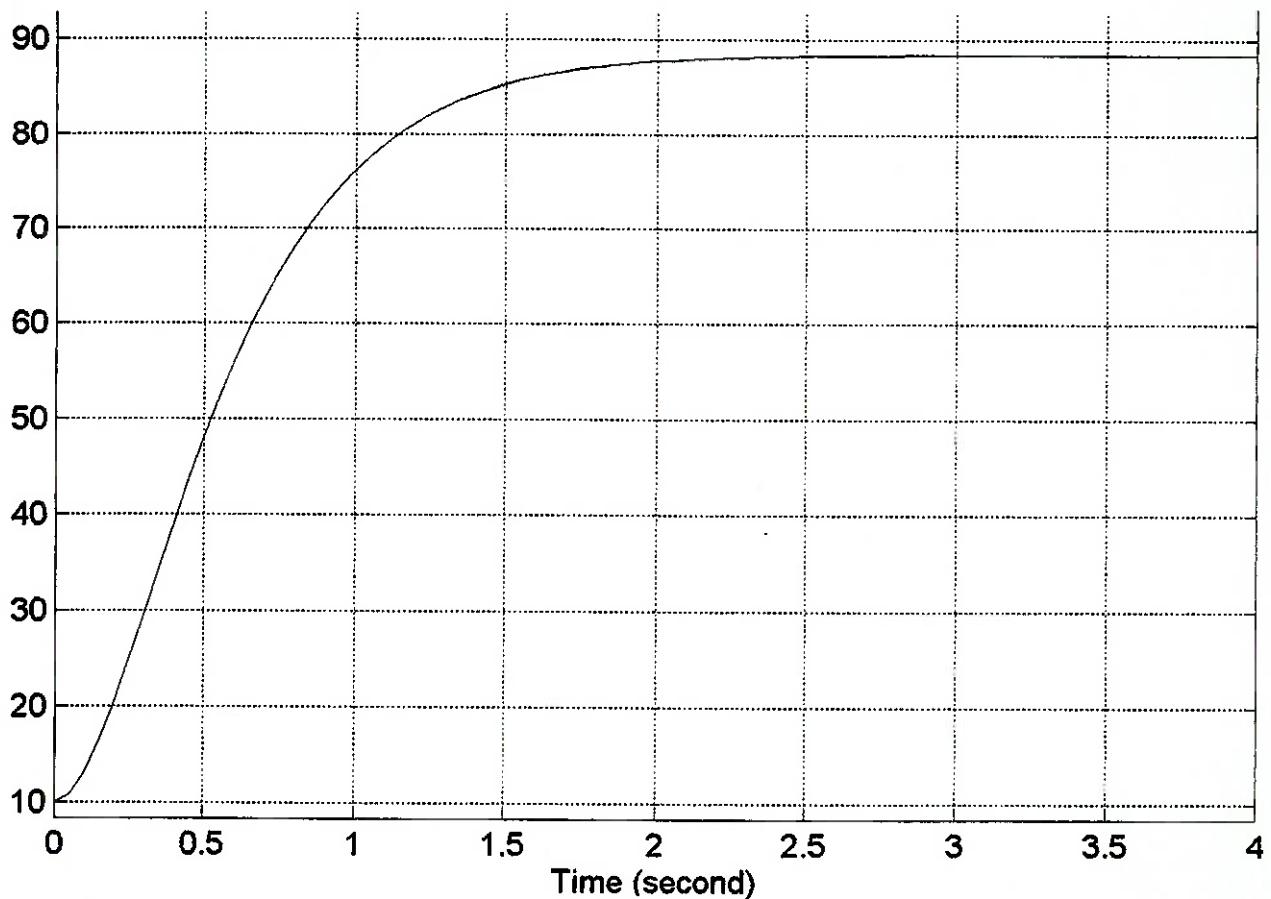


Figura 25 - Resposta controlada do sistema

Nota-se portanto que é perfeitamente possível implementar um controlador com as funções de transferências e algoritmos de aprendizado conhecidos fornecendo um resultado satisfatório.

CAPÍTULO 8 : CONCLUSÕES DO TRABALHO

1) Em tese as únicas informações necessárias para modelar um sistema via redes neurais são os valores de entrada e saída. No entanto, possuir o conhecimento físico do sistema é extremamente importante. Deve-se saber quais sinais de entrada fazem sentido para o estudo do sistema, e além disso qual o campo de variação destes sinais. Uma entrada mal dada pode induzir a rede a reconhecer aspectos que ela não deveria reconhecer e fornecer saídas diferentes das esperadas.

Conhecer bem a dinâmica de um sistema facilita muito o trabalho, por exemplo, se soubermos de antemão de quantos estados anteriores depende o estado atual o processo de modelamento será muito mais rápido e preciso.

Em suma, o sucesso da modelagem via redes neurais está intrinsecamente ligado a uma boa massa de dados para aprendizado, e uma boa massa de dados só é possível com o conhecimento físico do sistema.

2) Além do sucesso das redes dependerem muito de quais são as entradas dadas, há também a dependência de como são dadas as entradas. Treinou-se a rede do motor para um degrau sem ruído e o erro de aprendizado foi da ordem de 10^{-6} . Quando colocou-se como entrada um degrau um pouco diferente a rede não respondia bem. Treinou-se então a rede com uma entrada degrau com ruído. O erro subiu para 10^{-4} . Mas quando mudou-se o degrau a rede deu uma boa resposta.

Enfim, há um compromisso entre precisão e alcançabilidade, ou seja, dependendo do campo de variação das entradas que se deseja que uma rede neural reconheça, é necessário “abrir mão” da precisão das respostas e vice-versa.

3) Na primeira modelagem do motor considerou-se que ele dependia somente de duas entradas anteriores e três saídas anteriores, e o resultado foi que a resposta da rede era bem compatível com a resposta do modelo. Numa segunda e definitiva modelagem consideramos que ele dependia de quatro estados anteriores, além das três entradas anteriores, e os resultados foram ainda melhores.

No entanto, um aumento considerável do número de entradas e saídas anteriores faz com que o resultado piore.

Em suma, existe um valor ótimo do número de entradas e estados anteriores, de acordo com o sistema modelado. O conhecimento do sistema para antever esses

valores é bastante valioso, já que há uma economia do tempo que seria gasto caso fosse utilizado o método de tentativas e erros.

4) A percepção de que a rede neural é uma ferramenta muito poderosa na identificação de parâmetros e modelagem ficou bem clara. Talvez não seja ‘a solução’ para estes problemas, mas com certeza é uma alternativa a ser muito considerada, principalmente em sistemas altamente não-lineares cuja modelagem através de equações físicas torna-se extremamente trabalhosas.

5) Ainda há um grande campo de avanço com relação ao estudo de modelagem através de redes neurais com o propósito de controlar a injeção de combustível. O grande valor deste trabalho foi iniciar, abrir uma nova perspectiva de trabalho. É interessante fornecer uma alternativa para tanto comparar como também para recorrer caso outras modelagens não tenham dado certos, principalmente por se tratar de um sistema com características de não-linearidade elevadas que exigem hipóteses simplificadoras. Seria interessante a continuidade do mesmo, já que como foi citado durante o trabalho, a perspectiva de alcançar um resultado ótimo é muito grande.

6) O próximo passo é a realização do controle do sistema. Possuindo informações sobre as diferenças da relação ar-combustível desejada e obtida pode implementar uma rede neural para corrigir esta diferença. Uma idéia seria utilizar como entradas da rede os valores de entrada dos modelos ou do sistema e como saída a correção necessária para que a relação ar-combustível seja a desejada.

O uso dos modelos se faz necessário já que é difícil perceber e medir em laboratório as diferenças no transitório entre o valor estequiométrico da relação ar-combustível desejada e obtida.

7) Os resultados obtido com as redes neurais, principalmente, para o caso do motor foram muito satisfatórios, com erro aproximadamente zero para um amplo campo de variação da entrada degrau. Uma maior alcançabilidade ainda é possível aumentando o ruído de entrada para o qual a rede neural é treinada, ou então, utilizando modelos múltiplos nos quais cada modelo abrangeia um determinado campo de valores e formas de entrada.

- 8) Um outro passo interessante, seria a utilização de uma rede neural nos moldes da implementada neste trabalho, com o objetivo de modelar o conjunto motor-dinamômetro. Hoje, já existe no IPT um modelo fenomenológico construído através de equações físicas para este conjunto. Na verdade, os modelos do dinamômetro e motor aqui utilizados foram agrupados num só modelo com resultados bem satisfatórios. Poderia-se construir uma rede neural que utilize a massa de dados de entrada e saída deste conjunto, tal iniciativa serviria para se obter uma alternativa de modelagem além da realizada por equações físicas, já que como fora comentado durante o trabalho, apresenta hipóteses bem simplificadoras, devido a alta não linearidade do sistema.
- 9) Pode-se buscar melhorar ainda mais os resultados do motor e principalmente do dinamômetro, procurando um ruído de entrada que atenda ao compromisso alcançabilidade/precisão desejado. Pode-se também mudar a realimentação (número de entradas e saídas anteriores informadas no aprendizado) e estrutura da rede(mais camadas, mais neurônios em cada camada, funções de transferência, coeficiente de aprendizado, pesos e bias iniciais, etc).
- 10) Espera-se que este trabalho contribua no desenvolvimento de um projeto maior que é o estudo da utilização do gás natural como alternativa de combustível menos poluente, além disso espera-se que este sirva como material de auxílio para futuros trabalhos tanto na área de modelagem e controle de sistema não lineares.

ANEXOS

ANEXO A) IMPLEMENTAÇÃO DO PROGRAMA TESTE EM PASCAL

```
var
a,b,c,d,e,t : array[1..100] of real ;
i,j : integer ;
delta , alfa,saida,threshold,dthreshold,dwa,dwb,dwc,dwd,dwe,wa,wb,wc,wd,we : real ;
begin
a[1]:= -0.7343 ;
a[2]:= -0.7944 ;
a[3]:= -0.8276 ;
a[4]:= -0.8454 ;
a[5]:= -0.8538 ;
a[6]:= -0.8562 ;
a[7]:= -0.8542 ;
a[8]:= -0.8489 ;
a[9]:= -0.8410 ;
a[10]:= -0.8309 ;
a[11]:= -0.8191 ;
a[12]:= -0.8060 ;
a[13]:= -0.7920 ;
a[14]:= -0.7774 ;
a[15]:= -0.7625;
a[16]:= -0.7476;
a[17]:= -0.7329;
a[18]:= -0.7186;
a[19]:= -0.7049;
a[20]:= -0.6918;
a[21]:= -0.6795;
a[22]:= -0.6681;
a[23]:= -0.6575;
a[24]:= -0.6477;
a[25]:= -0.6388;
a[26]:= -0.6308;
a[27]:= -0.6235;
a[28]:= -0.6169;
a[29]:= -0.6111;
a[30]:= -0.6059;
a[31]:= -0.6013;
a[32]:= -0.5972;
```

```
a[33] := -0.5936;
a[34] := -0.5904;
a[35] := -0.5876;
a[36] := -0.5852;
a[37] := -0.5831;
a[38] := -0.5812;
a[39] := -0.5796;
a[40] := -0.5782;
a[41] := -0.5770;
b[1] := -0.6185;
b[2] := -0.4766;
b[3] := -0.3610;
b[4] := -0.2804;
b[5] := -0.2326;
b[6] := -0.2117;
b[7] := -0.2117;
b[8] := -0.2273;
b[9] := -0.2540;
b[10] := -0.2879;
b[11] := -0.3258;
b[12] := -0.3652;
b[13] := -0.4041;
b[14] := -0.4413;
b[15] := -0.4760;
b[16] := -0.5077;
b[17] := -0.5364;
b[18] := -0.5621;
b[19] := -0.5850;
b[20] := -0.6052;
b[21] := -0.6229;
b[22] := -0.6385;
b[23] := -0.6522;
b[24] := -0.6641;
b[25] := -0.6745;
b[26] := -0.6835;
b[27] := -0.6914;
b[28] := -0.6983;
b[29] := -0.7042;
b[30] := -0.7094;
```

```
b[31] := -0.7138;
b[32] := -0.7177;
b[33] := -0.7211;
b[34] := -0.7240;
b[35] := -0.7265;
b[36] := -0.7287;
b[37] := -0.7306;
b[38] := -0.7322;
b[39] := -0.7337;
b[40] := -0.7349;
b[41] := -0.7359;
c[1] := 0.3375;
c[2] := 0.3176;
c[3] := 0.2783;
c[4] := 0.2246;
c[5] := 0.1606;
c[6] := 0.0899;
c[7] := 0.0160;
c[8] := -0.0582;
c[9] := -0.1302;
c[10] := -0.1982;
c[11] := -0.2608;
c[12] := -0.3176;
c[13] := -0.3683;
c[14] := -0.4131;
c[15] := -0.4524;
c[16] := -0.4866;
c[17] := -0.5164;
c[18] := -0.5422;
c[19] := -0.5644;
c[20] := -0.5837;
c[21] := -0.6003;
c[22] := -0.6146;
c[23] := -0.6270;
c[24] := -0.6376;
c[25] := -0.6468;
c[26] := -0.6548;
c[27] := -0.6616;
c[28] := -0.6675;
```

```
c[29] := -0.6726;
c[30] := -0.6770;
c[31] := -0.6808;
c[32] := -0.6841;
c[33] := -0.6869;
c[34] := -0.6894;
c[35] := -0.6915;
c[36] := -0.6933;
c[37] := -0.6949;
c[38] := -0.6963;
c[39] := -0.6974;
c[40] := -0.6984;
c[41] := -0.6993;
d[1] := 0.5314;
d[2] := 0.6617;
d[3] := 0.7367;
d[4] := 0.7799;
d[5] := 0.8047;
d[6] := 0.8183;
d[7] := 0.8244;
d[8] := 0.8254;
d[9] := 0.8225;
d[10] := 0.8167;
d[11] := 0.8086;
d[12] := 0.7988;
d[13] := 0.7878;
d[14] := 0.7760;
d[15] := 0.7636;
d[16] := 0.7511;
d[17] := 0.7385;
d[18] := 0.7262;
d[19] := 0.7142;
d[20] := 0.7028;
d[21] := 0.6919;
d[22] := 0.6817;
d[23] := 0.6721;
d[24] := 0.6633 ;
d[25] := 0.6553;
d[26] := 0.6479;
```

```
d[27] := 0.6412;
d[28] := 0.6352;
d[29] := 0.6298;
d[30] := 0.6250 ;
d[31] := 0.6207;
d[32] := 0.6169;
d[33] := 0.6136;
d[34] := 0.6106;
d[35] := 0.6080;
d[36] := 0.6057;
d[37] := 0.6037;
d[38] := 0.6019;
d[39] := 0.6004;
d[40] := 0.5991;
d[41] := 0.5979;
e[1] := -0.5424 ;
e[2] := -0.3841;
e[3] := -0.2539;
e[4] := -0.1594;
e[5] := -0.0974;
e[6] := -0.0619;
e[7] := -0.0471;
e[8] := -0.0482;
e[9] := -0.0612;
e[10] := -0.0828;
e[11] := -0.1100;
e[12] := -0.1406;
e[13] := -0.1728;
e[14] := -0.2051;
e[15] := -0.2365;
e[16] := -0.2664;
e[17] := -0.2945;
e[18] := -0.3204;
e[19] := -0.3441;
e[20] := -0.3657;
e[21] := -0.3851;
e[22] := -0.4026;
e[23] := -0.4181;
e[24] := -0.4320;
```

```
e[25] := -0.4442;
e[26] := -0.4551;
e[27] := -0.4646;
e[28] := -0.4730;
e[29] := -0.4803;
e[30] := -0.4868;
e[31] := -0.4924;
e[32] := -0.4973;
e[33] := -0.5016;
e[34] := -0.5054;
e[35] := -0.5086;
e[36] := -0.5114;
e[37] := -0.5139;
e[38] := -0.5160;
e[39] := -0.5179;
e[40] := -0.5195;
e[41] := -0.5209;
t[1] := 0.0811;
t[2] := 0.6337;
t[3] := 1.0462;
t[4] := 1.3404;
t[5] := 1.5412;
t[6] := 1.6703;
t[7] := 1.7440;
t[8] := 1.7741;
t[9] := 1.7701;
t[10] := 1.7399;
t[11] := 1.6904;
t[12] := 1.6277;
t[13] := 1.5565;
t[14] := 1.4810;
t[15] := 1.4040;
t[16] := 1.3277;
t[17] := 1.2537;
t[18] := 1.1830;
t[19] := 1.1162;
t[20] := 1.0539;
t[21] := 0.9962;
t[22] := 0.9432;
```

```

t[23] := 0.8948;
t[24] := 0.8509;
t[25] := 0.8112;
t[26] := 0.7756;
t[27] := 0.7437;
t[28] := 0.7153;
t[29] := 0.6900;
t[30] := 0.6677;
t[31] := 0.6480;
t[32] := 0.6306;
t[33] := 0.6153;
t[34] := 0.6019;
t[35] := 0.5902;
t[36] := 0.5800;
t[37] := 0.5710;
t[38] := 0.5632;
t[39] := 0.5564;
t[40] := 0.5505;
t[41] := 0.5454;

```

{* CONDICOES INICIAS *}

```

wa := -2.8 ;
wb := 1.26 ;
wc := -0.71 ;
wd := 1.15 ;
we := -0.315 ;
alfa := 0.15 ;
threshold := -0.5 ;

```

saida := 0 ;

{* ITERACOES *}

for j := 1 to 15000

do begin

for i := 1 to 41

do begin

saida := a[i]*wa + b[i]*wb + c[i]*wc + d[i]*wd + e[i]*we -threshold ;

delta := t[i] - saida ;

if j = 14999 then begin

```

        writeln (saida) ; writeln (t[i]) ; writeln (delta) ; writeln ; readln ;
    end ;

dwa := alfa*a[i] * ( t[i] - saida ) ;
dwb := alfa*b[i] * ( t[i] - saida ) ;
dwc := alfa*c[i] * ( t[i] - saida ) ;
dwd := alfa*d[i] * ( t[i] - saida ) ;
dwe := alfa*e[i] * ( t[i] - saida ) ;
dthreshold := -alfa*( t[i]- saida ) ;
wa := wa + dwa ;
wb := wb + dwb ;
wc := wc + dwc ;
wd := wd + dwd ;
we := we + dwe ;
threshold := threshold + dthreshold ;
end ;

writeln (wa) ; writeln(wb) ; writeln(wc) ; writeln(wd) ; writeln(we) ; writeln(delta) ;
readln ;
end

```

ANEXO B) IMPLEMENTAÇÃO NO MATLAB DOS PROGRAMAS DE TREINAMENTO E SIMULAÇÃO DAS REDES DO MOTOR E DO DINAMÔMETRO

REDE NEURAL DO MOTOR

* TREINAMENTO DA REDE *

```
entrada1 = acel ;      * variação no ângulo da borboleta *
entrada2 = comba ;     * vazão de combustível          *
target1 = pressao ;    * pressão no coletor           *
target2 = n ;           * rotação do eixo            *
entrada=[entrada1 entrada2];
target=[target1 target2];
u=[entrada]';           * transposto da entrada      *
t=[target]';            * transposto do target (saída ) *
p1=delaysig(u,0,3);   * p1 é uma matriz que contém a entrada atual e três anteriores *
p2=delaysig(t,1,4);   * p2 é uma matriz que contém 3 saídas anteriores        *
p=[p1;p2] ;
[w1,b1,w2,b2]=initff(p,8,'tansig',t,'purelin');
tp=[25 100 0.0001 0.01];
[w1,b1,w2,b2,te,tr]=trainlm(w1,b1,'tansig',w2,b2,'purelin',p,t,tp) ;
```

* SIMULAÇÃO DA REDE *

```
pp1=p1(:,1);
estados=zeros(2,2000);
for i=4:2000,
if i=4,
    estado=simuff([pp1;[0;0;0;0;0;0;0]],w1,b1,'tansig',w2,b2,'purelin') ;
else
    * este bloco faz a realimentação da saída *
    estado=simuff([pp1;[estados(:,i-1);estados(:,i-2);estados(:,i-3);
                    estados(:,i-4)]],w1,b1,'tansig',w2,b2,'purelin') ;
end;
```

```

estados(:,i)=estado;
clear pp1 ;
pp1=p1(:,i);
end;

```

REDES NEURAIS DO DINÂMETRO

REDE 1 (ROTACÃO)

* INICIALIZAÇÃO (Coloca os valores de entrada e saída na mesma escala: 10^{-1})*

```

entrada1=wref;
entrada1=entrada1(1000:3000);
target1=w/1000;
target1=target1(1000:3000);

```

* TREINAMENTO DA REDE *

```

entrada=[entrada1];
target=[target1];
u=[entrada]';
t=[target]';
p1=delaysig(u,0,4);
p2=delaysig(t,1,4);
p=[p1;p2];
[w1,b1,w2,b2]=initff(p,6,'tansig',t,'purelin');
tp=[10 50 0.00001 0.01];
[w1,b1,w2,b2,te,tr]=trainlm(w1,b1,'tansig',w2,b2,'purelin',p,t,tp);

```

* SIMULAÇÃO DA REDE *

```

pp1=p1(:,1);
states=zeros(1,2000);
for i=4:2000,
    if i==4,
        state=simuff([pp1;[0;0;0;0]],w1,b1,'tansig',w2,b2,'purelin') ;
    else

```

```

state=simuff([pp1;[states(:,i-1);states(:,i-2);states(:,i-3);states(:,i-4)]],w1,b1,
            'tansig',w2,b2,'purelin') ;

end;
states(:,i)=state;
clear pp1;
pp1=p1(:,i);
end;

```

REDE 2 (ESPESSURA DO FILME DE ÁGUA NA CÂMARA)

* INICIALIZAÇÃO (Coloca os valores de entrada e saída na mesma escala: 10^{-1})*

```

entrada1=wref;
entrada1=entrada1(1000:3000);
target2=dR*10;
target2=target2(1000:3000);

```

* TREINAMENTO DA REDE *

```

entrada=[entrada1];
target=[target2];
u=[entrada];
t=[target];
p1=delaysig(u,0,3);
p2=delaysig(t,1,5);
p=[p1;p2] ;
[w1,b1,w2,b2]=initff(p,5,'tansig',t,'purelin');
tp=[10 50 0.00001 0.01] ;
[w1,b1,w2,b2,te,tr]=trainlm(w1,b1,'tansig',w2,b2,'purelin',p,t,tp) ;

```

* SIMULAÇÃO DA REDE *

```

pp1=p1(:,1);
states=zeros(1,2000);
for i=5:2000,
if i==5,
state=simuff([pp1;[0;0;0;0;0]],w1,b1,'tansig',w2,b2,'purelin') ;

```

```

else
state=simuff([pp1;[states(:,i-1);states(:,i-2);states(:,i-3);states(:,i-4);states(:,i-5)]],w1,b1,
             'tansig',w2,b2,'purelin') ;

end;
states(:,i)=state;
clear pp1;
pp1=p1(:,i);
end;

```

REDE 3 (ÂNGULO DA VÁLVULA)

* INICIALIZAÇÃO (Coloca os valores de entrada e saída na mesma escala: 10^{-1})*

```

entrada1=wref;
entrada1=entrada1(1000:3000);
target3=alfa*0.1;
target3=target3(1000:3000);

```

* TREINAMENTO DA REDE *

```

entrada=[entrada1];
target=[target3];
u=[entrada]';
t=[target]';
p1=delaysig(u,0,3);
p2=delaysig(t,1,5);
p=[p1;p2];
[w1,b1,w2,b2]=initff(p,5,'tansig',t,'purelin');
tp=[10 50 0.00001 0.01];
[w1,b1,w2,b2,te,tr]=trainlm(w1,b1,'tansig',w2,b2,'purelin',p,t,tp);

```

* SIMULAÇÃO DA REDE *

```

pp1=p1(:,1);
states=zeros(1,2000);
for i=5:2000,
    if i==5,

```

```
state=simuff([pp1;[0;0;0;0;0]],w1,b1,'tansig',w2,b2,'purelin') ;
else
state=simuff([pp1;[states(:,i-1);states(:,i-2);states(:,i-3);states(:,i-4);states(:,i-5)]],w1,b1,
'tansig',w2,b2,'purelin') ;
end;
states(:,i)=state;
clear pp1;
pp1=p1(:,i);
end;
```

ANEXO C) EXPLICAÇÕES A RESPEITO DAS FUNÇÕES PRÉ-DEFINIDAS UTILIZADAS NOS PROGRAMAS

. **delaysig (x,a,b)** : dado um vetor x esta função cria uma matriz onde cada linha representa um instante no tempo. Por exemplo se a=0 e b=2, a função vai criar uma matriz onde a primeira linha é uma réplica do vetor x significando o instante atual, e as outras duas linhas são formadas atrasando o vetor x 1 instante e 2 instantes no tempo. É esta função que permite atrasar no tempo as entradas e as saídas de maneira a proporcionar o aprendizado da rede.

. **[w1 b1 w2 b2]=initiff(entrada,n,f1,target,f2)** : a função initiff faz o setup para uma rede com duas camadas, determinando a quantidade de pesos e bias da primeira e segunda camadas em função dos vetores de entrada e target, inicializando os pesos e bias (w1 b1 w2 b2) aleatoriamente mas dentro de um certo campo de variação, criando funções de transferência f1 e f2 para a primeira e segunda camadas respectivamente, e gerando n neurônios na primeira camada.

. **tp=[a b c d]** : Este vetor entra como parâmetro para o algoritmo de aprendizado

a é o intervalo em que se deve mostrar a queda do erro quadrático ;

b é o número máximo de iterações ;

c é o limite de erro quadrático que se deseja atingir;

d é o coeficiente de aprendizado

. **trainlm** : esta função faz o treinamento de uma rede através do algoritmo de Levenberg-Marquardt.

. **simuff(p,w1,b1,f1,w2,b2,f2)** : esta função simula uma rede neural de duas camadas onde : a primeira camada possui uma matriz de pesos igual a w1, um vetor de bias igual a b1 e função de transferência igual a f1;

 a segunda camada possui matriz de pesos w2, vetor de bias b2 e função de transferência f2;

 a simulação é feita para um vetor de entrada igual a p. Se y = simuff então y contém o vetor de respostas desta rede para uma entrada igual a p.

BIBLIOGRAFIA

- DEMUTH, H. ; BEALE, M. Neural Network Toolbox User's Guide. The Mathworks Inc. USA, 1994.
- FLEURY, A.T. ; LOPES, J.A. Considerações Sobre as Abordagens de Controle ao Problema da Redução de Emissões em Motores de Combustão Interna a Gás Natural. Congresso Brasileiro de Automática, Rio de Janeiro, 1994.
- GURNEY, K. Computers and Symbols versus Nets and Neurons. Dept. Human Sciences. Brunel University, 1986.
- HOPFIELD, J.L. Learning Algorithms and Probability Distributions in Feed-Forward and Feed-Back Networks. USA, 1987.
- LOPES, J.A. Um Controlador Preditivo Generalizado (GPC) Aplicado ao Problema de Controle da Relação Ar-Combustível em Motores Ciclo Otto Operando com Gás Natural, com Vistas em Redução de Emissões. Tese de Mestrado Apresentada à Escola Politécnica da USP, 1996.
- MAJORS, M. ; STORI, J. ; CHO, D. Neural Network Control of Automotive Fuel-Injection Systems. IEEE Transactions on Control Systems Technology, 1994.
- MOSCATI, N.R. ; TRIELLI, M.A. ; FLEURY A.T. ; NIGRO F.E.B. ; LOPES, J.A. Modelagem e Simulação de um Freio Dinamômetro Hidráulico. IPT (Instituto de Pesquisas Tecnológicas), São Paulo, 1995.
- MOSCATI, N.R. ; TRIELLI, M.A. ; FLEURY A.T. ; NIGRO F.E.B. ; LOPES, J.A. Modelagem e Simulação de um Motor de Combustão Interna Movido a Gás Natural Acoplado a um Dinamômetro Hidráulico. IPT (Instituto de Pesquisas Tecnológicas), São Paulo, 1996.
- NARENDRA, K. ; PARTHASARATHY, K. Identification and Control of Dynamical Systems Using Neural Networks. IEEE Transactions on Control Systems Technology, 1990.
- RUMELHART, D.E. ; HINTON G.E. Learning Representations by Back-Propagation errors. 1986.
- SCHENK 1 Hydraulic Dynamometer DYNABAR^C. Publication I3051/7 (in portuguese), Schenk do Brasil, Ind. Com. Ltda.
- SHIRAIISHI, H. ; IPRI, S. ; CHO, D. CMAC Neural Network Controller for Fuel-Injection Systems. IEEE Transactions on Control Systems Technology, 1995.
- SOUSZEK, B. Neural Network and Concurrent Time Systems. Prague University, 1989