

**ANÁLISE DO TEMPO DE DURAÇÃO DE PROCESSOS
TRABALHISTAS UTILIZANDO REDES NEURAIS ARTIFICIAIS
COMO APOIO À TOMADA DE DECISÕES**

GENIVAL PAVANELLI

**ANÁLISE DO TEMPO DE DURAÇÃO DE PROCESSOS TRABALHISTAS
UTILIZANDO REDES NEURAS ARTIFICIAIS COMO APOIO À TOMADA
DE DECISÕES**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Ciências, do Programa de Pós-Graduação em Métodos Numéricos em Engenharia, na Área de Concentração em Programação Matemática, dos setores de Ciências Exatas e de Tecnologia da Universidade Federal do Paraná.

Orientadora: Profa. Dra. Maria Teresinha
Arns Steiner

Co-orientadora: Profa. Dra. Deise Maria
Bertholdi Costa

CURITIBA
2007

TERMO DE APROVAÇÃO

GENIVAL PAVANELLI

ANÁLISE DO TEMPO DE DURAÇÃO DE PROCESSOS TRABALHISTAS UTILIZANDO REDES NEURAS ARTIFICIAIS COMO APOIO À TOMADA DE DECISÕES

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre em Ciências, do Programa de Pós-Graduação em Métodos Numéricos em Engenharia, na Área de Concentração em Programação Matemática, dos setores de Ciências Exatas e Tecnologia da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientadora:

Profa. Dra. Maria Teresinha Arns Steiner
Departamento de Matemática, UFPR

Co-orientadora:

Profa. Dra. Deise Maria Bertholdi Costa
Departamento de Desenho, UFPR

Prof. Dr. Heitor Silvério Lopes, D.Eng.
Programa de Pós-Graduação em Eng. Elétr. e Inf. Ind., UTFPR

Prof. Dr. Marco Cesar Goldberg, D.Eng.
Programa de Pós-Graduação em Informática, UFRN

Curitiba, 11 de junho de 2007

A minha esposa Alessandra
e a meus filhos Giovana e Alberto
Dedico

AGRADECIMENTOS

À minha esposa Alessandra, amor eterno, cúmplice há muitos anos, junto dela encontro alegria e força para trilhar todos os caminhos da minha vida.

À minha filha, Giovana e ao meu filho Alberto, a essência da magia que é a razão da minha energia, persistência e luta.

Aos meus pais Sr. Benedito e Sra. Domingas, pessoas que sempre foram exemplos de coragem, amor, retidão e perseverança.

Aos meus irmãos José e Mario, pessoas que representam, para mim, a união nos momentos importantes.

A minha sogra Sra. Angelina, pessoa importante, que na sua simplicidade sempre apoiou meus projetos.

Aos meus cunhados, cunhadas, sobrinhos e sobrinhas, pessoas importantes no conjunto que cerca minha vida.

A Profa. Dra. Maria Teresinha Arns Steiner, uma professora no sentido profundo da palavra, que com sua sabedoria na condução de minha orientação levou-me por caminhos que me trouxeram cada vez mais experiência e amadurecimento.

A co-orientadora, Profa. Dra. Deise Maria Bertholdi Costa, uma pessoa de visão, entusiasta, cujas orientações foram de grande valia no desenvolvimento da minha dissertação.

A todos os professores do curso, pelos ensinamentos.

Ao MM. Juiz do Trabalho, Dr. Bráulio Gabriel Gusmão, Juiz da 1ª Vara do Trabalho de São José dos Pinhais – Paraná, incansável na busca da excelência em seu trabalho, pelas suas colaborações.

Aos funcionários da 1ª Vara do Trabalho de São José dos Pinhais - Paraná, que sempre responderam prontamente minhas solicitações.

A todos os amigos do PPGMNE, em especial a Rodrigo, Cassius e Fernando, pela amizade, companheirismo e apoio em todos os momentos.

À Maristela Bandil pela amizade, dedicação e apoio.

À todos meus chefes do Colégio Militar de Curitiba, que apoiaram o meu trabalho, e entendendo minha ausência tornaram possível esta realização.

À Profa. e amiga Maria Terezinha Knabben, pela pronta resposta diante de minhas solicitações.

À todos aqueles que, de uma forma ou de outra, colaboraram para realização deste trabalho.

E, principalmente agradeço a Deus, fonte de luz e sabedoria, pelo amparo nesta jornada e em todos os momentos da minha vida.

SUMÁRIO

LISTA DE FIGURAS	viii
LISTA DE QUADROS	ix
LISTA DE TABELAS	x
RESUMO	xii
ABSTRACT	xiii
CAPÍTULO I	
1 INTRODUÇÃO	1
1.1 OBJETIVOS DO TRABALHO.....	2
1.2 REVISÃO DA LITERATURA – TRABALHOS RELACIONADOS.....	3
1.3 ESTRUTURA DO TRABALHO.....	5
CAPÍTULO II	
2 DESCRIÇÃO DO PROBLEMA	7
2.1 INTRODUÇÃO.....	7
2.2 ESTUDO DE UM CASO.....	15
2.2.1 Obtenção dos Dados.....	15
2.2.2 Tratamento dos Dados.....	16
CAPÍTULO III	
3 REFERENCIAL TEÓRICO	21
3.1 REDES NEURAIS ARTIFICIAIS.....	21
3.1.1 Histórico.....	21
3.1.2 O Neurônio Artificial.....	24
3.1.3 Função de Ativação de uma Rede Neural Artificial.....	27
3.1.4 Arquitetura de uma Rede Neural Artificial.....	28
3.1.5 Treinamento de uma Rede Neural Artificial.....	30
3.1.6 Redes de Múltiplas Camadas ou Redes <i>Feed-forward</i>	31
3.2 ANÁLISE DE COMPONENTES PRINCIPAIS.....	36
3.2.1 Introdução.....	36
3.2.2 Componentes Principais Populacionais.....	37

3.2.3 Componentes Principais Amostras.....	38
3.2.4 Número de Componentes que deve ser Retido.....	39

CAPÍTULO IV

4 IMPLEMENTAÇÃO DAS TÉCNICAS PARA RESOLUÇÃO DO PROBLEMA E ANÁLISE DOS RESULTADOS.....	41
4.1 IMPLEMENTAÇÃO DAS TÉCNICAS PARA RESOLUÇÃO DO PROBLEMA.....	41
4.1.1 Teste I.....	45
4.1.2 Teste II.....	49
4.1.3 Teste III.....	56
4.2 ANÁLISE DOS RESULTADOS.....	64

CAPÍTULO V

5 CONCLUSÕES E SUGESTÕES PARA FUTUROS TRABALHOS.....	67
5.1 CONCLUSÕES.....	67
5.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	69

REFERÊNCIAS.....	70
-------------------------	-----------

APÊNDICES.....	74
-----------------------	-----------

LISTA DE FIGURAS

FIGURA 2.1.	FASES DO PROCESSO DE CONHECIMENTO E EXECUÇÃO.....	8
FIGURA 2.2.	FASE DA AUTUAÇÃO E CADASTRO.....	9
FIGURA 2.3.	FASE DA CITAÇÃO E NOTIFICAÇÃO.....	10
FIGURA 2.4.	FASE DO CONTRADITÓRIO.....	11
FIGURA 2.5.	FASE DO JULGAMENTO.....	12
FIGURA 2.6.	FASE DOS RECURSOS.....	13
FIGURA 2.7.	FASE DA EXECUÇÃO.....	14
FIGURA 3.1.	NEURÔNIO FORMAL.....	22
FIGURA 3.2.	REDE DE PERCEPTONS.....	22
FIGURA 3.3.	REDE ADALINE E MADALINE.....	23
FIGURA 3.4.	ESTRUTURA DO MÉTODO <i>BACK-PROPAGATION</i>	24
FIGURA 3.5.	NEURÔNIO BIOLÓGICO.....	25
FIGURA 3.6.	MODELO DE UM NEURÔNIO ARTIFICIAL.....	25
FIGURA 3.7.	DIAGRAMA DE FUNCIONAMENTO DE UM NEURÔNIO ARTIFICIAL.....	26
FIGURA 3.8.	FUNÇÕES DE ATIVAÇÃO DE UMA RNA.....	27
FIGURA 3.9.	MODELO DE REDE NEURAL COM UMA CAMADA.....	28
FIGURA 3.10.	MODELO DE REDE NEURAL COM DUAS CAMADAS.....	29
FIGURA 3.11.	MODELO DE REDE NEURAL COM TRÊS CAMADAS.....	29
FIGURA 3.12.	MODELO DE REDE NEURAL RECORRENTE.....	30
FIGURA 3.13.	ILUSTRAÇÃO DAS PROPAGAÇÕES <i>FORWARD</i> (PARA A FRENTE) E <i>BACKWARD</i> (PARA TRÁS) DO ALGORITMO <i>BACK-PROPAGATION</i>	35
FIGURA 3.14.	REPRESENTAÇÃO GEOMÉTRICA DE COMPONENTES PRINCIPAIS.....	37
FIGURA 3.15.	<i>SCREE PLOT</i> COM OITO COMPONENTES PRINCIPAIS.....	40
FIGURA 4.1.	FLUXOGRAMA DE IMPLEMENTAÇÃO DAS TÉCNICAS ENVOLVIDAS.....	41
FIGURA 4.2.	TREINAMENTO VERSUS CAPACIDADE DE GENERALIZAÇÃO DA RNA.....	44
FIGURA 4.3.	AUTOVALORES VERSUS FATORES DA ACP.....	51
FIGURA 4.4.	AUTOVALORES VERSUS FATORES DA ACP.....	58

LISTA DE QUADROS

QUADRO 2.1. CODIFICAÇÃO DO ATRIBUTO OBJETO DO PROCESSO.....	17
QUADRO 2.2. CODIFICAÇÃO DO ATRIBUTO SALÁRIO DO RECLAMANTE.....	18
QUADRO 2.3. CODIFICAÇÃO DO ATRIBUTO TEMPO DE SERVIÇO.....	18
QUADRO 2.4. CODIFICAÇÃO DO ATRIBUTO PROFISSÃO.....	19
QUADRO 2.5. CODIFICAÇÃO DO ATRIBUTO NÚMERO DE AUDIÊNCIAS.....	19

LISTA DE TABELAS

TABELA 4.1.	TOPOLOGIAS DO TESTE I DO PRIMEIRO PROCESSO.....	46
TABELA 4.2.	TOPOLOGIAS DO TESTE I DO SEGUNDO PROCESSO.....	46
TABELA 4.3.	RESULTADOS NUMÉRICOS DAS SIMULAÇÕES COM VARIAÇÃO DO NÚMERO DE ITERAÇÕES NO PRIMEIRO PROCESSO.....	47
TABELA 4.4.	RESULTADOS NUMÉRICOS DAS SIMULAÇÕES COM VARIAÇÃO DO NÚMERO DE ITERAÇÕES NO SEGUNDO PROCESSO.....	48
TABELA 4.5.	AUTOVALORES EM ORDEM DECRESCENTE.....	49
TABELA 4.6.	TOPOLOGIAS DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 31 COMPONENTES PRINCIPAIS.....	52
TABELA 4.7.	NÚMERO DE ITERAÇÕES DO TESTE II DO PRIMEIRO E SE- GUNDO PROCESSOS COM 31 COMPONENTES PRINCIPAIS.....	52
TABELA 4.8.	TOPOLOGIAS DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 16 COMPONENTES PRINCIPAIS	54
TABELA 4.9.	NÚMERO DE ITERAÇÕES DO TESTE II DO PRIMEIRO E SE- GUNDO PROCESSOS COM 16 COMPONENTES PRINCIPAIS.....	54
TABELA 4.10.	TOPOLOGIAS DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS.....	55
TABELA 4.11.	NÚMERO DE ITERAÇÕES DO TESTE II DO PRIMEIRO E SE- GUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS.....	56
TABELA 4.12.	AUTOVALORES EM ORDEM DECRESCENTE.....	57
TABELA 4.13.	TOPOLOGIAS DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 23 COMPONENTES PRINCIPAIS.....	59
TABELA 4.14.	NÚMERO DE ITERAÇÕES DO TESTE III DO PRIMEIRO E SE- GUNDO PROCESSOS COM 23 COMPONENTES PRINCIPAIS.....	60
TABELA 4.15.	TOPOLOGIAS DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 12 COMPONENTES PRINCIPAIS.....	61
TABELA 4.16.	NÚMERO DE ITERAÇÕES DO TESTE III DO PRIMEIRO E SE- GUNDO PROCESSOS COM 12 COMPONENTES PRINCIPAIS.....	62
TABELA 4.17.	TOPOLOGIAS DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS.....	63

TABELA 4.18. NÚMERO DE ITERAÇÕES DO TESTE III DO PRIMEIRO E SE- GUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS.....	64
TABELA 4.19. MELHORES RESULTADOS DAS REDES NEURAI.....	65

RESUMO

Com o aumento do número de processos trabalhistas que as Varas do Trabalho recebem para análise, julgamento e emissão de sentença, faz-se necessária a utilização de ferramentas matemáticas que forneçam uma previsão do tempo de andamento destes processos, a fim de que os cidadãos que recorrem a essa justiça tenham uma perspectiva do tempo de duração do julgamento de suas solicitações.

Este trabalho tem como objetivo fornecer uma previsão de tempo de duração do processo aos usuários desse sistema de justiça, bem como assessorar os Juízes do Trabalho na tomada de suas decisões, especificamente o Juiz da Primeira Vara do Trabalho de São José dos Pinhais (SJP), Paraná.

A metodologia proposta neste trabalho consiste na implementação de uma Rede Neural Artificial (RNA) que forneça uma previsão de tempo de duração dos processos trabalhistas.

Buscando atingir o objetivo proposto, através da metodologia adotada, foram treinadas diversas RNA, com as mais variadas topologias, e em alguns casos, utilizando-se Análise de Componentes Principais, buscando refinar ainda mais os resultados obtidos.

As ferramentas utilizadas mostraram-se de grande eficiência, uma vez que apresentaram resultados consistentes com uma margem de erro aceitável.

Palavras-Chave: Rede Neural Artificial, Análise de Componentes Principais, Tempo de Processo

ABSTRACT

As the number of labor lawsuits has on given time preview been increasing in Labor Jurisdictions, mathematical tools show to be crucial spent in analyzing, judging, and giving the verdict, so that the citizens can be aware of the outcome of their lawsuits from the perspective on the duration of the process as a whole.

This work aims at predicting the length of time of the process to the users of this law system, as well as to advise labor judges in making their decisions, specifically Sao Jose dos Pinhais Labor Jurisdiction Judge (Parana State - Brazil).

The methodology presented in this research is based on the implementation of an Artificial Neural Network that is able to predict the length of time taken by the labor lawsuits.

Attempting to reach the main aim of this work and refine the results, many Artificial Neural Network were trained using different topologies, or even using Principal Component Analysis.

The tools used in this research proved to be extremely efficient, once they have presented solid results with low error margin.

Kei-words: Artificial Neural Network, Principal Component Analysis, Time of the Process.

CAPÍTULO I

1. INTRODUÇÃO

A Justiça do Trabalho tem como competência julgar todas as ações com relação a trabalho, ações sobre representação sindical, atos decorrentes de greve, indenização por dano moral ou patrimonial resultantes da relação de trabalho e, ainda, os processos relativos às penalidades administrativas impostas aos empregadores por fiscais do trabalho.

Diante de tão amplo horizonte de atribuições, faz-se necessária a utilização de ferramentas matemáticas que forneçam uma previsão do tempo de andamento destes processos, a fim de que os cidadãos que recorrem a essa justiça tenham uma perspectiva do tempo de duração do julgamento de suas solicitações.

No ano de 2005, a 1ª Vara de Justiça do Trabalho da cidade de São José dos Pinhais (SJP-PR), recebeu cerca de três mil processos para análise, julgamento e emissão de sentença. Contando com 19 funcionários que tramitam os processos, fica a cargo do único juiz a emissão da sentença que é obtida pela análise do referido processo.

Diante de uma vasta quantidade de informações contidas em cada processo e levando em consideração a necessidade de agilidade na emissão da sentença, a utilização de uma ferramenta que venha reconhecer padrões em processos trabalhistas de modo a auxiliar o juiz na previsão do tempo de duração dos processos vem ao encontro de tal necessidade.

Uma pergunta então é inevitável: Qual ferramenta utilizar para este reconhecimento de padrões?

As Redes Neurais Artificiais (RNA) são baseadas no sistema nervoso biológico e utilizadas, entre outras funções, no reconhecimento de padrões. Assim, esta é a ferramenta que se encaixa perfeitamente às pretensões deste trabalho.

Atualmente as RNA têm aplicação nos mais variados campos, dentre os quais se podem destacar:

- Diagnóstico médico [Cipra, 1992], [Infantosi *et al*, 2004];
- Na predição de falência bancária [Tam *et al*, 1992];
- Na aplicação à fabricação da pasta de papel industrial [Fadum, 1993];
- No controle de processo de produção de papel industrial [Rudd, 1991], [Steiner, 1994];
- No mundo financeiro [Gazeta Mercantil, 1993], [Cipra, 1992];
- Na obtenção de um modelo organizacional [Almeida, 1995];
- Na detecção de fraudes com cartões [Financial Times, 1993];
- Nos problemas de administração de empresas [Almeida, 1995], [Adamowicz, 2000];
- Na orientação profissional [Baldin, 2002];
- Na análise de crédito bancário [Lemos *et al*, 2005];
- No reconhecimento de padrões em um nariz artificial [Yamazaki, 2001];
- No mercado acionário [Mueller, 1996].

1.1 OBJETIVOS DO TRABALHO

O objetivo principal deste trabalho é fornecer uma previsão do tempo de duração de um processo trabalhista aos usuários do sistema da Justiça do Trabalho, utilizando RNA, como ferramenta matemática para o reconhecimento de padrões nestes processos trabalhistas a fim de assessorar Juízes do Trabalho.

Diante deste contexto, este trabalho apresenta a implementação de uma RNA que, considerando as informações relevantes, reconhece os padrões contidos nos processos, fornecendo assim várias vantagens, dentre as quais podem ser destacadas:

- obtenção de uma perspectiva de duração do processo de forma clara e objetiva;
- maior possibilidade de estabelecimento de acordos;
- diminuição das durações médias dos processos, como consequência de uma maior possibilidade de estabelecimento de acordos.

1.2 REVISÃO DA LITERATURA – TRABALHOS RELACIONADOS

Nesta seção são resumidos trabalhos que se utilizam de RNA na solução dos mais diversos problemas.

As RNA vêm sendo largamente utilizadas nos mais diversos campos, a saber: análise de crédito, área da saúde, detecção de fraudes, bolsa de valores, gerenciamento de produção, sistemas de saúde e vários outros.

WOLF (2004) propõe uma análise automática de sinais eletrocardiográficos por RNA. Utilizou um algoritmo para extrair informações do registro eletrocardiográfico de pacientes que posteriormente foram comparadas com faixas de normalidade, indicando, assim, possível presença de alterações morfológicas.

CASTRO (2004) desenvolveu um sistema inteligente para previsão do índice IBOVESPA, baseado em RNA. Modelos de previsão distintos foram propostos para a série IBOVESPA, porém o modelo mais eficiente para a previsão deste índice foi desenvolvido a partir de RNA.

REALI (2004) mostrou a utilização de RNA no gerenciamento da produção de frango. Para a construção das redes neurais artificiais foi utilizado o programa computacional *NeuroShell@Predictor*, desenvolvido pela *Ward Systems Group*. Ao programa foram apresentadas as variáveis escolhidas como entradas para o cálculo do modelo preditivo e a variável de saída, aquela a ser predita. Utilizou-se os dados de 1000 criadores para o treinamento das redes e de 604 criadores para a validação dos resultados. Em todos os 20 modelos gerados na fase de treinamento, os resultados foram bem ajustados, apresentando Coeficientes de Determinação Múltipla (R^2) elevados e muito próximos de 1, como o desejado, além de apresentarem o Erro Quadrático Médio (QME) e Erro Médio reduzidos, evidenciando

que tal técnica oferece critérios objetivos que podem servir de suporte para as decisões dos responsáveis pela produção industrial do frango de corte.

FREIMAN (2004) discute a possibilidade de utilização das redes no agro negócio, realizando previsões de preços de *commodities* e comparando-as com aquelas obtidas com o uso de um método estatístico tradicional.

COSTA (2004) propõe uma modelagem das distâncias percorridas por pacientes com fratura no fêmur a hospitais públicos do Rio de Janeiro – RJ, utilizando RNA e Regressão Múltipla. Os resultados mostraram que as RNA apresentaram acerto de 88,5%, enquanto na regressão o acerto foi de 33%. Tais resultados são explicados pelas características não lineares do problema.

VIDAL (2004) realiza um estudo de caso analisando a tendência do número de acidentes e feridos nas rodovias federais do Espírito Santo, utilizando para isto as RNA, pois a análise estatística mostra elevado grau de dificuldade na determinação de tendências ou na identificação de comportamento ao longo do tempo.

OLIVEIRA (2004) apresenta um estudo sobre a variabilidade do nível do mar na baía de Paranaguá – PR. Destaca que as marés astronômicas são as principais causas dessa variabilidade, mas os efeitos meteorológicos também são responsáveis pelas sobreelevações e abaixamentos do nível do mar. A RNA utilizada para prever a maré meteorológica apresentou um bom desempenho, sendo útil no sentido de melhorar os resultados das previsões de maré calculadas com os modelos clássicos das constantes harmônicas.

LOPES (2004) criou um sistema de identificação de alvos (aeronaves) em sistemas de defesa aérea, filtrando, através de uma RNA alvos falsos que apresentam características semelhantes a aeronaves. Os resultados mostraram a eficiência da rede na identificação de alvos falsos sem comprometer a segurança dos sistemas de defesa aérea brasileiro.

LEMOS *et al* (2005) utilizam duas ferramentas de *Data Mining*: RNA e Árvores de Decisão no reconhecimento de padrões de “bons e maus” tomadores de crédito. Analisando registro de 339 clientes de uma agência bancária transformou estes

dados, através das técnicas citadas, em informações que podem auxiliar a tomada de decisão sobre conceder ou não crédito bancário a um novo cliente.

BAPTISTELLA *et al* (2006) comparam as técnicas de RNA e Regressão Linear Múltipla na estimação de valores venais de imóveis urbanos na cidade de Guarapuava-PR. As duas técnicas mostraram-se eficientes na resolução deste problema, porém os resultados obtidos através das redes foram melhores que os obtidos através da regressão.

BALDIN (2002) utiliza técnicas de RNA aplicadas a pessoas satisfeitas profissionalmente para, posteriormente, fazer uso deste treinamento na orientação de jovens na escolha de sua profissão.

INFANTOSI *et al* (2004) utilizam Análise de Componentes Principais como metodologia para redução da dimensionalidade das variáveis de entrada de uma RNA, cuja finalidade é auxiliar médicos na tomada de decisões em transplante renal.

1.3 ESTRUTURA DO TRABALHO

Buscando melhor apresentação e clareza, o presente trabalho divide-se em cinco capítulos.

O primeiro capítulo trata desta introdução ao trabalho. No capítulo II é apresentada uma descrição detalhada do problema abordado.

No capítulo III são apresentados conceitos que envolvem as técnicas de RNA, desde o treinamento da rede, as topologias adotadas, o algoritmo *back-propagation* (retro-propagação), a função de transferência sigmoideal, até o balanceamento dos pesos para o reconhecimento dos padrões. Também são apresentados conceitos de Análise de Componentes Principais – desde Componentes Principais Populacionais, suas interpretações algébrica e geométrica, até Componentes Principais Amostrais e, por fim, algumas regras para determinação do número de componentes que devam ser retidos.

No capítulo IV é descrita, minuciosamente, a aplicação de RNA e Análise de Componentes Principais ao problema abordado no capítulo II e, também, a análise dos resultados.

Finalizando, no capítulo V são apresentadas as conclusões obtidas por meio da análise dos resultados do capítulo anterior, bem como sugestões para trabalhos futuros.

CAPÍTULO II

2. DESCRIÇÃO DO PROBLEMA

Neste capítulo será apresentada a descrição detalhada do problema estudado junto a 1ª Vara da Justiça do Trabalho de São José dos Pinhais - Paraná.

2.1 INTRODUÇÃO

A justiça do trabalho tem por finalidade julgar todas as controvérsias decorrentes da relação de trabalho, na forma da lei. Para cumprir sua finalidade, a mesma está estruturada em três graus de jurisdição:

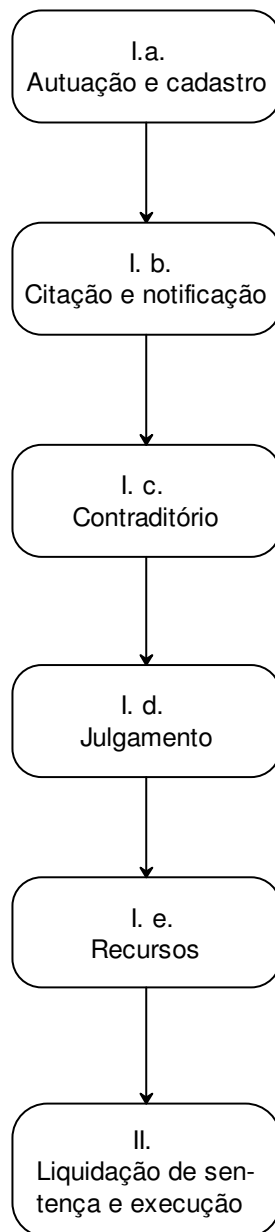
- Primeiro Grau: Varas do Trabalho;
- Segundo Grau: Tribunais Regionais do Trabalho;
- Terceiro Grau: Tribunal Superior do Trabalho.

As Varas do Trabalho são compostas por um juiz do trabalho titular e um juiz do trabalho substituto. Por ocasião da pesquisa realizada em novembro de 2006, junto à Associação Nacional dos Magistrados da Justiça do Trabalho (ANAMATRA, 2006), a justiça do trabalho apresenta a seguinte constituição: São 1.109 Varas do Trabalho em todo o país, com 2.288 juízes, sendo 1.109 titulares e 1.179 substitutos. Os Tribunais Regionais do Trabalho (TRT) estão instalados no Distrito Federal e em 22 Estados e são compostos por 315 juízes, distribuídos de acordo com o movimento processual do Tribunal. O Tribunal Superior do Trabalho (TST) é composto por 17 ministros, togados e vitalícios, todos nomeados pelo Presidente da República, sendo 11 destas vagas destinadas a juízes de carreira, três a advogados e três aos membros do Ministério Público do Trabalho.

Todo cidadão que tenha alguma controvérsia decorrente de relação de trabalho tem o direito de procurar a Justiça do Trabalho, a fim de que a mesma seja julgada e seus direitos sejam respeitados.

Buscando esquematizar o trâmite de uma ação trabalhista, apresentam-se, a seguir, sete fluxogramas que mostram o andamento do processo, desde a sua autuação até a emissão da sentença.

FIGURA 2.1. FASES DO PROCESSO DE CONHECIMENTO E EXECUÇÃO

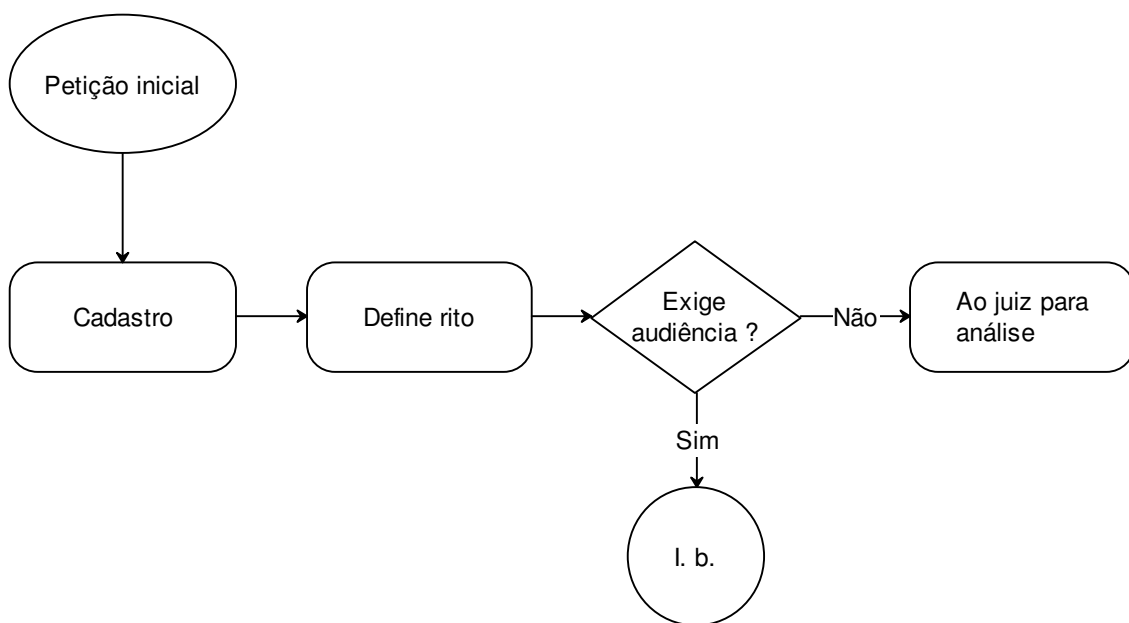


A figura 2.1 mostra as fases gerais de um processo trabalhista. O início se dá quando o autor (reclamante) autua seus pedidos em uma vara do trabalho. O processo é então cadastrado (I.a). A justiça do trabalho vai notificar o reclamado (I.b), que apresentará seus argumentos acerca dos pedidos do reclamante (I.c). O próximo passo fica a cargo do juiz do trabalho, a quem cabe julgar os pedidos do autor da causa (I.d). Quando as partes envolvidas tomam conhecimento do julgamento podem impetrar um recurso (I.e). Se não couberem mais recursos ou se

ambas as partes estão satisfeitas com o julgamento, o juiz determina a execução do processo (II), ou seja, são calculados os valores a serem pagos.

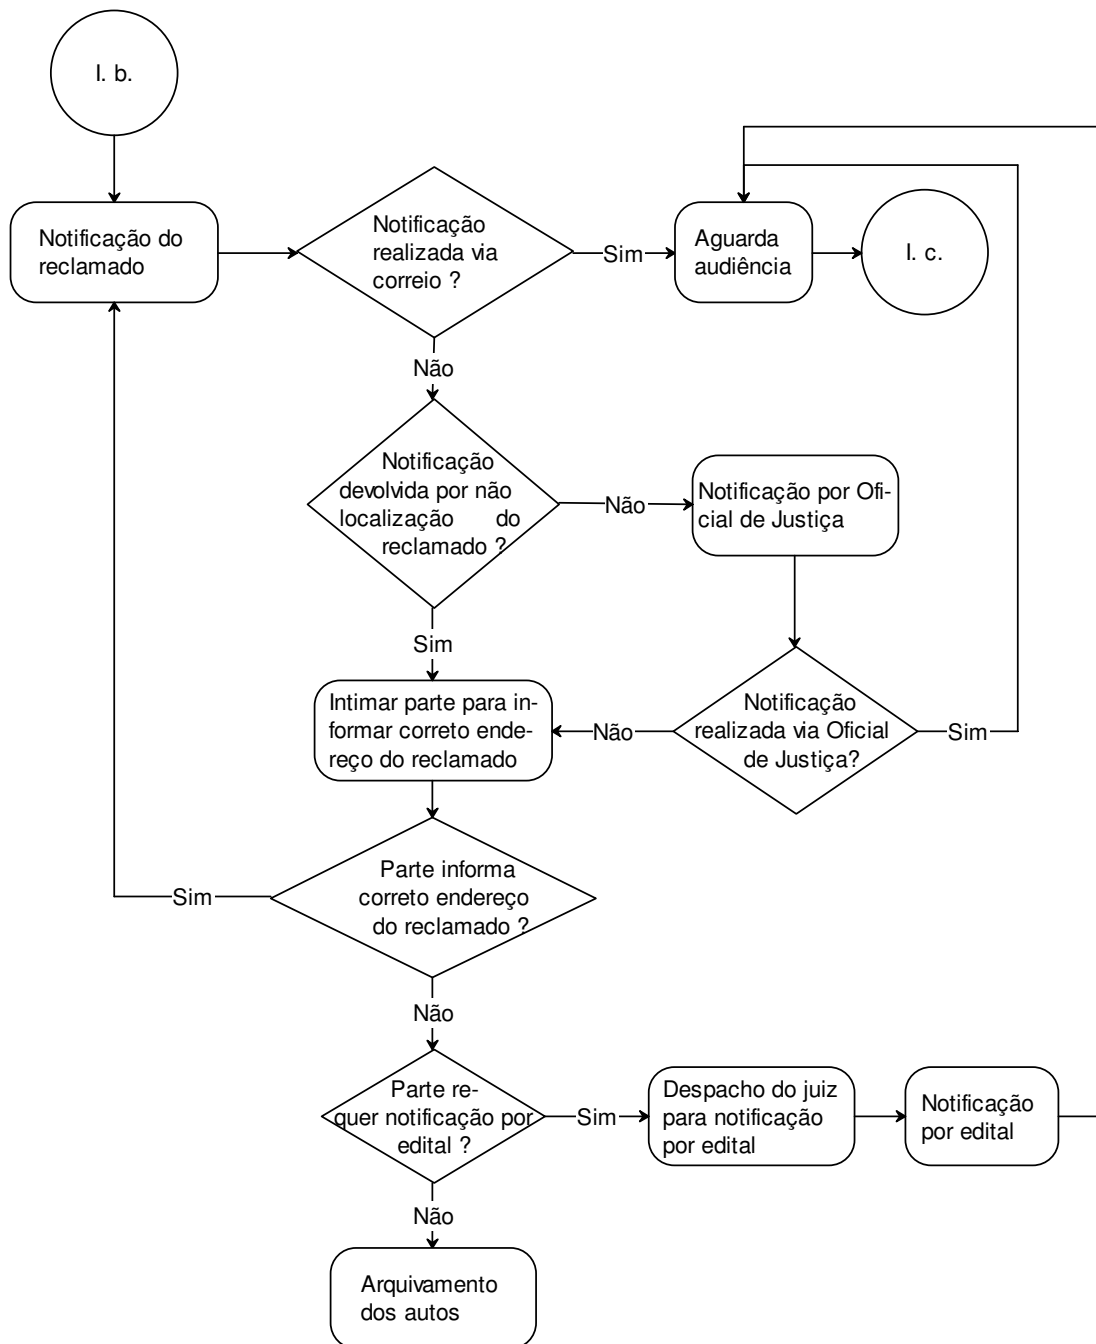
Os fluxogramas que se seguem esquematizam as ações, dentro de cada uma das fases expostas anteriormente no fluxograma contido na figura 2.1, a serem tomadas pelas partes envolvidas no processo.

FIGURA 2.2. FASE DA AUTUAÇÃO E CADASTRO



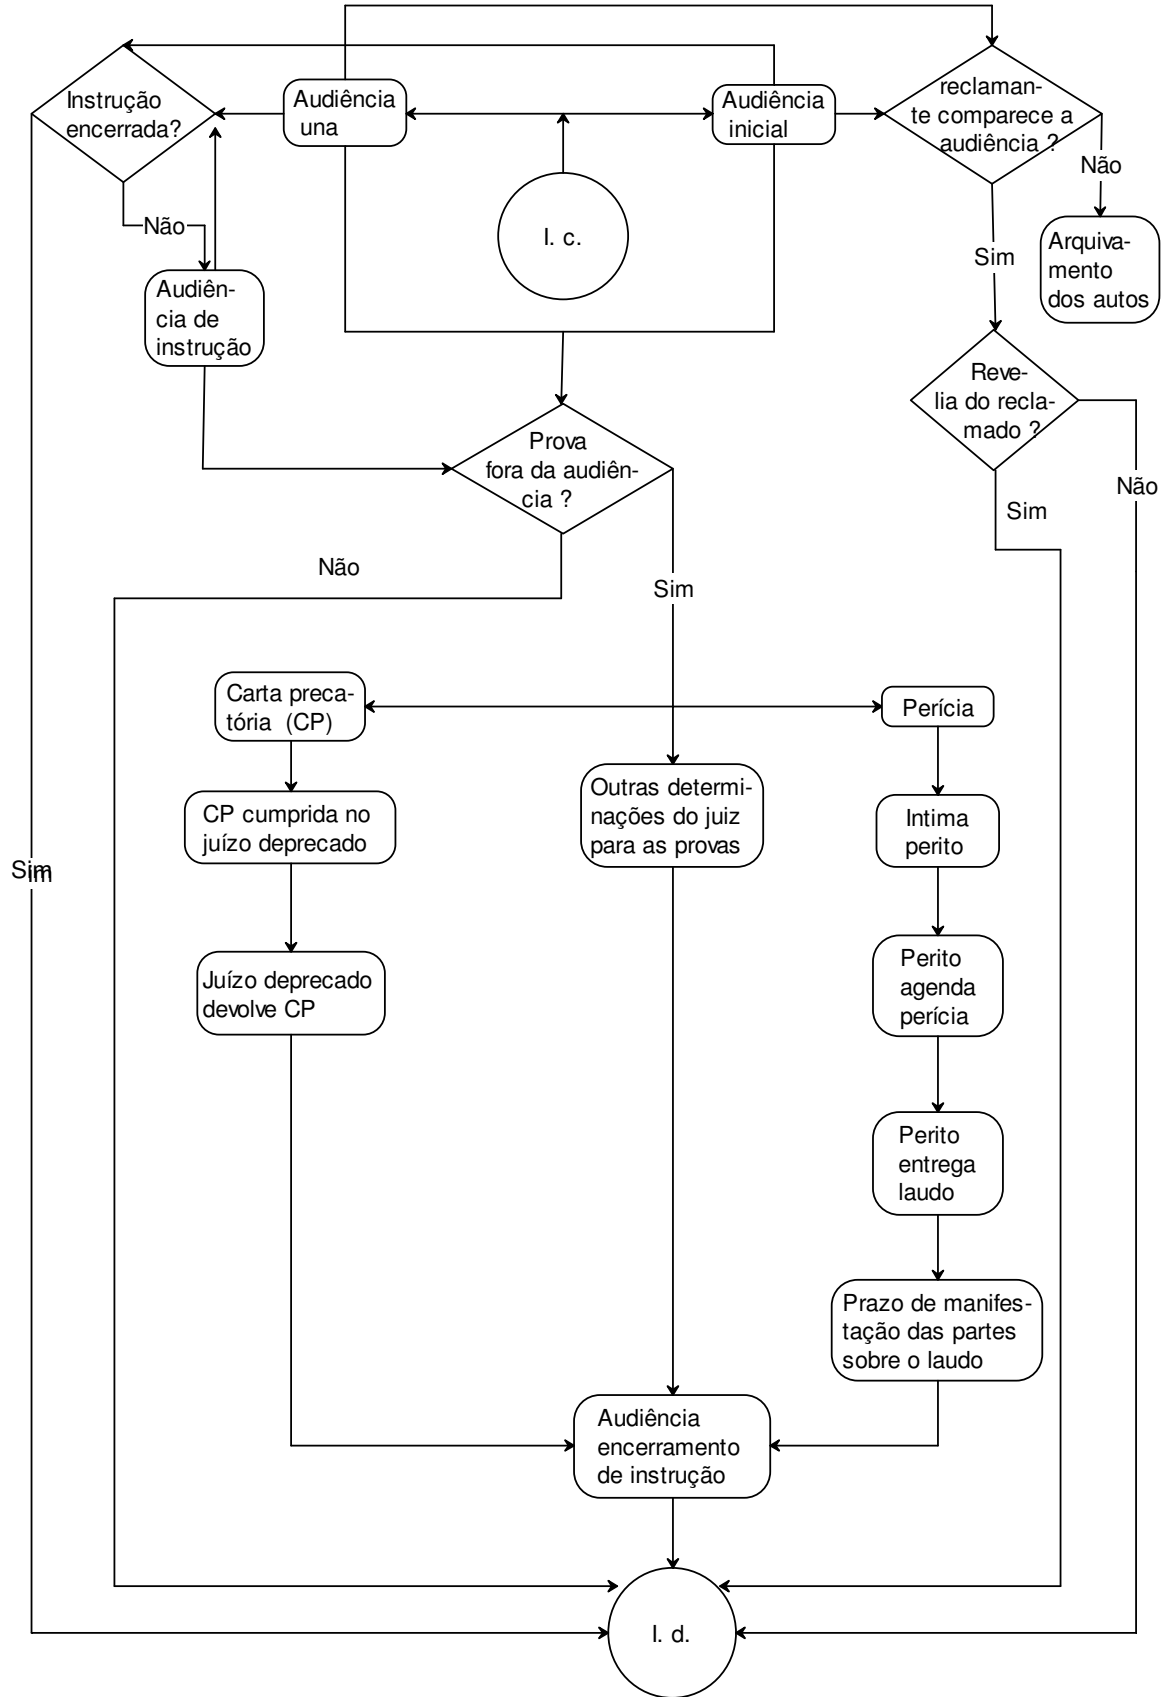
A figura 2.2 apresenta a fase inicial do processo. É a partir da petição que o reclamante expõe seus pedidos à justiça. Estas solicitações são cadastradas, passando a compor o processo que é classificado de acordo com o tipo de rito a ser seguido. Se este processo exigir audiência com as partes envolvidas segue para a fase de citação e notificação, caso contrário vai para análise do juiz.

FIGURA 2.3. FASE DA CITAÇÃO E NOTIFICAÇÃO



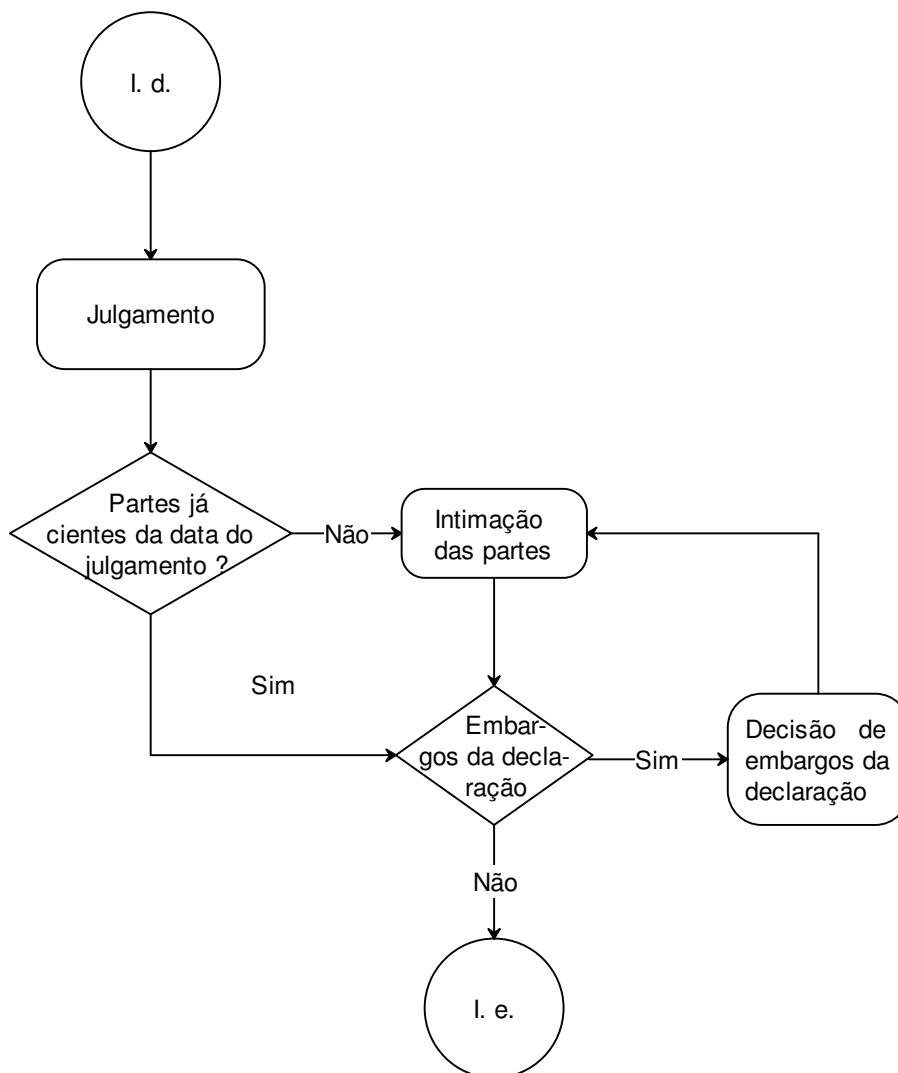
A figura 2.3 mostra todos os recursos utilizados pela justiça do trabalho para citar e notificar o reclamado do processo. A justiça do trabalho utiliza três maneiras de notificar o reclamado. A primeira delas se dá através do correio. Caso não se atinja o objetivo, a notificação será feita via oficial de justiça. Se mesmo assim o reclamado não foi notificado pode-se notificá-lo através de edital.

FIGURA 2.4. FASE DO CONTRADITÓRIO



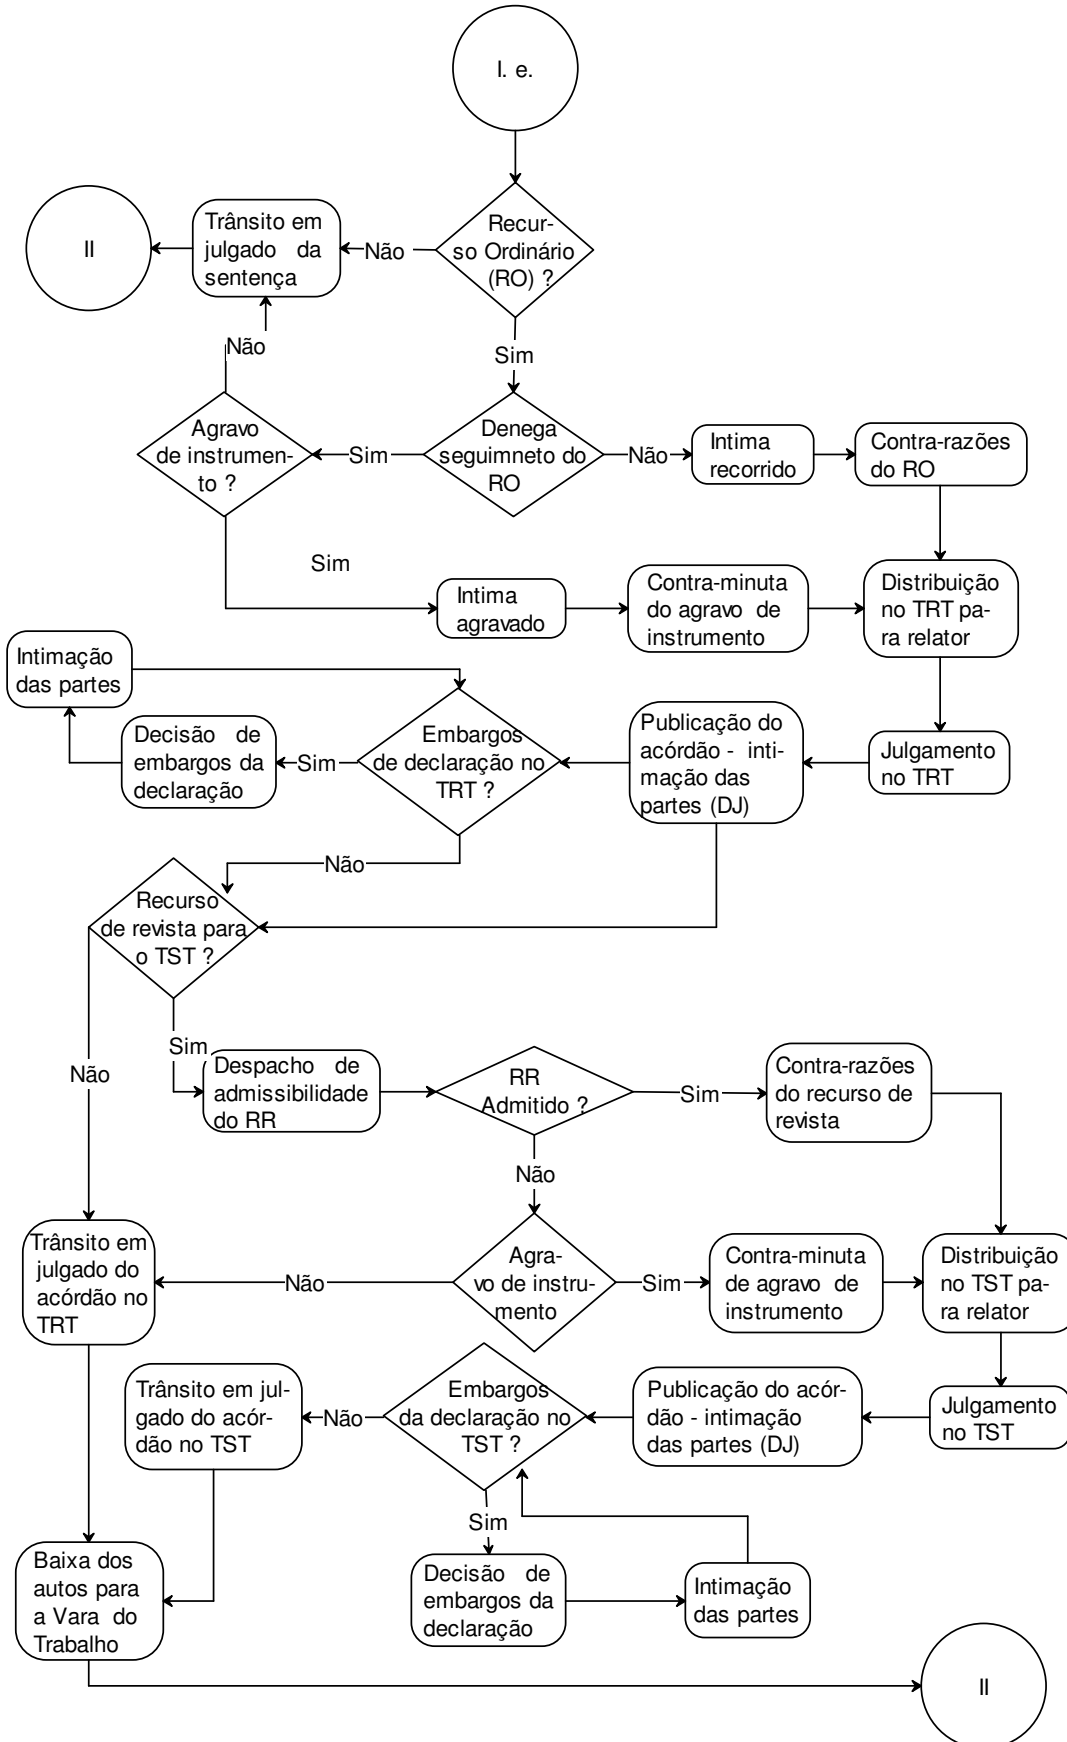
A figura 2.4 mostra o desenvolvimento da fase do contraditório. Nesta fase o juiz do trabalho utiliza-se de audiências, perícias e cartas precatórias (se for o caso) a fim de elucidar todos os fatos acerca do processo. Quando todos os fatos estão devidamente esclarecidos, o juiz encerra a instrução e o processo segue para a fase do julgamento.

FIGURA 2.5. FASE DO JULGAMENTO



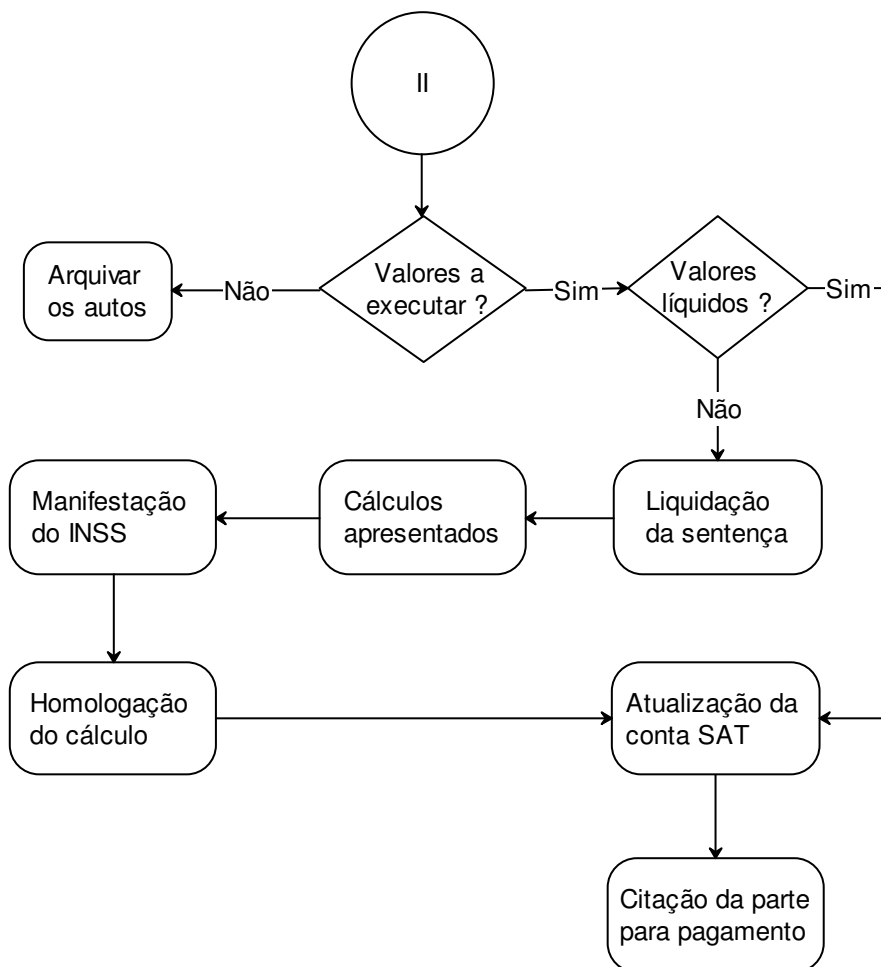
A figura 2.5 ilustra a fase do julgamento. Nesta fase, quando todos os fatos já foram elucidados, o juiz do trabalho julga os pedidos do reclamante. Se alguma das partes fornecerem embargos à sentença do juiz, ele analisa tais embargos, e caso os aceite, informa uma nova sentença.

FIGURA 2.6. FASE DOS RECURSOS



A fase dos recursos, ilustrada na figura 2.6, mostra a seqüência de fatos a serem seguidos quando uma das partes envolvidas no processo discorda da sentença emitida pelo juiz. A parte que discordou da sentença solicita Recurso Ordinário (RO) ao Tribunal Regional do Trabalho (TRT). A outra parte fornece contra-razões ao RO. O TRT julga o recurso e publica o acórdão (decisão acerca do recurso). Se alguma das partes discordar deste acórdão, solicita Recurso de Revista (RR) ao Tribunal Superior do Trabalho (TST). Novamente a outra parte fornece suas contra-razões a este recurso. O TST julga tal recurso e emite seu acórdão. O processo volta para a vara do trabalho de origem e é executado conforme fluxograma 2.7 a seguir.

FIGURA 2.7. FASE DA EXECUÇÃO



A última fase do processo, ilustrada na figura 2.7, trata da execução da sentença. Se o processo não gerou valores a serem pagos ele é arquivado. Caso

contrário, os valores são calculados e informados a parte interessada para que execute o pagamento.

2.2 ESTUDO DE UM CASO

Este trabalho foi realizado junto à 1ª Vara do Trabalho de São José dos Pinhais-PR, que no ano de 2005 recebeu cerca de três mil processos. Estes processos foram analisados sem o auxílio de nenhuma ferramenta matemática ou computacional que pudesse auxiliar o juiz na emissão da sentença e/ou fornecer ao cliente do sistema uma previsão quanto ao tempo de duração do processo.

2.2.1 Obtenção dos Dados

Com o propósito pré-estabelecido de treinar uma RNA que forneça uma previsão ótima do tempo de duração de processos trabalhistas e, diante de uma infinidade de dados contidos em cada um deles, foram realizadas reuniões com o juiz a fim de identificar quais dados seriam realmente relevantes na obtenção do tempo de duração do processo.

Como resultado destas reuniões, chegou-se à seguinte relação de dez entradas / atributos da RNA:

1. Objeto do Processo: corresponde às solicitações feitas pelo reclamante. Estas, dentre outras, podem ser do tipo: falta de registro em carteira profissional, horas extras, fundo de garantia por tempo de serviço, verbas rescisórias, seguro desemprego, vale transporte, adicional de insalubridade, multa do Art. 477, adicional noturno, diferenças salariais, multa do Art. 467 e indenização por danos morais.

2. Salário do Reclamante: refere-se ao último salário recebido pelo autor do processo.

3. Rito: trata do tipo de rito a ser seguido no processo. O rito pode ser de dois tipos: de trabalho (RT) ou processo sumaríssimo (PS).

4. Perícia: se há necessidade (ou não) de realização de alguma espécie de perícia. Neste caso tem-se, como exemplo, a perícia médica ou a de periculosidade.

5. Tempo de Serviço: é dado em meses pela diferença entre a data de dispensa e data de admissão.

6. Acordo: quando as partes (reclamante e reclamado) entram em acordo antes do julgamento do pedido.

7. Profissão: trata das funções exercidas pelo reclamante. Dividiu-se este atributo em duas partes: setor, que pode ser comércio, indústria e serviço; cargo, que pode ser direção e execução.

8. Recurso Ordinário (RO): quando uma das partes (reclamante ou reclamado) não concorda com a sentença emitida pelo juiz e solicita RO ao TRT.

9. Recurso de Revista (RR): quando uma das partes (reclamante ou reclamado) não concorda com o acórdão emitido pelo TRT e solicita RR ao TST.

10. Número de Audiências: trata do número de audiências necessárias para que o juiz emita a sentença.

Foram analisados um total de cem processos ajuizados entre os anos de 1997 e 2005, na Vara do Trabalho de São José dos Pinhais – Paraná. Através da Ficha de Dados (Apêndice I) foram extraídos os atributos listados anteriormente, criando, assim, uma matriz de dados destinada ao treinamento e ao teste das RNA.

2.2.2 Tratamento dos Dados

A fim de que a RNA apresentasse uma consistência no seu desempenho, com relação à obtenção das respostas desejadas, cada um dos atributos anteriormente citados em 2.2.1 foi "tratado" de maneira a corresponder a uma ou mais coordenadas binárias (LU *et al*, 1996), (BAESENS *et al*, 2003), do vetor de entrada da RNA, conforme comentado a seguir:

O atributo "Objeto do Processo" que corresponde a uma das solicitações, já citadas, pelo autor do processo, apresentará o valor "1", se for solicitada; valor "0", em caso de não solicitação, ou seja, trata-se de um atributo nominal. O quadro 2.1 a seguir mostra a codificação desse atributo.

QUADRO 2.1. CODIFICAÇÃO DO ATRIBUTO OBJETO DO PROCESSO

Atributos	Valores originais dos Atributos	Intervalos	Número de padrões em cada intervalo	Entrada 1	Número de Entradas
1 Objeto do Processo – Falta de Registro em CPTS (atributo nominal)				I₁	1
	1 = sim	1 = sim	11	1	
	0 = não	0= não	89	0	
2 Objeto do Processo – Horas Extras. (atributo nominal)				I₂	1
	1 = sim	1 = sim	87	1	
	0 = não	0= não	13	0	
3 Objeto do Processo – FGTS (atributo nominal)				I₃	1
	1 = sim	1 = sim	52	1	
	0 = não	0= não	48	0	
4 Objeto do Processo – Verbas Rescisórias (atributo nominal)				I₄	1
	1 = sim	1 = sim	65	1	
	0 = não	0= não	35	0	
5 Objeto do Processo – Seguro Desemprego (atributo nominal)				I₅	1
	1 = sim	1 = sim	19	1	
	0 = não	0= não	81	0	
6 Objeto do Processo – Vale Transporte (atributo nominal)				I₆	1
	1 = sim	1 = sim	13	1	
	0 = não	0= não	87	0	
7 Objeto do Processo – Adicional Insalubridade (atributo nominal)				I₇	1
	1 = sim	1 = sim	21	1	
	0 = não	0= não	79	0	
8 Objeto do Processo – Multa Art 477 (atributo nominal)				I₈	1
	1 = sim	1 = sim	55	1	
	0 = não	0= não	45	0	
9 Objeto do Processo – Adicional Noturno (atributo nominal)				I₉	1
	1 = sim	1 = sim	4	1	
	0 = não	0= não	96	0	
10. Objeto do Processo – Diferenças Salariais (atributo nominal)				I₁₀	1
	1 = sim	1 = sim	28	1	
	0 = não	0= não	72	0	
11 Objeto do Processo – Multa Art 467 (atributo nominal)				I₁₁	1
	1 = sim	1 = sim	28	1	
	0 = não	0= não	72	0	
12 Objeto do Processo – Danos Morais (atributo nominal)				I₁₂	1
	1 = sim	1 = sim	15	1	
	0 = não	0= não	85	0	
Total	---	---	---	---	12

O atributo "Salário do Reclamante" foi dividido em faixas, buscando manter a mesma cardinalidade dentro de cada uma delas. Neste caso, por se tratar de um atributo ordinal, as coordenadas binárias que o representam foram definidas conforme quadro 2.2 a seguir, apresentando assim três coordenadas no vetor de entrada da rede neural.

QUADRO 2.2. CODIFICAÇÃO DO ATRIBUTO SALÁRIO DO RECLAMANTE

Atributo	Valores originais dos Atributos	Intervalos	Número de padrões em cada intervalo	Entrada 1	Entrada 2	Entrada 3	Número de Entradas
Salário do Reclamante (atributo ordinal)	Faixas	Salário em reais		I ₁₃	I ₁₄	I ₁₅	3
	1	<= 300	23	0	0	0	
	2	>300 e <= 400	25	0	0	1	
	3	>400 e <= 600	23	0	1	1	
	4	> 600 reais	29	1	1	1	

Quando o atributo "Rito" for do tipo RT, apresentará entrada com valor "1"; quando for do tipo PS, apresentará valor "0". Se for necessária a execução de qualquer tipo de Perícia, este dado apresentará entrada igual a "1" no vetor de entrada; caso contrário, apresentará valor "0".

Com relação ao "Tempo de Serviço", novamente se tem uma variável ordinal. Analogamente ao tratamento dispensado ao atributo "Salário do Reclamante", esse atributo foi dividido em faixas, buscando manter a mesma cardinalidade dentro de cada uma delas. Porém, como se pode observar no quadro 2.3, este apresenta quatro coordenadas no vetor de entradas da RNA.

QUADRO 2.3. CODIFICAÇÃO DO ATRIBUTO TEMPO DE SERVIÇO

Atributo	Valores originais dos Atributos	Intervalos	Número de padrões em cada intervalo	Entrada 1	Entrada 2	Entrada 3	Entrada 4	Número de Entradas
Tempo de Serviço (atributo ordinal)	Faixa	Duração em meses		I ₁₈	I ₁₉	I ₂₀	I ₂₁	4
	1	<= 6	20	0	0	0	0	
	2	> 6 e <= 14	23	0	0	0	1	
	3	>14 e <= 28	27	0	0	1	1	
	4	> 28 e <= 48	14	0	1	1	1	
	5	> 48	16	1	1	1	1	

Quando as partes (reclamante e reclamado) entram em "acordo" antes do julgamento do pedido, esta entrada apresentará o valor "1"; caso contrário, apresentará valor "0". Conforme comentado anteriormente, o atributo "Profissão" foi dividido em setor e cargo; por se tratar de uma variável nominal, contará com quatro coordenadas no vetor entrada de dados, como se observa no quadro 2.4 a seguir.

QUADRO 2.4. CODIFICAÇÃO DO ATRIBUTO PROFISSÃO

Atributo	Setor do Atributo	Cargo do Atributo	Número de padrões em cada Setor/Cargo	Entrada 1	Entrada 2	Entrada 3	Entrada 4	Número de Entradas
Profissão (atributo nominal)	Setor	Cargo		I_{23}	I_{24}	I_{25}	I_{26}	4
	Comércio	Direção	1	0	0	1	1	
	Comércio	Execução	13	0	0	1	0	
	Indústria	Direção	2	0	1	0	1	
	Indústria	Execução	39	0	1	0	0	
	Serviço	Direção	2	1	0	0	1	
	Serviço	Execução	43	1	0	0	0	

Tanto o "Recurso Ordinário" quanto o "Recurso de Revista", se forem solicitados, apresentarão valor "1" no vetor entrada de dados; caso contrário, apresentarão valor "0". O tratamento dado ao atributo "Número de Audiências" foi o mesmo dado ao "Tempo de Serviço" e ao "Salário do Reclamante", uma vez que se trata de uma variável ordinal. Este dado apresenta quatro coordenadas no vetor de entrada, conforme se vê na quadro 2.5 a seguir.

QUADRO 2.5. CODIFICAÇÃO DO ATRIBUTO NÚMERO DE AUDIÊNCIAS

Atributo	Valores originais dos Atributos	Intervalos	Número de padrões em cada intervalo	Entrada 1	Entrada 2	Entrada 3	Entrada 4	Número de Entradas
Número de Audiências (atributo ordinal)	Faixa	Audiências		I_{29}	I_{30}	I_{31}	I_{32}	4
	1	1	47	0	0	0	0	
	2	2	33	0	0	0	1	
	3	3	14	0	0	1	1	
	4	4	4	0	1	1	1	
	5	≥ 5	2	1	1	1	1	

Assim sendo, obtém-se um vetor com 32 coordenadas binárias, que correspondem aos dez atributos definidos para cada processo. Como foram extraídos dados de cem processos, a matriz de entrada de dados (Apêndice II) da RNA é da ordem de (100 x 32).

No tratamento dispensado à saída da RNA, precisou-se levar em consideração que a função de transferência utilizada no treinamento e no teste da RNA é a função sigmoïdal, que fornece saídas contidas no intervalo (0, 1) para entradas contidas no intervalo $(-\infty, +\infty)$. Assim, foi necessário enquadrar as saídas, ou seja, os tempos de duração dos processos que variaram, no caso estudado, de 2 a 94 meses ao intervalo de abrangência desta função.

Foram definidos dois tipos de enquadramento das saídas ao intervalo (0, 1). O primeiro processo de ajuste consistiu em dividir todas as saídas por 94. Já, no segundo processo utilizou-se do fato de que a amostra de dados da saída se trata de uma distribuição normal. Assim, para cada saída, calculou-se a distribuição normal cumulativa. Assim sendo, tanto o primeiro quanto o segundo processos (Apêndice III), enquadram as saídas da RNA no intervalo de abrangência da função sigmoidal (0, 1).

CAPÍTULO III

3. REFERENCIAL TEÓRICO

Neste capítulo são apresentados conceitos que envolvem as técnicas de RNA, desde o treinamento da rede até o balanceamento dos pesos para o reconhecimento dos padrões. Também são apresentados conceitos de Análise de Componentes Principais tais como Componentes Principais Populacionais, suas interpretações algébrica e geométrica e Componentes Principais Amostrais.

3.1 REDES NEURAIS ARTIFICIAIS

As RNA são inspiradas na estrutura neural humana e utilizam técnicas computacionais que simulam o seu funcionamento, aprendendo através da experiência.


São compostas de muitos elementos simples, inspirados pelo sistema nervoso biológico, que operam em paralelo. A função da rede é determinada pelas conexões entre os seus elementos (STEINER, 2005).

HAYKIN (2001) define as redes como um processador maciço e paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e aplicá-lo para resolver problemas.

3.1.1 Histórico

Data de 1943 o primeiro modelo artificial de um neurônio biológico, que foi denominado pelos seus criadores Warren McCulloch (neurofisiologista) e Walter Pitts (matemático) de neurônio formal ou neurônio artificial. Em seu trabalho "*A Logical Calculus of the Ideas Immanent in Nervous Activity*", que unificou conceitos de neurofisiologia e lógica matemática, eles mostraram que uma coleção de neurônios formais era capaz de realizar alguns cálculos lógicos. O princípio de funcionamento do neurônio formal é apresentado na figura 3.1 a seguir.

FIGURA 3.1. NEURÔNIO FORMAL




FONTE: DIN (2006)

Por um longo período de tempo, poucos resultados foram obtidos. Em 1949, Donald Hebb, em seu livro intitulado "*The Organization of Behavior*", mostrou novas idéias, sendo o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios, de maneira que as mudanças nas forças das sinapses fossem proporcionais às ativações. Em seguida, Widrow e Hoff mostraram uma regra de aprendizado baseada na minimização do erro através do método do gradiente, que ficou conhecida como regra de *Widrow-Hoff* ou *regra delta*.


Em 1959, a partir das idéias desenvolvidas por Pitts e McCulloch, Frank Roseblatt descreveu o *perceptron*, primeiro modelo de rede neural que acrescia sinapses aos nodos de Pitts e McCulloch. Roseblatt descreveu uma topologia onde os neurônios eram organizados em camadas de entrada e saída, conforme se observa na Figura 3.2. Os pesos das conexões eram adaptados levando a rede a aprender certas funções lógicas e classificar vários tipos de padrões.

FIGURA 3.2. REDE DE PERCEPTONS



Em 1962, Widrow e Hoff desenvolveram as redes ADALINE (*ADaptive Linear NEtwork*) e o MADALINE (*MAAny ADALINE*) perceptron, que apresentam uma arquitetura de três camadas, conforme se pode observar na figura 3.3.


FIGURA 3.3. REDE ADALINE E MADALINE



FONTE: DIN (2006)

A partir de 1969, a pesquisa sobre redes neurais foi praticamente abandonada devido à repercussão do trabalho de Minsky e Papert, que expunha as limitações do Perceptron. Eles diziam que tal modelo se restringia à resolução de problemas linearmente separáveis, ou seja, problemas cuja solução pode ser obtida dividindo o espaço de entrada em duas regiões através de uma reta.

Foi em 1974 que Werbos lançou as bases do algoritmo *back-propagation* (retro-propagação), cuja estrutura se apresenta na figura 3.4, o que possibilitou que redes neurais de múltiplas camadas apresentassem capacidade de aprendizado para resolver problemas não-lineares. A partir de meados da década de 80 foram publicados os resultados obtidos pela técnica de treinamento por retro-propagação, fato que gerou uma explosão de interesse pelas RNA na comunidade internacional (HAYKIN, 2001).

FIGURA 3.4. ESTRUTURA DO MÉTODO *BACK-PROPAGATION*


FONTE: DIN (2006)

3.1.2 O Neurônio Artificial

O funcionamento do cérebro humano é muito complexo e dinâmico. Ele é capaz, através de uma constante interação com o meio em que está inserido, de receber, processar e responder a uma enorme quantidade de informações em um minúsculo intervalo de tempo. Apesar da complexidade geral do seu funcionamento, o cérebro é constituído basicamente de neurônios, que nada mais são do que simples unidades de processamento. Tais neurônios, ilustrados na figura 3.5, são constituídos basicamente pelas seguintes partes:

- dendritos: constituem as entradas dos impulsos elétricos;
- corpo celular: região onde são processadas as informações, obtidas a partir dos dendritos;
- axônio: saída das informações que foram processadas no corpo celular.


FIGURA 3.5. NEURÔNIO BIOLÓGICO



FONTE: BAPTISTELA (2005)

O neurônio artificial propõe um funcionamento análogo ao neurônio biológico, e é a unidade de processamento de informação fundamental para operação de uma RNA. A figura 3.6 mostra um modelo de neurônio artificial em que se pode verificar os cinco elementos básicos que o compõem que serão, em seguida, descritos: um conjunto de sinapses ou elos de conexão, um somador, o *bias*, uma função de ativação e uma saída.

FIGURA 3.6. MODELO DE UM NEURÔNIO ARTIFICIAL



FONTE: HAYKIN (2001)

- a) sinapses ou elos de conexão: são caracterizados por um peso ou força própria (w_{ki});
- b) somador (V_k): tem a função de somar os sinais de entrada, ponderado pelas respectivas sinapses ou pesos do neurônio. A equação 3.1, a seguir, representa este somatório:

$$v_k = \sum_{i=1}^m X_i W_{ki} \quad (3.1)$$

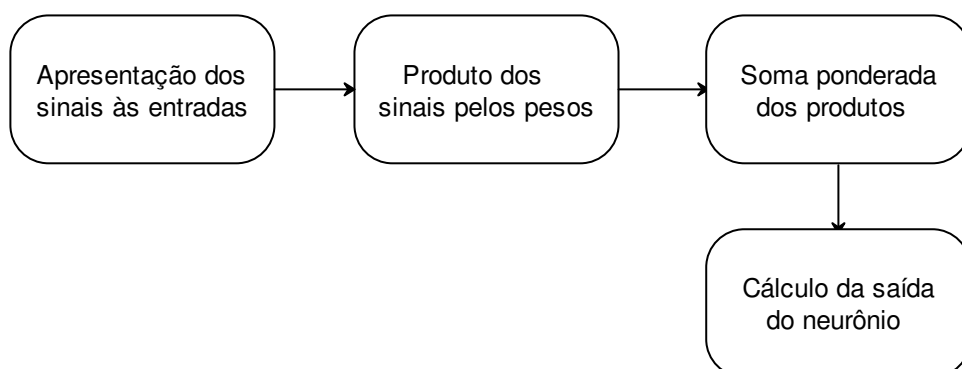
onde: W_{ki} = pesos do neurônio k; X_i = sinais de entrada; m = número de entradas.

- c) função de ativação (ϕ): tem a função de limitar o sinal de saída a um valor finito.
- d) *bias* (b_k): trata-se de uma entrada adicional acrescida ao neurônio artificial. Seu valor de entrada é fixado em "1", e seu peso é ajustável como os demais pesos da rede.
- e) saída (v_k): é expressa pela equação 3.2, a seguir.

$$y_k = \phi(v_k + b_k) \quad (3.2)$$

Resumidamente, um neurônio artificial opera de acordo com o diagrama apresentado na figura 3.7, a seguir.

FIGURA 3.7. DIAGRAMA DE FUNCIONAMENTO DE UM NEURÔNIO ARTIFICIAL




3.1.3 Função de Ativação de uma Rede Neural Artificial

Segundo STEINER (2005), a função de ativação é muito importante para o comportamento de uma RNA, porque é ela que define a saída do neurônio artificial e, portanto, o caminho pelo qual a informação é conduzida.

Existem vários tipos de funções de ativação, dentre os quais se destacam como principais: a função degrau que produz uma saída binária; a função linear; a função sigmoidal, que é não-linear crescente e diferenciável. A figura 3.8, a seguir, traz as representações gráficas destas três funções de ativação.

FIGURA 3.8. FUNÇÕES DE ATIVAÇÃO DE UMA RNA



FONTE: HAYKIN (2001)

As funções de ativação ilustradas na figura 3.8 têm suas correspondentes equações (HAYKIN, 2001) mostradas em (3.3), (3.4), (3.5) e (3.6), respectivamente:

$$\text{a) Função degrau ou } \textit{Threshold}: \varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (3.3)$$

$$\text{b) Função Linear:} \quad \varphi(v) = \begin{cases} 1 & \text{se } v \geq \frac{1}{2} \\ v, & \text{se } \frac{1}{2} > v > -\frac{1}{2} \\ 0 & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (3.4)$$

c) Função sigmoidal, que pode apresentar um dos seguintes tipos:

- função logística :
$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3.5)$$

onde a é o parâmetro de inclinação da função sigmóide. Assume valores entre "0" e "1".

- função tangente hiperbólica:
$$\varphi(v) = \tanh(v) \quad (3.6)$$


que pode assumir valores negativos.

3.1.4 Arquitetura de uma Rede Neural Artificial

Os neurônios que constituem uma RNA podem ser organizados em camadas e de diversas maneiras. A este arranjo entre os neurônios e suas respectivas conexões dá-se o nome de topologia ou arquitetura da rede. Em função do sentido do fluxo de dados, as redes podem ser classificadas em: *feed-forward* ("alimentadas" adiante) em que os dados só se propagam para frente e *feedback* (recorrentes), se os dados podem se propagar nos dois sentidos. De acordo com HAYKIN (2001), existem três diferentes tipos de arquiteturas:

- Rede neural com uma única camada alimentada adiante (*feed-forward*): a figura 3.9 mostra o modelo desta arquitetura. É importante notar que a denominação de camada única se dá pelo fato de não ocorrer nenhum processamento na camada de entrada nem na camada de pesos. Tal processamento ocorre exclusivamente na camada de saída, daí a sua denominação.

FIGURA 3.9. MODELO DE REDE NEURAL COM UMA CAMADA



- Rede neural com múltiplas camadas alimentadas adiante (*feed-forward*): as figuras 3.10 e 3.11 ilustram este tipo de rede. Na primeira, tem-se uma rede com duas camadas – uma oculta outra de saída. A segunda ilustra

uma rede com três camadas – duas ocultas e uma de saída. Mais uma vez cabe ressaltar que, para denominar as redes, só se levam em conta as camadas onde ocorre processamento; logo, desconsideram-se a camada de entrada e as de pesos.

FIGURA 3.10. MODELO DE REDE NEURAL COM DUAS CAMADAS



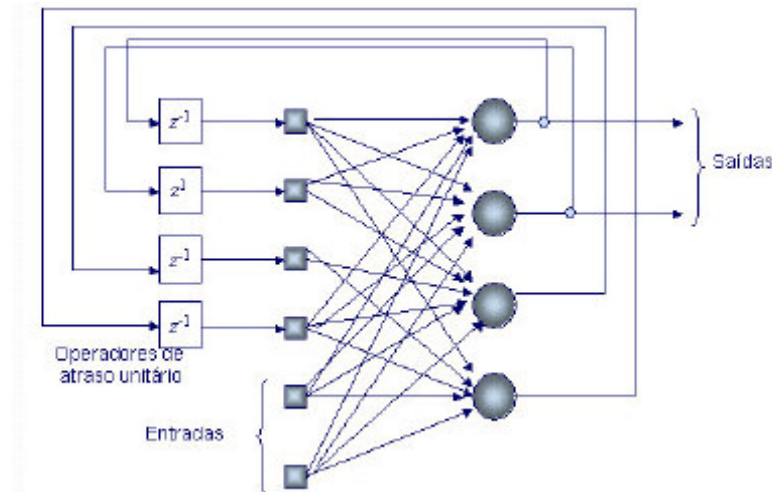


FIGURA 3.11. MODELO DE REDE NEURAL COM TRÊS CAMADAS



- c) Rede neural recorrente (*feedback*): caracteriza-se pela apresentação de pelo menos uma laço de realimentação. Este tipo de rede é ilustrado na figura 3.12, a seguir.

FIGURA 3.12. MODELO DE REDE NEURAL RECORRENTE



FONTE: HAYKIN (2001)

3.1.5 Treinamento de uma Rede Neural Artificial

Treinar uma rede neural consiste em balancear os pesos das conexões entre seus neurônios de maneira que ela execute uma tarefa específica. Este treinamento é feito a partir dos atributos escolhidos para o problema, que geram os sinais a serem processados nos neurônios da rede, conduzindo-a ao aprendizado por experiência. Segundo HAYKIN (2001), o aprendizado de uma rede pode ser feito de duas maneiras distintas:

- a) Treinamento supervisionado: utilizado quando se conhece, para todos os vetores de entrada de dados, as respectivas saídas (respostas desejadas). Para que ocorra o aprendizado, todos os padrões são apresentados individualmente à rede e, a partir de cálculos de comparação do valor da saída da rede (valor obtido) com o valor desejado (valor real), os pesos entre os neurônios são ajustados. Este processo de apresentação dos padrões à rede, seguido do balanceamento dos pesos, é repetido inúmeras vezes (iterações) até que o erro atingido esteja dentro do limite

aceitável ou estabilizado indicando, neste caso, que a RN atingiu um mínimo local.

- b) Treinamento não-supervisionado: utilizado quando só se conhece o conjunto de entrada de dados. Este tipo de treinamento, também conhecido como treinamento auto-supervisionado, busca classificar os dados de entrada a partir de algum critério de semelhança, extraindo quaisquer propriedades estatísticas dos dados e utilizando os neurônios como classificadores.

3.1.6 Redes de Múltiplas Camadas ou Redes *Feed-forward*

Em toda rede *feed-forward*, conforme ilustrado nas figuras 3.10 e 3.11 anteriores, podem ser observadas as seguintes unidades básicas:

- a) Entradas: encarregam-se de receber as informações do meio externo. Uma rede neural deve possuir o número de entradas igual ao número de coordenadas do vetor de entrada de dados. Este número é obtido a partir da análise dos atributos do problema estudado. Nesta unidade básica não ocorre o processamento de informações.
- b) Camadas intermediárias ou camadas escondidas: não interagem diretamente com o ambiente, mas têm a importante função de processar as informações vindas da camada anterior e enviar o resultado deste processamento à camada seguinte, auxiliando no ajuste dos pesos sinápticos da rede.
- c) Camada de saída: recebe informações da camada anterior, processa-as e as envia, ao meio externo, o resultado do *processamento*.

As redes *feed-forward* podem ser treinadas com o algoritmo *back-propagation* a fim de encontrar um erro mínimo. Este procedimento, porém, pode conduzir a um erro mínimo local e não global como o desejado. Para se evitar este impasse, deve-se variar o conjunto de pesos iniciais, o número de neurônios na camada escondida

ou até mesmo o número de camadas escondidas buscando-se, assim, diferentes maneiras de encontrar a melhor solução para o problema.

Estas redes normalmente utilizam a função de ativação logística sigmoideal, expressa em (3.5), que fornece saídas entre no intervalo (0, 1) para entradas no intervalo $(-\infty, \infty)$.

Far-se-á, a seguir, uma descrição de todos os passos do algoritmo *back-propagation* que, basicamente, divide-se em duas fases: a propagação *forward* (para frente) e *backward* (para trás).

Iniciando a propagação *forward*, em que todos os padrões descritos por suas coordenadas x_j^p , serão apresentados à rede, verifica-se que qualquer unidade i da rede recebe os sinais de entrada e os agrupa na expressão (3.7) (STEINER, 2005).

$$i_i^p = \sum_{j=1}^n w_{ij} x_j^p + \theta_i, \quad i = 1, \dots, k \quad (3.7)$$

onde i_i^p é a entrada do padrão p para o neurônio i ; k é o número de neurônios na camada escondida; w_{ij} é o peso conexão entre as unidades i e j ; n é o número de sinais de entrada na rede; x_j^p são as coordenadas do padrão p ; θ_i é o *bias* do neurônio i .

Com base no resultado obtido de (3.7) e utilizando a função de transferência logística sigmoideal, cada unidade i gera um sinal de saída a_i^p , expresso na função (3.8).

$$a_i^p = \frac{1}{1 + e^{-i_i^p}} \quad (3.8)$$

Os sinais de saída gerados em (3.8) são enviados para a camada h e agregados em i_h^p conforme (3.9).

$$i_h^p = \sum_{i=1}^k w_{hi} a_i^p + \theta_{hi} \quad (3.9)$$

onde i_h^p é a entrada para o neurônio h ; w_{hi} é o peso da conexão entre as unidades h e i ; θ_{hi} é o *bias* do neurônio h .

A partir desses sinais, e utilizando a função de transferência logística sigmoideal, obtém-se a saída a_h^p da rede em (3.10).

$$a_h^p = \frac{1}{1 + e^{-i_h^p}} \quad (3.10)$$

Este valor obtido a_h^p , para o padrão p , é comparado com o valor da saída d_p , calculando-se o erro quadrático, conforme (3.11).

$$E = \sum_p E^p = \frac{1}{2} \sum_p (d_p - a_h^p)^2 \quad (3.11)$$

Segundo STEINER (2005), é o vetor de pesos W que constitui o que a rede neural “sabe” e também quem determina como ela responderá a qualquer entrada arbitrária do meio ambiente.

Terminada a primeira fase (propagação *forward*) mostra-se, a seguir, a propagação *backward*, que executa o gradiente descendente em W a fim de localizar a solução ótima.

Segundo STEINER (2005), encontra-se primeiramente a variação dos pesos w_{hi} conforme (3.12).

$$\Delta_p w_{hi} = -\gamma \frac{\partial E_p}{\partial w_{hi}} \quad (3.12)$$

onde γ é a taxa de aprendizagem, tal que $0 < \gamma < 1$.

$$\begin{aligned} \text{como } \frac{\partial E_p}{\partial w_{hi}} &= -(d_p - a_h^p) \left[\frac{(e^{-ip} a_i^p)}{(1 + e^{-ip})^2} \right] \\ \frac{\partial E_p}{\partial w_{hi}} &= \left[\frac{-1}{(1 + e^{-ip})} \right] \left[\frac{(e^{-ip})}{(1 + e^{-ip})^2} \right] [a_i^p (d_p - a_h^p)] \\ \frac{\partial E_p}{\partial w_{hi}} &= -a_h^p (1 - a_h^p) a_i^p (d_p - a_h^p) \end{aligned}$$

$$\text{Então, } \Delta_p w_{hi} = \gamma a_h^p (1 - a_h^p) a_i^p (d_p - a_h^p)$$

Considerando na variação dos pesos para o padrão atual t a troca de pesos obtida no padrão anterior $(t-1)$, tem-se (3.13).

$$\Delta_p w_{hi}(t) = \gamma a_h^p (1 - a_h^p) a_i^p (d_p - a_h^p) + \alpha w_{hi}(t-1) \quad (3.13)$$

onde α é a constante que determina o efeito na troca de pesos em $(t-1)$. Desta forma, obtêm-se os pesos atualizados entre a camada escondida e a camada de saída como em (3.14).

$$w_{hi}(t) = w_{hi}(t-1) + \Delta_p w_{hi}(t) \quad (3.14)$$

O próximo passo é atualizar os pesos entre as entradas e a camada intermediária (STEINER, 2005) :

$$\Delta_p w_{ij} = -\gamma \frac{\partial E_p}{\partial w_{ij}}$$

$$\Delta_p w_{ij} = -(d_p - a_h^p) \left[\frac{\left(-(-e_h^{-ip}) \frac{\partial i_h^p}{\partial w_{ij}} \right)}{(1 + e_h^{-ip})^2} \right]$$

como:

$$\frac{\partial i_h^p}{\partial w_{ij}} = w_{hi} \frac{\partial a_i^p}{\partial w_{ij}}$$

$$\frac{\partial a_i^p}{\partial w_{ij}} = \frac{e_i^{-ip} \frac{\partial i_i^p}{\partial w_{ij}}}{(1 + e_i^{-ip})^2}$$

$$\frac{\partial i_i^p}{\partial w_{ij}} = x_j^p$$

Então, após as devidas substituições, tem-se:

$$\frac{\partial a_i^p}{\partial w_{ij}} = \frac{e_i^{-ip} x_j^p}{(1 + e_i^{-ip})^2} \quad \text{e} \quad \frac{\partial i_i^p}{\partial w_{ij}} = w_{hi} \left[\frac{(e_i^{-ip}) x_j^p}{(1 + e_i^{-ip})^2} \right]$$

Assim,

$$\Delta_p w_{ij}(t) = \gamma (d_p - a_h^p) \left[\frac{(e_h^{-ip})}{(1 + e_h^{-ip})^2} \right] w_{hi} \left[\frac{(e_i^{-ip}) x_j^p}{(1 + e_i^{-ip})^2} \right]$$

$$\Delta_p w_{ij}(t) = \gamma (d_p - a_h^p) a_h^p (1 - a_h^p) w_{hi} a_i^p (1 - a_i^p) x_j^p$$

Considerando na variação dos pesos para o padrão atual t a troca de pesos obtida no padrão anterior $(t-1)$, tem-se (3.15).

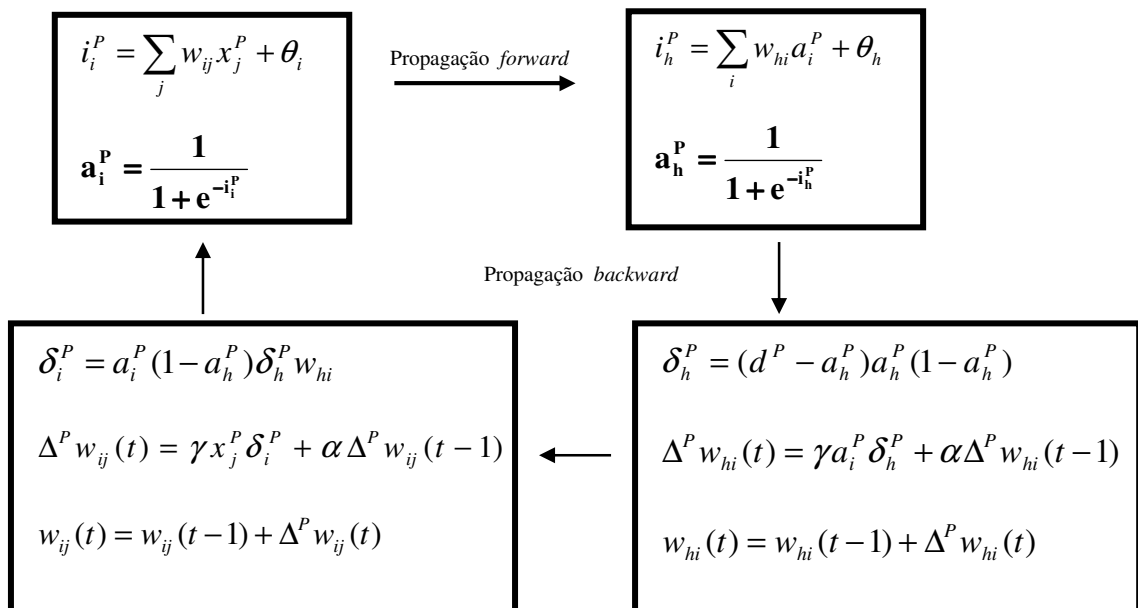
$$\Delta_p w_{ij}(t) = \gamma (d_p - a_h^p) a_h^p (1 - a_h^p) w_{hi} a_i^p (1 - a_i^p) x_j^p + \alpha \Delta_p w_{ij}(t-1) \quad (3.15)$$

Desta forma, obtêm-se os pesos atualizados $w_{ij}(t)$ entre a camada de entrada e a camada escondida como em (3.16).

$$w_{ij}(t) = w_{ij}(t-1) + \Delta_p w_{ij}(t) \quad (3.16)$$

A figura 3.13, a seguir, mostra o esquema do algoritmo *back-propagation*, para $h=1$, ou seja, para uma saída.

FIGURA 3.13. ILUSTRAÇÃO DAS PROPAGAÇÕES *FORWARD* E *BACKWARD* DO ALGORITMO *BACK-PROPAGATION*



onde: p = padrão; t = iteração; γ = taxa de aprendizagem; α = taxa de momento; w_{ij} e w_{hi} = pesos entre as camadas de entrada-oculta e oculta-saída, respectivamente; i^P = potencial interno do processador; x_j^P = *input* para o padrão p ; a^P = *output* para o padrão p ; d^P = valor desejado para o padrão p .

Encontram-se, respectivamente nos apêndices IV e V a resolução de um exemplo numérico de uma RNA com uma única camada, e com duas camadas, ambas utilizando o algoritmo *back-propagation*, e a função de transferência sigmoïdal.

3.2. ANÁLISE DE COMPONENTES PRINCIPAIS

3.2.1 Introdução

A Análise de Componentes Principais (ACP) é uma técnica de análise estatística multivariada que está relacionada com a explicação da estrutura de covariância por meio de combinações lineares das variáveis originais em estudo. Consiste numa transformação de eixos, tornando as novas variáveis não-correlacionadas. Os objetivos gerais desta análise são a redução da dimensão original e a facilitação da interpretação das análises realizadas (JOHNSON e WICHERN, 2002).

Segundo MARQUES (2005), a ACP é uma técnica utilizada para investigar as relações entre um conjunto de p variáveis correlacionadas e transformar o conjunto de variáveis originais em um novo conjunto de variáveis não-correlacionadas. As novas variáveis, as componentes principais, são combinações lineares das variáveis originais e são derivadas em ordem decrescente de importância tal que, por exemplo, a 1ª componente principal é a combinação linear normalizada com variância máxima.

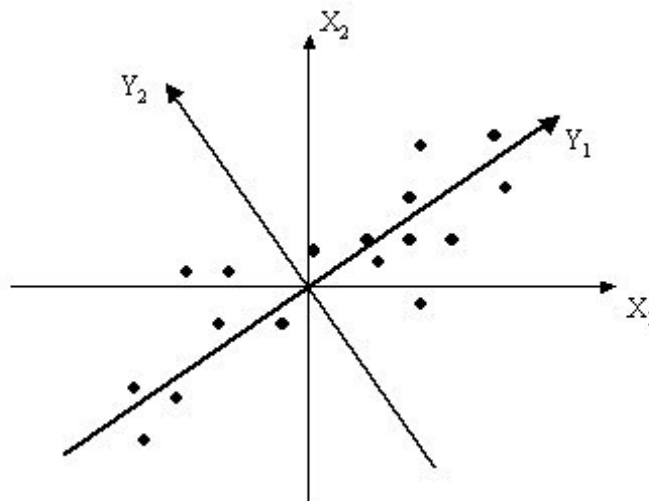
A explicação da variabilidade total de um sistema de p variáveis geralmente só pode ser explicada por p componentes principais. Porém, grande parte desta variabilidade pode ser expressa por k componentes, tal que $k < p$. É importante ressaltar que o desenvolvimento das componentes principais não requer pressuposições de normalidade multivariada.

3.2.2 Componentes Principais Populacionais

Algebricamente as componentes principais Y_1, Y_2, \dots, Y_p representam combinações lineares de p variáveis aleatórias X_1, X_2, \dots, X_p do vetor aleatório \underline{X} . Geometricamente estas combinações lineares representam a seleção de um novo sistema de eixos coordenados, obtido pela rotação do sistema de eixos original. Os novos eixos representam as direções com variabilidade máxima (JOHNSON e WICHERN, 2002).

A figura 3.14 mostra geometricamente os sistemas de coordenadas original (X_1, X_2) e de componentes principais (Y_1, Y_2) para $p = 2$.

FIGURA 3.14. REPRESENTAÇÃO GEOMÉTRICA DE COMPONENTES PRINCIPAIS



FONTE: JOHNSON e WICHERN (2002)

onde:

X_1 e X_2 são eixos originais e

Y_1 e Y_2 são novos eixos (eixos originais rotacionados: centrado na média amostral).

As componentes principais são obtidas a partir da matriz de covariância Σ , ou da matriz de correlação ρ e das variáveis X_1, X_2, \dots, X_p .


autovalor próximo de zero, em geral, indica uma dependência linear no conjunto de dados.

Segundo JOHNSON e WICHERN (2002), um método muito utilizado para determinar quantas componentes devem permanecer foi estabelecido em 1960, por Kaiser. Para ele, mantêm-se somente as componentes cujos autovalores são superiores a um.

Outro critério é estabelecer a permanência das n primeiras componentes ($n < p$), de acordo com a variação cumulativa que elas explicam. Uma variação cumulativa com um bom grau de explicação é superior a 75%. Fica, porém, a cargo do usuário julgar a necessidade de variação a ser explicada.

Também é possível a utilização do *scree plot* (gráfico de cotovelos) como uma ferramenta visual para auxiliar a determinação do número suficiente de componentes a ser retido. Na figura 3.15 pode-se observar a formação de um cotovelo próximo à posição $i = 6$. Isto mostra que os componentes acima de λ_5 são relativamente pequenos quando comparados com os anteriores, o que leva a concluir que as cinco primeiras componentes são suficientes para resumir a variação total do sistema.

FIGURA 3.15. SCREE PLOT COM OITO COMPONENTES PRINCIPAIS



CAPÍTULO IV

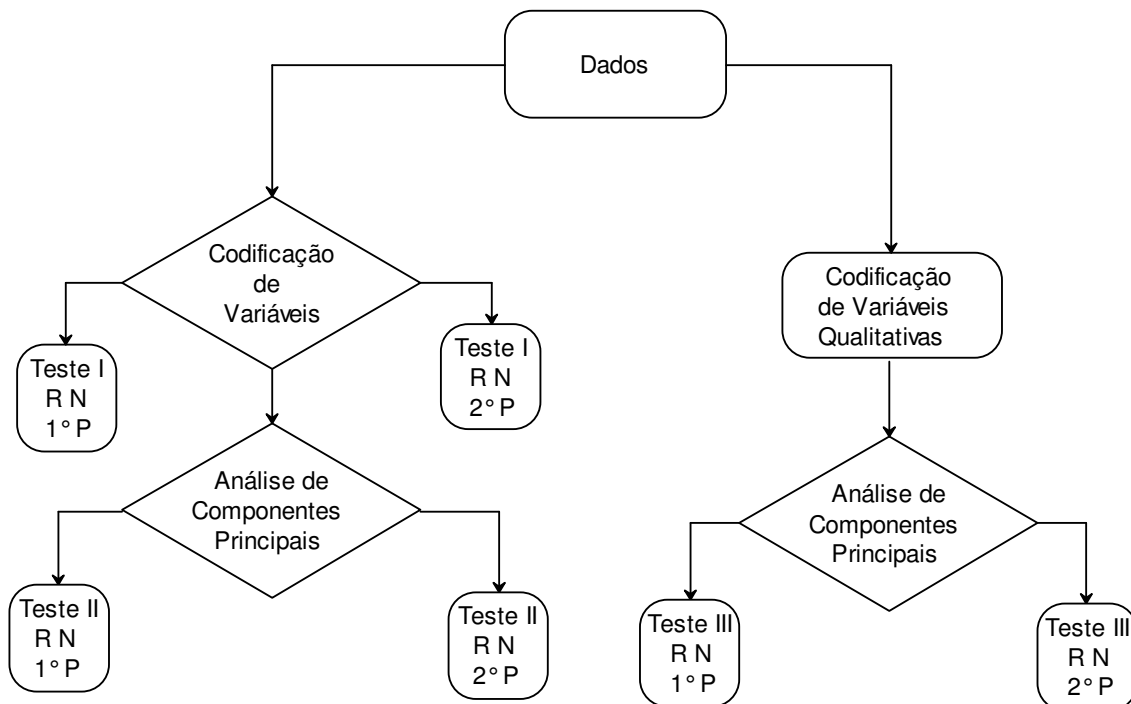
4. IMPLEMENTAÇÃO DAS TÉCNICAS PARA RESOLUÇÃO DO PROBLEMA E ANÁLISE DOS RESULTADOS

4.1 IMPLEMENTAÇÃO DAS TÉCNICAS PARA RESOLUÇÃO DO PROBLEMA

Os dados utilizados no presente trabalho foram obtidos junto à 1ª Vara do Trabalho de São José dos Pinhais – Paraná, conforme já comentado no capítulo II deste trabalho. Foram analisados 100 processos que já tiveram suas sentenças emitidas no período compreendido entre os anos de 1998 e 2005. De cada processo foram extraídos os atributos que compõem o vetor de entrada para a rede neural.

As técnicas propostas neste trabalho foram implementadas segundo o fluxograma ilustrado na figura 4.1, a seguir.

FIGURA 4.1. FLUXOGRAMA DE IMPLEMENTAÇÃO DAS TÉCNICAS ENVOLVIDAS



Legenda:

RN 1º P – Redes Neurais aplicando o 1º Processo à saída.

RN 2º P – Redes Neurais aplicando o 2º Processo à saída.

Conforme ilustrado neste fluxograma, após a coleta, os dados foram codificados de maneira que cada um dos atributos correspondesse a uma ou mais coordenadas binárias do vetor de entrada da rede neural. Tal codificação, conforme descrito no capítulo II, tem por objetivo:

- a) estabelecer “valores” para as variáveis qualitativas do tipo nominal, que, neste trabalho, são: objeto do processo – subdividido em falta de registro em carteira profissional, horas extras, fundo de garantia por tempo de serviço, verbas rescisórias, seguro desemprego, vale transporte, adicional de insalubridade, multa do Art. 477, adicional noturno, diferenças salariais, multa do Art. 467 e indenização por danos morais –, tipo de rito, perícia, acordo, profissão, recurso ordinário e recurso de revista.
- b) transformar variáveis quantitativas em qualitativas do tipo ordinal. Neste trabalho são as seguintes: salário do reclamante, tempo de serviço e número de audiências.

No Apêndice VI encontram-se as codificações de todos os atributos, tornando-os binários.

Para realizar o treinamento de todas as redes neurais, foi desenvolvido um programa no *Software Visual Basic 6.0*, utilizando o algoritmo *back-propagation*. A topologia adotada varia em cada um dos testes, porém em todas elas se tem uma camada de entrada, uma camada escondida e um neurônio na saída. A opção por apenas uma camada escondida é baseada no Teorema da Aproximação Universal (HAYKIN, 2001), que afirma que uma única camada é suficiente para um *perceptron* de múltiplas camadas computar aproximação uniforme para um dado conjunto de treinamento, representado pelo conjunto de entradas, e a saída desejada.

A função de ativação utilizada neste estudo, tanto na camada oculta quanto na camada de saída foi a logística sigmoideal, conforme já comentado, que fornece saídas em $(0, 1)$ para entradas em $(-\infty, +\infty)$. Assim, foi necessário enquadrar as saídas que variam de 2 a 94 meses ao intervalo de $(0, 1)$. Conforme já comentado no final da seção 2.2.2, o primeiro processo de ajuste da saída da rede à função de

ativação se obteve a partir da divisão do tempo de processo por 94, uma vez que este é o maior valor do espaço amostral. O segundo processo baseou-se no fato de que a amostra das saídas, conforme observado no histograma, apresentava uma distribuição normal. Assim, para cada valor foi obtida a distribuição normal cumulativa.

Para avaliar o desempenho da rede neural, tanto no grupo de treinamento quanto no grupo de testes, adotou-se o RMSE, que é a raiz quadrada do erro quadrático médio (MSE). O cálculo do RMSE é obtido pela expressão (4.1), a seguir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (d_i^p - a_i^p)^2}{n}} \quad (4.1)$$

onde d_i^p é a saída desejada para o padrão p (valor real), a_i^p é a saída para o padrão p (obtida pela rede) e n é o número de padrões a serem avaliados.

Os 100 processos que compunham a amostra foram divididos aleatoriamente, em dois conjuntos. O primeiro, chamado conjunto de treinamento, é composto de 75% dos processos analisados, cuja função é de treinar a rede. A partir desta amostra de 75 processos, realiza-se o treinamento supervisionado da rede, ressaltando-se que para cada vetor de entrada de dados (que contém todos os atributos de um processo) já se conhece a saída. A saída obtida pela rede é comparada com a saída desejada (real) e através da propagação *backward*, o algoritmo *back-propagation* atualiza todos os pesos da rede.

Uma iteração do algoritmo consiste em apresentar todos os padrões do conjunto de treinamento à rede. O número de iterações (ou épocas) que serão executadas pode ser igual a um número previamente determinado, ou quando o *RMSE* atingir um valor satisfatório (que também tenha sido anteriormente estabelecido).

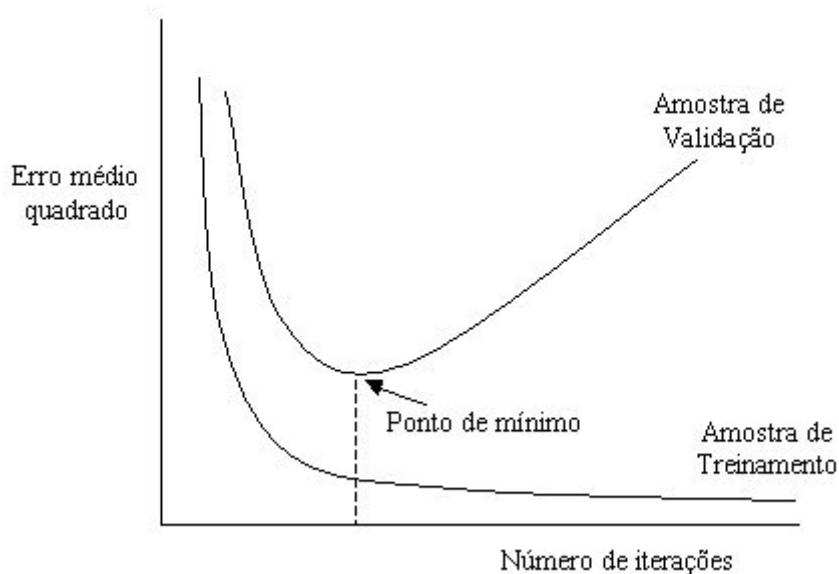
O segundo conjunto de processos, composto pelos 25% processos restantes, é denominado conjunto de testes e é utilizado para verificar, através do *RMSE*, o grau de aprendizado da rede. A partir do conjunto final de pesos obtidos no treinamento da rede, a propagação *forward* calcula a saída para cada um dos

padrões deste conjunto de testes. Com os valores obtidos pela rede e sabendo-se os valores reais, calcula-se o *RMSE* deste conjunto.

As curvas de aprendizagem relativas aos conjuntos de treinamento e teste são distintas. Geralmente o modelo funciona melhor com o conjunto sobre o qual foi projetado, ou seja, sobre o conjunto de treinamento.

A curva de aprendizagem sobre o conjunto de treinamento decresce monotonamente com o aumento de iterações. Distintamente, no conjunto de testes, a curva decresce monotonamente para um mínimo e então começa a crescer conforme aumenta o número de iterações. Na figura 4.2, a seguir, pode-se observar o comportamento das curvas de aprendizagem dos conjuntos de treinamento (Amostra de Treinamento) e de teste (Amostra de Validação).

FIGURA 4.2. TREINAMENTO VERSUS CAPACIDADE DE GENERALIZAÇÃO DA RNA



FONTE: HAYKIN (2001)

Foi escolhida uma nomenclatura para cada topologia a fim de representar na seqüência as seguintes características: quantidade de entradas, número de neurônios na camada escondida e número de iterações. A rede E32N1I40, por exemplo, é uma rede com 32 entradas, 1 neurônio na camada escondida e que foi treinada com 40 iterações.

Buscando minimizar o erro das RNA foram realizados três testes distintos. No primeiro teste todas as entradas da rede foram codificadas conforme descrito no capítulo II. No segundo teste, além da codificação realizada no teste anterior, foi aplicada a ACP. No último teste também foi aplicada a ACP, porém só foram codificadas as variáveis nominais.

Nos três testes realizados todas as redes neurais foram submetidas a quatro grupos distintos de pesos iniciais, a fim de diminuir a probabilidade de se ficar “preso” a um erro mínimo local. Assim, a utilização de grupos de pesos iniciais distintos tem por finalidade aumentar a chance de se encontrar o erro mínimo global.

4.1.1 Teste I

Neste teste as redes neurais foram treinadas utilizando a codificação de todos os atributos. Assim, cada padrão apresenta um vetor de entrada com 32 coordenadas binárias. As saídas foram ajustadas ao intervalo de abrangência da função logística sigmoideal através dos dois processos enunciados anteriormente. Desta maneira, o teste em questão ficou dividido em outros dois: Teste I do primeiro processo e Teste I do segundo processo.

Com a camada de entrada já definida com 32 neurônios e a camada de saída também definida, contando com apenas um neurônio, restava definir quantos neurônios comporiam a camada escondida. Com este objetivo, primeiramente fez-se variar de 1 até 14 o número de neurônios na camada oculta. Cada uma destas topologias foi treinada com 50 iterações. A rede neural que apresentou melhor resultado até então, voltou a ser treinada, porém variando-se o número de iterações, a fim de minimizar o erro no grupo de teste. Os dados relevantes encontram-se na tabelas 4.1 e 4.2, a seguir, onde verifica-se na primeira coluna o número da simulação, na segunda coluna a topologia adotada, na terceira coluna o erro do grupo de treinamento (RMSE Tr) e na quarta coluna o erro do grupo de testes (RMSE Tes).

TABELA 4.1. TOPOLOGIAS DO TESTE I DO PRIMEIRO PROCESSO

Simulação	Topologia	RMSE Tr	RMSE Tes
1	E32N1I50	0,05300	0,50700
2	E32N2I50	0,04930	0,46510
3	E32N3I50	0,04310	0,16490
4	E32N4I50	0,04390	0,15630
5	E32N5I50	0,04100	0,13180
6	E32N6I50	0,03580	0,10110
7	E32N7I50	0,03850	0,22190
8	E32N8I50	0,03100	0,08890
9	E32N9I50	0,03230	0,10080
10	E32N10I50	0,03420	0,19350
11	E32N11I50	0,03500	0,33120
12	E32N12I50	0,03400	0,09470
13	E32N13I50	0,03460	0,10530
14	E32N14I50	0,03470	0,15540

A partir da tabela 4.1 verifica-se que a melhor arquitetura é a que apresenta oito neurônios na camada escondida, já que nesta topologia o RMSE para o conjunto de testes é o igual a 0,0889, ou seja, a RNA apresenta melhor generalização.

TABELA 4.2. TOPOLOGIAS DO TESTE I DO SEGUNDO PROCESSO

Simulação	Topologia	RMSE Tr	RMSE Tes
1	E32N1I50	0,07323	0,37367
2	E32N2I50	0,07363	0,31984
3	E32N3I50	0,06300	0,13749
4	E32N4I50	0,05784	0,18521
5	E32N5I50	0,04417	0,23619
6	E32N6I50	0,05484	0,10432
7	E32N7I50	0,05137	0,25062
8	E32N8I50	0,04745	0,15619
9	E32N9I50	0,04253	0,13712
10	E32N10I50	0,03435	0,14541
11	E32N11I50	0,04602	0,27232
12	E32N12I50	0,04080	0,14424
13	E32N13I50	0,04557	0,18309
14	E32N14I50	0,04329	0,16062

Da tabela 4.2 anterior conclui-se, através do RMSE do grupo de testes, que quando a saída é tratada como uma distribuição normal (2º Processo), o melhor resultado é obtido a partir de uma rede com seis neurônios na camada escondida, onde o RMSE do conjunto de teste é igual a 0,10432, ou seja, o menor valor obtido.

Comparando-se as tabelas 4.1 e 4.2, conclui-se que os melhores resultados são obtidos a partir do primeiro processo, ou seja, quando as saídas reais são divididas por 94.

Verificadas quais as melhores arquiteturas para as redes nos dois processos, cada uma delas voltou a ser treinada, porém desta vez variando-se o número de iterações, a fim de atingir o menor RMSE no grupo de teste. Listam-se a seguir, nas tabelas 4.3 e 4.4, os valores relevantes deste treinamento.

TABELA 4.3. RESULTADOS NUMÉRICOS DAS SIMULAÇÕES COM VARIAÇÃO DO NÚMERO DE ITERAÇÕES NO PRIMEIRO PROCESSO.

SIMULAÇÃO	TOPOLOGIA	PRIMEIRO PROCESSO	
		RMSE Tr	RMSE Tes
1	E32N8I10	0,09330	0,09830
2	E32N8I20	0,05460	0,09210
3	E32N8I30	0,04050	0,08810
4	E32N8I40	0,03450	0,08770
5	E32N8I50	0,03100	0,08890
6	E32N8I60	0,02840	0,09050
7	E32N8I70	0,02640	0,09230
8	E32N8I80	0,02480	0,09400
9	E32N8I90	0,02360	0,09550
10	E32N8I100	0,02250	0,09670
11	E32N8I110	0,02160	0,09770
12	E32N8I120	0,02080	0,09860
13	E32N8I130	0,02000	0,09930
14	E32N8I140	0,01930	0,09990
15	E32N8I150	0,01850	0,10050
16	E32N8I200	0,01560	0,10260
17	E32N8I300	0,01200	0,10650
18	E32N8I400	0,00990	0,10990
19	E32N8I500	0,00850	0,11280
20	E32N8I750	0,00610	0,11910
21	E32N8I1000	0,00460	0,12440

Nas simulações descritas na tabela 4.3, verifica-se que, quando se trabalha no primeiro processo, o RMSE do conjunto de treinamento diminui monotonamente, desde 0,0933 (com 10 iterações) até 0,0046 (com 1000 iterações). Por outro lado, no conjunto de testes, este erro começa com 0,0983 quando se têm 10 iterações, diminui até atingir o valor mínimo (0,0877), com 40 iterações; e a partir daí aumenta até o valor de 0,1244, com 1000 épocas. Este aumento do erro no grupo de teste após certo número de iterações ocorre devido ao excesso de treinamento, o que leva a rede a perder a capacidade de generalização entre os padrões de entrada-saída similares, prejudicando o seu desempenho, seguindo a curva ilustrada na figura 4.2.

TABELA 4.4. RESULTADOS NUMÉRICOS DAS SIMULAÇÕES COM VARIAÇÃO DO NÚMERO DE ITERAÇÕES NO SEGUNDO PROCESSO.

Simulação	TOPOLOGIA	SEGUNDO PROCESSO	
		RMSE Tr	RMSE Tes
1	E32N6I10	0,08650	0,11750
2	E32N6I20	0,07430	0,11020
3	E32N6I30	0,06720	0,10500
4	E32N6I40	0,06070	0,10350
5	E32N6I50	0,05480	0,10430
6	E32N6I60	0,04950	0,10630
7	E32N6I70	0,04460	0,10890
8	E32N6I80	0,04000	0,11160
9	E32N6I90	0,03580	0,11420
10	E32N6I100	0,03190	0,11630
11	E32N6I110	0,02850	0,11790
12	E32N6I120	0,02560	0,11940
13	E32N6I130	0,02300	0,12070
14	E32N6I140	0,02090	0,12210
15	E32N6I150	0,01900	0,12380
16	E32N6I200	0,01220	0,13490
17	E32N6I300	0,00610	0,15240
18	E32N6I400	0,00440	0,15830
19	E32N6I500	0,00370	0,16000
20	E32N6I750	0,00270	0,15950
21	E32N6I1000	0,00230	0,15900

Analogamente, nas simulações descritas na tabela 4.4, verifica-se a diminuição monótona e contínua do erro no conjunto de treinamento, e a diminuição até um mínimo no conjunto de teste. O melhor resultado para este teste é obtido na simulação 4, quanto a rede é treinada com 40 iterações, apresentando RMSE igual a 0,0607 no conjunto de treinamento e 0,1035 no conjunto de teste.

4.1.2 Teste II

Neste teste as redes neurais foram treinadas após a Análise de Componentes Principais (ACP), que teve como propósito avaliar a importância relativa das variáveis que compõem a amostra de dados.

A tabela 4.5 a seguir mostra as componentes principais, seus autovalores e variâncias. Vê-se, por exemplo, que quando se utilizam as componentes de número 1 até o 18 está se representando a estrutura de covariância inicial com uma fidelidade de 90,154%, ou seja, a perda de informações é de 9,846%.

TABELA 4.5. AUTOVALORES EM ORDEM DECRESCENTE

COMPONENTES		VARIÂNCIA	
NÚMERO	AUTOVALOR	PERCENTUAL	ACUMULADA
1	0,7303	13,648	13,648
2	0,6589	12,315	25,963
3	0,4852	9,068	35,031
4	0,3769	7,044	42,075
5	0,3504	6,55	48,625
6	0,2988	5,585	54,209
7	0,2685	5,018	59,227
8	0,2524	4,717	63,944
9	0,1999	3,736	67,679
10	0,1878	3,509	71,189
11	0,1781	3,328	74,517
12	0,1617	3,023	77,54
13	0,1467	2,741	80,281
14	0,1297	2,423	82,704
15	0,1238	2,313	85,018
16	0,1008	1,884	86,901

continua

continuação


COMPONENTES		VARIÂNCIA	
NÚMERO	AUTOVALOR	NÚMERO	AUTOVALOR
17	0,0903	1,688	88,589
18	0,0837	1,565	90,154
19	0,0746	1,394	91,548
20	0,0681	1,272	92,82
21	0,062	1,158	93,978
22	0,0539	1,008	94,986
23	0,0477	0,891	95,877
24	0,044	0,822	96,699
25	0,0396	0,739	97,438
26	0,0354	0,661	98,1
27	0,0318	0,594	98,693
28	0,0246	0,46	99,154
29	0,0213	0,398	99,552
30	0,0161	0,3	99,853
31	0,0079	0,147	100
32	0	0	100

Para realização da ACP, utilizou-se o *software STATIGRAPHICS plus 5.1*. Aplicando esta técnica ao conjunto de dados originais compostos por 32 variáveis, percebeu-se que as 31 primeiras componentes principais seriam suficientes para explicar a estrutura de covariância inicial sem perda de informação. O objetivo da aplicação da ACP nesse treinamento não era o de reduzir o número de variáveis. A redução de 32 para 31 variáveis só ocorreu porque a 32ª componente apresentava autovalor e variância nulos.

A figura 4.3, a seguir, ilustra a magnitude dos autovalores dos fatores das componentes principais. A partir do gráfico do *scree plot*, pode-se observar a formação de cotovelos próximos às posições $i = 10$ e $i = 16$. De acordo com a necessidade de fidelidade de informações que se quer manter, estipula-se o número de componentes a ser utilizado. Ao se definir o uso das 10 primeiras componentes principais, mantém-se uma fidelidade de informações em apenas 71,189%, em relação ao conjunto de dados original, porém reduz-se o número de componentes a 31,25% do original. Utilizando as 16 primeiras componentes, está se representando a estrutura de covariância inicial com uma fidelidade de 86,901 %, ou seja, a perda

de informações é de 13,099%; por outro lado, está sendo reduzida a cardinalidade do conjunto de dados a 50% do valor original.

FIGURA 4.3. AUTOVALORES VERSUS FATORES DA ACP.



A partir dessa análise, este teste treinou redes com 31,16 e 10 componentes principais. Analogamente ao teste I, as redes foram treinadas para dois tipos de processos, lembrando que o primeiro processo é aquele em que as saídas são divididas por 94; o segundo calcula a distribuição normal cumulativa para cada uma das saídas.

Para cada um dos dois processos de cada conjunto de entrada (31, 16 e 10 componentes principais), primeiramente se buscou o número de neurônios na camada oculta que apresentasse menor RMSE. Essa busca consistiu em treinar redes com 50 iterações e fazer variar o número de neurônios na camada escondida desde 1 até 14. Em seguida, com a arquitetura da rede já definida, variou-se o número de iterações de 10 até 1.000, buscando o menor erro possível no grupo de teste. Os resultados relevantes são apresentados nas tabelas 4.6 a 4.11, a seguir.

TABELA 4.6. TOPOLOGIAS DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 31 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E31N1I50	0,04921	0,54848	0,07362	0,39474
E31N2I50	0,05643	0,38851	0,07484	0,34312
E31N3I50	0,03957	0,12731	0,05516	0,15234
E31N4I50	0,04051	0,50734	0,05160	0,35032
E31N5I50	0,03918	0,29775	0,05181	0,33091
E31N6I50	0,02956	0,10070	0,04827	0,12023
E31N7I50	0,03546	0,08099	0,04696	0,11817
E31N8I50	0,03269	0,19859	0,04021	0,28929
E31N9I50	0,03047	0,22522	0,03943	0,16015
E31N10I50	0,03280	0,10441	0,03945	0,16895
E31N11I50	0,03591	0,17819	0,04817	0,16787
E31N12I50	0,03157	0,37781	0,03889	0,28104
E31N13I50	0,03250	0,08703	0,04132	0,12490
E31N14I50	0,02840	0,16052	0,03608	0,14287

Como se observa na tabela 4.6 anterior, foram testadas arquiteturas variando a camada escondida desde 1 até 14 neurônios. A topologia que apresentou menor erro, tanto no primeiro quanto no segundo processo, foi a E31N7I50, ou seja, a rede que consistia em 31 neurônios na camada de entrada e sete na camada oculta. Com a arquitetura já definida, variou-se o número de iterações a fim de se buscar o menor RMSE no grupo de teste. Tal resultado é apresentado na tabela 4.7, a seguir.

TABELA 4.7. NÚMERO DE ITERAÇÕES DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 31 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E31N7I1	0,20398	0,14454	0,24617	0,20364
E31N7I10	0,08514	0,12809	0,09332	0,11824
E31N7I20	0,05581	0,10970	0,07131	0,11477
E31N7I30	0,04520	0,09127	0,06215	0,11761
E31N7I40	0,03945	0,08343	0,05441	0,11817
E31N7I50	0,03546	0,08099	0,04696	0,11817
E31N7I60	0,03223	0,08054	0,04095	0,11931
E31N7I70	0,02943	0,08076	0,03651	0,12169

continua

TOPOLOGIA	continuação			
	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes		RMSE Tr
E31N7I80	0,02697	0,08122	0,03316	0,12478
E31N7I90	0,02479	0,08177	0,03056	0,12797
E31N7I100	0,02285	0,08236	0,02847	0,13092
E31N7I200	0,01216	0,08918	0,01718	0,14725
E31N7I500	0,00617	0,10249	0,00502	0,15901
E31N7I1000	0,00387	0,11103	0,00228	0,16407

A tabela 4.7 anterior, mostra que o melhor resultado deste treinamento foi obtido no primeiro processo, quando a rede neural contou com 60 iterações, visto que, neste caso, o RMSE do grupo de teste é de apenas 0,08054. O segundo processo apresentou o menor erro quando submetido a apenas 20 iterações, porém tal erro foi superior ao do primeiro processo. Vale lembrar que esse treinamento não buscou reduzir o número de variáveis. Assim, foi mantida a estrutura de covariância inicial com uma fidelidade de 100%, ou seja, a perda de informações é nula.

O próximo treinamento foi realizado utilizando apenas as 16 primeiras componentes principais. Tal procedimento garante uma fidelidade de informações de 86,901%, ou seja, uma perda de informações de 13,099%; por outro lado, a cardinalidade do conjunto de dados está sendo reduzida a 50% do valor original.

Observando a tabela 4.8 a seguir, pode-se notar que foi realizado o mesmo treinamento do caso anterior, ou seja, foram testadas arquiteturas variando a camada oculta desde 1 até 14 neurônios. Nesse caso a topologia que apresentou menor erro, tanto no primeiro quanto no segundo processo, foi a E16N2I50, ou seja, a rede composta de 16 neurônios na camada de entrada, dois neurônios na camada escondida, treinada com 50 iterações.

TABELA 4.8. TOPOLOGIAS DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 16 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E16N1I50	0,10346	0,45685	0,10256	0,35896
E16N2I50	0,10417	0,15570	0,09607	0,13298
E16N3I50	0,07658	0,19190	0,08653	0,38220
E16N4I50	0,07010	0,15675	0,07328	0,14682
E16N5I50	0,06869	0,17256	0,06455	0,21522
E16N6I50	0,07290	0,26326	0,07436	0,14649
E16N7I50	0,06103	0,18827	0,05560	0,18417
E16N8I50	0,05831	0,26699	0,06583	0,20779
E16N9I50	0,05572	0,20681	0,06583	0,20779
E16N10I50	0,06346	0,15586	0,07347	0,13611
E16N11I50	0,05470	0,19136	0,06323	0,18748
E16N12I50	0,05567	0,26493	0,05594	0,19873
E16N13I50	0,05610	0,22111	0,05855	0,16865
E16N14I50	0,06926	0,17168	0,06902	0,16099

A partir dessa arquitetura, variou-se o número de iterações, a fim de se buscar o menor RMSE no grupo de teste. Os resultados relevantes são apresentados na tabela 4.9, a seguir.

TABELA 4.9. NÚMERO DE ITERAÇÕES DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 16 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E16N2I1	0,21200	0,15942	0,26135	0,22565
E16N2I10	0,12593	0,10692	0,11471	0,20261
E16N2I20	0,11059	0,12846	0,10266	0,17346
E16N2I30	0,11050	0,13529	0,09938	0,15160
E16N2I40	0,10905	0,14146	0,09742	0,13866
E16N2I50	0,10417	0,15570	0,09607	0,13298
E16N2I60	0,09678	0,17538	0,09497	0,13164
E16N2I70	0,09081	0,19412	0,09374	0,13266
E16N2I80	0,08598	0,21063	0,09187	0,13544
E16N2I90	0,07947	0,22616	0,08918	0,13988
E16N2I100	0,06789	0,23828	0,08621	0,14574
E16N2I200	0,04132	0,27470	0,06899	0,18515
E16N2I500	0,03866	0,28087	0,06523	0,21815
E16N2I1000	0,03787	0,28564	0,05893	0,21673

Neste treinamento foram consideradas somente as 16 primeiras componentes principais, o que reduz a fidelidade de informações. Pode-se ratificar este dado ao comparar-se as tabelas 4.7 e 4.9. Na primeira, o menor RMSE de teste é igual a 0,08054; na segunda, tal valor sobe para 0,10692.

No último treinamento realizado neste teste, adotou-se o uso das 10 primeiras componentes principais, o que manteve a fidelidade de informações em apenas 71,189% em relação ao conjunto de dados original, porém com redução do número de componentes a 31,25% do original. Este treinamento foi análogo aos dois anteriores, e os resultados mais importantes encontram-se nas tabelas 4.10 e 4.11, a seguir.

TABELA 4.10. TOPOLOGIAS DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E10N1I50	0,12360	0,56867	0,13836	0,35437
E10N2I50	0,12349	0,17522	0,12692	0,35872
E10N3I50	0,09352	0,18186	0,10982	0,20510
E10N4I50	0,07638	0,22523	0,09608	0,30387
E10N5I50	0,08773	0,27429	0,07743	0,25224
E10N6I50	0,09307	0,19291	0,11057	0,21176
E10N7I50	0,09598	0,21033	0,09866	0,17389
E10N8I50	0,09803	0,28109	0,08932	0,29425
E10N9I50	0,08561	0,17527	0,08966	0,16646
E10N10I50	0,09416	0,18999	0,08640	0,22275
E10N11I50	0,08279	0,19947	0,08385	0,32635
E10N12I50	0,09694	0,18202	0,09899	0,19873
E10N13I50	0,07287	0,18012	0,06923	0,19823
E10N14I50	0,08616	0,29262	0,09083	0,29092

Pode-se verificar na tabela 4.10 anterior, que a melhor arquitetura deste treinamento apresenta, em ambos os processos, 10 neurônios na camada de entrada e 9 na camada escondida. De acordo com esta topologia, o primeiro processo apresenta RMSE igual a 0,17527 no grupo de teste, enquanto no segundo processo o menor erro no mesmo grupo é igual a 0,16646.

A partir da arquitetura definida no treinamento anterior, variou-se o número de iterações, buscando atingir o ponto de menor RMSE no grupo de teste. Mais uma vez se observa o comportamento típico das curvas de aprendizado dos grupos de treinamento e teste, tanto no primeiro quanto no segundo processo (figura 4.2). Ratifica-se também a perda de informações ao se desprezar algumas componentes principais. Observa-se que com 31 componentes principais atingiu-se, no primeiro processo, um erro igual a 0,08054 (tabela 4.7). Para 16 componentes principais atingiu-se, no mesmo processo, um erro igual a 0,10692 (tabela 4.9). Com apenas 10 componentes, como se observa na tabela 4.11, a seguir, o menor erro, no mesmo processo, é de 0,13636.

TABELA 4.11. NÚMERO DE ITERAÇÕES DO TESTE II DO PRIMEIRO E SEGUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E10N9I1	0,21251	0,14822	0,26539	0,20741
E10N9I10	0,13724	0,13636	0,13376	0,18269
E10N9I20	0,12024	0,15300	0,12186	0,17069
E10N9I30	0,11034	0,16075	0,11093	0,16723
E10N9I40	0,09848	0,16718	0,10004	0,16436
E10N9I50	0,08561	0,17527	0,08966	0,16646
E10N9I60	0,07438	0,18161	0,07981	0,17420
E10N9I70	0,06589	0,18379	0,07052	0,18309
E10N9I80	0,05950	0,18274	0,06214	0,18994
E10N9I90	0,05461	0,18090	0,05551	0,19429
E10N9I100	0,05086	0,17975	0,05073	0,19642
E10N9I200	0,03340	0,18235	0,03253	0,17900
E10N9I500	0,01943	0,18482	0,01461	0,18040
E10N9I1000	0,01017	0,20399	0,01143	0,20056

4.1.3 Teste III

Neste teste as variáveis ordinais originais não foram codificadas, ou seja, os atributos salário, tempo de serviço e número de audiências não foram transformados em vetores binários conforme os testes anteriores. Assim, cada vetor de entrada de dados apresenta 24 coordenadas. Utilizando o mesmo banco de dados dos testes

anteriores, conta-se com 100 processos, gerando uma matriz de dados com 100 linhas e 24 colunas.

Esta matriz de dados foi submetida ao processo de análise de componentes principais a fim de avaliar a importância relativa das variáveis que a compõem. Na tabela 4.12, a seguir, podem ser vistas as componentes principais, seus respectivos autovalores, bem como a variância percentual e acumulada. A componente de número 6, por exemplo, apresenta autovalor igual a 1,44719, variância percentual de 6,03% e cumulativa de 51,214%, o que significa que, ao se tratar apenas com as seis primeiras componentes principais, ocorre uma perda de informações em relação ao conjunto original de dados, de 48,786%.

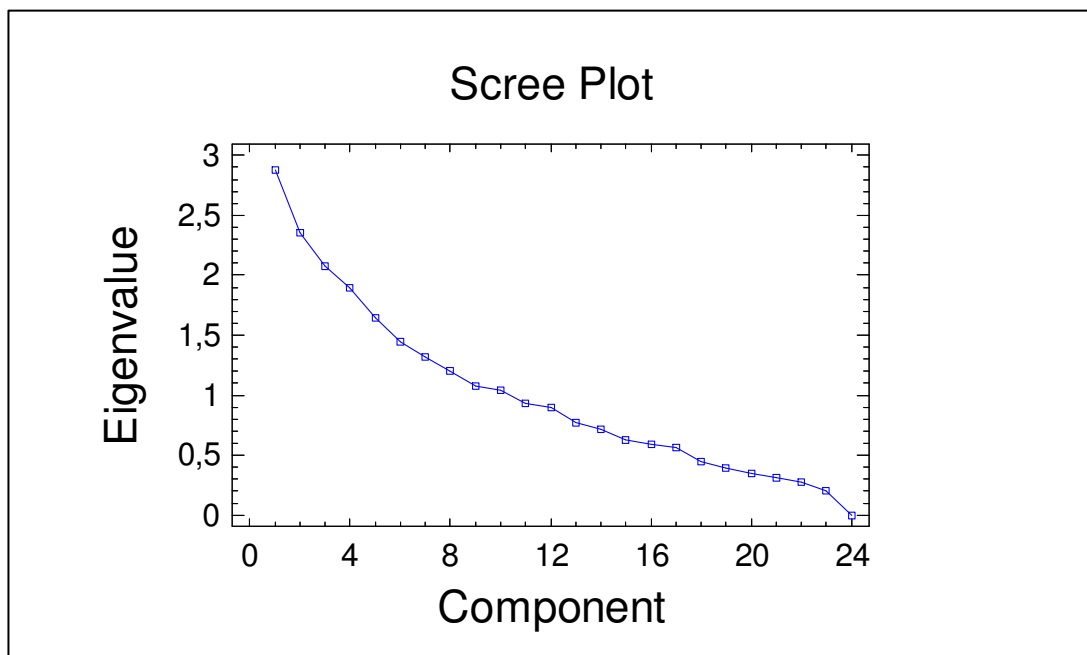
TABELA 4.12. AUTOVALORES EM ORDEM DECRESCENTE

COMPONENTES		VARIÂNCIA	
NÚMERO	AUTOVALOR	PERCENTUAL	ACUMULADA
1	2,87555	11,981	11,981
2	2,35393	9,808	21,789
3	2,07293	8,637	30,427
4	1,89756	7,907	38,333
5	1,64411	6,85	45,184
6	1,44719	6,03	51,214
7	1,32167	5,507	56,721
8	1,19906	4,996	61,717
9	1,07402	4,475	66,192
10	1,04334	4,347	70,539
11	0,932516	3,885	74,425
12	0,898041	3,742	78,166
13	0,766744	3,195	81,361
14	0,720902	3,004	84,365
15	0,62756	2,615	86,98
16	0,589719	2,457	89,437
17	0,560517	2,335	91,772
18	0,448995	1,871	93,643
19	0,3899	1,625	95,268
20	0,348896	1,454	96,721
21	0,309435	1,289	98,011
22	0,273412	1,139	99,15
23	0,203998	0,85	100
24	0	0	100

Analisando a tabela 4.12 anterior, observa-se que a componente de número 24 não apresenta nenhuma variância; logo, ao descartá-la, o conjunto não sofre perda de informações.

A figura 4.4, a seguir, mostra o *scree plot*, relacionando as componentes principais e seus respectivos autovalores.

FIGURA 4.4. AUTOVALORES VERSUS FATORES DA ACP



A reprodução da variabilidade total do sistema original requer as 23 componentes principais; porém, como se pode observar na tabela 4.12, a maior parte desta variabilidade pode ser expressa por um número menor de componentes.

Este teste treinou redes com três conjuntos distintos de entrada de dados. No primeiro treinamento foram utilizadas as 23 componentes principais. Tal treino não teve por objetivo diminuir a dimensão do conjunto de dados originais, mas sim trabalhar com este novo conjunto de variáveis não-correlacionadas.

No segundo treinamento foram utilizadas apenas 12 componentes principais. O critério utilizado para descartar as 12 últimas componentes principais foi a análise do *scree plot* (figura 4.4), através do qual se vê a formação de um cotovelo próximo à componente de número 12, o que mostra que as componentes acima de λ_{12} são relativamente pequenas quando comparadas com as anteriores, levando à

conclusão de que as doze primeiras componentes são suficientes para resumir grande parte da variação total do sistema.

No último treinamento realizado neste teste, a determinação do número de componentes que deve permanecer foi estabelecida pelo o critério Kaiser (JOHNSON e WICHERN, 2002), segundo o qual se mantêm somente as componentes cujos autovalores são superiores a um. Assim, no terceiro treinamento foram mantidas apenas as dez primeiras componentes principais.

Da mesma maneira conforme feito nos testes I e II, as redes deste teste foram treinadas para os dois processos de codificação das saídas. O primeiro processo é aquele em que as saídas foram divididas por 94; no segundo, as saídas foram calculadas de acordo com a distribuição normal cumulativa.

Para cada um dos três conjuntos de entrada de dados, utilizados nos dois processos de codificação de saída, foram inicialmente treinadas redes com 50 épocas e variando-se a camada oculta de 1 até 14 neurônios. Os resultados mais importantes constam da tabela 4.13, a seguir, enquanto os dados completos do 1º processo compõem o Apêndice VII.

TABELA 4.13. TOPOLOGIAS DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 23 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E23N1I50	0,06968	0,14800	0,09901	0,32363
E23N2I50	0,05303	0,20287	0,07805	0,22058
E23N3I50	0,03189	0,16561	0,06799	0,12235
E23N4I50	0,03207	0,13947	0,04118	0,14504
E23N5I50	0,02686	0,36916	0,03977	0,29881
E23N6I50	0,02383	0,07108	0,03484	0,23274
E23N7I50	0,02294	0,08402	0,02813	0,31707
E23N8I50	0,03090	0,12042	0,02778	0,15836
E23N9I50	0,02282	0,25118	0,02108	0,19719
E23N10I50	0,02502	0,45144	0,02929	0,32784
E23N11I50	0,02375	0,14043	0,02713	0,17868
E23N12I50	0,02225	0,12329	0,02633	0,19707
E23N13I50	0,02485	0,11329	0,02651	0,16935
E23N14I50	0,02186	0,21053	0,03237	0,12221

De acordo com a tabela 4.13 anterior, conclui-se que a melhor arquitetura de rede para o primeiro processo é E23N6I50, ou seja, 23 neurônios na camada de entrada e seis na camada escondida. No segundo processo a rede que apresenta o melhor resultado é composta de 23 neurônios na camada de entrada e 14 na escondida. A partir desta definição foram treinadas essas duas redes, agora com a variação do número de iterações, a fim de se obter o menor erro possível. A tabela 4.14, a seguir, mostra os resultados relevantes. O Apêndice VIII apresenta os resultados completos para o 1º processo.

TABELA 4.14. NÚMERO DE ITERAÇÕES DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 23 COMPONENTES PRINCIPAIS

PRIMEIRO PROCESSO			SEGUNDO PROCESSO		
TOPOLOGIA	RMSE Tr	RMSE Tes	TOPOLOGIA	RMSE Tr	RMSE Tes
E23N6I10	0,05718	0,10532	E23N14I10	0,08714	0,12857
E23N6I20	0,03792	0,08161	E23N14I20	0,06364	0,13704
E23N6I30	0,03175	0,07455	E23N14I30	0,04878	0,13739
E23N6I40	0,02738	0,07145	E23N14I40	0,03959	0,12949
E23N6I50	0,02383	0,07108	E23N14I50	0,03237	0,12221
E23N6I60	0,02134	0,07196	E23N14I60	0,02700	0,12000
E23N6I70	0,01955	0,07333	E23N14I70	0,02256	0,12168
E23N6I80	0,01819	0,07489	E23N14I80	0,01893	0,12501
E23N6I90	0,01706	0,07653	E23N14I90	0,01604	0,12878
E23N6I100	0,01609	0,07821	E23N14I100	0,01363	0,13242
E23N6I200	0,01014	0,09270	E23N14I200	0,00499	0,14129
E23N6I500	0,00573	0,11402	E23N14I500	0,00346	0,15290
E23N6I1000	0,00409	0,12951	E23N14I1000	0,00242	0,16704

A partir dos resultados da tabela 4.14, é possível observar que bastam 50 iterações para se obter o menor erro no grupo de testes do primeiro processo. Observa-se, também, que tal erro é menor do que o obtido no segundo processo.

O próximo treinamento buscou reduzir o número de componentes principais. Utilizam-se apenas as 12 primeiras componentes, ou seja, a matriz de entrada de dados foi reduzida em 50%. A escolha pela redução a 12 componentes baseou-se, conforme comentado na seção 3.2.4, no gráfico do *scree plot* (figura 4.4). Mais uma vez foram treinadas redes para os dois processos de ajuste das saídas, fazendo-se variar o número de neurônios na camada escondida de 1 até 14. A tabela 4.15 a

seguir, mostra os melhores resultados desse treinamento e o Apêndice IX traz o treinamento completo para o 1º processo.

TABELA 4.15. TOPOLOGIAS DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 12 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E12N1I50	0,08010	0,14067	0,13038	0,27122
E12N2I50	0,06632	0,19747	0,08442	0,15346
E12N3I50	0,04978	0,11291	0,08204	0,26016
E12N4I50	0,04745	0,09476	0,06721	0,13699
E12N5I50	0,04104	0,18902	0,05121	0,33608
E12N6I50	0,04105	0,19372	0,05444	0,17482
E12N7I50	0,04017	0,15443	0,06994	0,19585
E12N8I50	0,03943	0,12388	0,05086	0,16535
E12N9I50	0,03386	0,10803	0,04625	0,16304
E12N10I50	0,04283	0,12590	0,05943	0,17036
E12N11I50	0,04267	0,19597	0,04891	0,13966
E12N12I50	0,03216	0,09471	0,02598	0,19133
E12N13I50	0,03757	0,14655	0,04232	0,20350
E12N14I50	0,03818	0,24983	0,03794	0,23092

Fazendo uso das 12 primeiras componentes principais, nota-se que, tanto no primeiro quanto no segundo processo, a arquitetura que melhor se enquadrou à situação foi a E12N4I50, a qual apresenta 12 neurônios na camada de entrada e apenas 4 na camada escondida. A partir desta arquitetura fez-se variar o número de iterações em cada um dos processos, buscando o menor RMSE nos grupos de teste.

A tabela 4.16, a seguir, mostra a variação das curvas dos erros nos dois grupos dos dois processos. No primeiro processo, o menor erro no grupo de testes foi obtido ao submeter a rede neural a apenas 20 iterações, quando, a partir de então, ao se aumentar o número de iterações o erro neste grupo passa a aumentar. Já no segundo processo o menor RMSE foi obtido ainda mais rapidamente – bastaram 10 iterações para alcançá-lo. Em ambos os casos, ratifica-se que nos conjuntos de treinamento o erro sempre diminui à medida que se aumenta o número de iterações. No segundo processo, por exemplo, o erro inicial é de 0,23330 e cai

para o valor de 0,05402 quando a rede é submetida a 200 iterações. Os resultados completos desse treinamento, para o 1º processo, encontram-se no Apêndice X.

TABELA 4.16. NÚMERO DE ITERAÇÕES DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 12 COMPONENTES PRINCIPAIS

PRIMEIRO PROCESSO			SEGUNDO PROCESSO		
TOPOLOGIA	RMSE Tr	RMSE Tes	TOPOLOGIA	RMSE Tr	RMSE Tes
E12N4I10	0,09159	0,08520	E12N4I1	0,23330	0,17853
E12N4I20	0,06811	0,07991	E12N4I5	0,14614	0,15751
E12N4I30	0,05726	0,08290	E12N4I10	0,11461	0,12555
E12N4I40	0,05055	0,08925	E12N4I20	0,09515	0,13389
E12N4I50	0,04745	0,09476	E12N4I30	0,08297	0,13424
E12N4I60	0,04566	0,09861	E12N4I40	0,07349	0,13366
E12N4I70	0,04442	0,10129	E12N4I50	0,06721	0,13699
E12N4I80	0,04344	0,10335	E12N4I60	0,06298	0,14007
E12N4I90	0,04258	0,10505	E12N4I70	0,06070	0,14139
E12N4I100	0,04179	0,10650	E12N4I80	0,05964	0,14195
E12N4I200	0,03574	0,12206	E12N4I90	0,05898	0,14235
E12N4I500	0,02400	0,19691	E12N4I100	0,05842	0,14271
E12N4I1000	0,01946	0,20707	E12N4I200	0,05402	0,14358

O último treinamento realizado neste teste utilizou o critério de Kaiser (JOHNSON E WICHERN, 2002) para definir a quantidade de componentes principais que seriam utilizadas, que, conforme já comentado, estabelece que devem ser mantidas as componentes que possuam autovalores acima de um. Ao adotar-se tal critério, pode-se verificar, através da tabela 4.12, que apenas as 10 primeiras componentes serão utilizadas. Por um lado reduz-se de 24 para 10 o número de coordenadas dos vetores que compõem a matriz de entrada de dados. Por outro lado há uma perda de informações de 29,461% em relação ao conjunto de dados original.

Estabelecida a quantidade de entradas, o próximo passo é encontrar a melhor arquitetura para as redes. Analogamente aos treinamentos anteriores, fez-se variar o número de neurônios na camada escondida de 1 até 14, para ambos os processos de codificação da saída da rede.

A tabela 4.17, a seguir, mostra esta variação nas topologias da rede com seus respectivos RMSE nos dois processos, e o Apêndice XI, mostra o treinamento completo para o 1º processo.

TABELA 4.17. TOPOLOGIAS DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS

TOPOLOGIA	PRIMEIRO PROCESSO		SEGUNDO PROCESSO	
	RMSE Tr	RMSE Tes	RMSE Tr	RMSE Tes
E10N1I50	0,09708	0,15179	0,13080	0,27269
E10N2I50	0,07556	0,24736	0,09090	0,36182
E10N3I50	0,05253	0,10734	0,08381	0,26277
E10N4I50	0,04406	0,09593	0,08173	0,16762
E10N5I50	0,05036	0,13752	0,07299	0,25261
E10N6I50	0,04604	0,12002	0,05370	0,12836
E10N7I50	0,04608	0,34984	0,07700	0,20228
E10N8I50	0,04430	0,12940	0,06833	0,18487
E10N9I50	0,04681	0,29012	0,06750	0,22302
E10N10I50	0,04428	0,13067	0,05390	0,14119
E10N11I50	0,05230	0,07676	0,05730	0,16768
E10N12I50	0,05133	0,10886	0,06311	0,13574
E10N13I50	0,03978	0,11348	0,04894	0,15201
E10N14I50	0,04143	0,10765	0,04542	0,21254

Observa-se, a partir da tabela 4.17 anterior, que no primeiro processo a arquitetura que apresentou melhor resultado foi a E10N11I50, ou seja, uma rede com 10 neurônios na camada de entrada e 11 na escondida. No segundo processo, a topologia E10N6I50 foi a que melhor se enquadrou à situação.

Estabelecidas as arquiteturas, variou-se de 10 até 1.000 o número de épocas, buscando reduzir ainda mais os erros nos grupos de teste.

A partir da tabela 4.18, a seguir, observa-se que, para o primeiro processo – quando se treinou uma rede composta de 10 neurônios na camada de entrada e 11 na camada escondida – bastam 10 iterações para que o grupo de testes atinja o erro mínimo. Para o segundo processo, em que a rede treinada é composta por 10 neurônios na camada de entrada e apenas 6 na camada oculta, são necessárias 60

iterações para se atingir o menor RMSE. O Apêndice XII apresenta os resultados completos desse treinamento para o 1º processo.

TABELA 4.18. NÚMERO DE ITERAÇÕES DO TESTE III DO PRIMEIRO E SEGUNDO PROCESSOS COM 10 COMPONENTES PRINCIPAIS

PRIMEIRO PROCESSO			SEGUNDO PROCESSO		
TOPOLOGIA	RMSE Tr	RMSE Tes	TOPOLOGIA	RMSE Tr	RMSE Tes
E10N11I10	0,08338	0,06104	E10N6I10	0,10390	0,13769
E10N11I20	0,06817	0,06550	E10N6I20	0,08646	0,13679
E10N11I30	0,06112	0,07099	E10N6I30	0,07424	0,13311
E10N11I40	0,05622	0,07470	E10N6I40	0,06145	0,12924
E10N11I50	0,05230	0,07676	E10N6I50	0,05370	0,12836
E10N11I60	0,04881	0,07854	E10N6I60	0,04925	0,13136
E10N11I70	0,04535	0,08183	E10N6I70	0,04665	0,13490
E10N11I80	0,04186	0,08663	E10N6I80	0,04488	0,13809
E10N11I90	0,03866	0,09192	E10N6I90	0,04327	0,14106
E10N11I100	0,03605	0,09704	E10N6I100	0,04170	0,14357
E10N11I200	0,02331	0,12746	E10N6I200	0,03155	0,14702
E10N11I500	0,01066	0,13349	E10N6I500	0,02107	0,17177
E10N11I1000	0,00546	0,14862	E10N6I1000	0,01406	0,18425

4.2 ANÁLISE DOS RESULTADOS

Neste capítulo foram apresentados os treinamentos de várias redes neurais, cada uma delas com diversas topologias, visando obter uma previsão da duração do tempo de processos trabalhistas da 1ª Vara do Trabalho de São José dos Pinhais.

Os melhores resultados, em todos os treinamentos de todos os testes, foram obtidos sempre a partir do primeiro processo de codificação das saídas, que é aquele em que as saídas são divididas por 94.

A tabela 4.19, a seguir, mostra os melhores resultados de todos os treinamentos realizados, especificando os RMSE's de treinamento e teste para cada topologia de cada um dos três testes realizados nos dois processos de codificação das saídas.

TABELA 4.19. MELHORES RESULTADOS DAS REDES NEURAIIS

TESTE	PRIMEIRO PROCESSO			SEGUNDO PROCESSO		
	TOPOLOGIA	RMSE Tr	RMSE Tes	TOPOLOGIA	RMSE Tr	RMSE Tes
I	E32N8I40	0,03450	0,08770	E32N6I40	0,06070	0,10350
II	E31N7I60	0,03223	0,08054	E31N7I20	0,07131	0,11477
II	E16N2I10	0,12593	0,10692	E16N2I60	0,09497	0,13164
II	E10N9I10	0,13724	0,13636	E10N9I40	0,10004	0,16436
III	E23N6I50	0,02383	0,07108	E23N14I60	0,02700	0,12000
III	E12N4I20	0,06811	0,07991	E12N4I10	0,11461	0,12555
III	E10N11I10	0,08338	0,06104	E10N6I50	0,05370	0,12836

Conforme detalhado na tabela 4.19, o Teste I foi realizado com a codificação de todas as variáveis, sem ACP. No Teste II, além da codificação de todas as variáveis, foi realizada a ACP e nos treinamentos foram utilizadas 31, 16 e 10 componentes principais. No Teste III houve codificação apenas das variáveis qualitativas, a ACP e, nos treinamentos, foram utilizadas 23, 12 e 10 componentes principais.

De tudo o que foi analisado neste capítulo, cujos resultados mais importantes constam da tabela 4.19, constata-se que a não codificação das variáveis quantitativas produz melhores resultados e que a ACP é uma ferramenta que melhora o desempenho da RNA.

Assim sendo, verifica-se que os melhores resultados para a determinação da previsão da duração do tempo de processos trabalhistas foram obtidos através do teste III. Vale a pena recordar que no teste III as variáveis ordinais originais não foram codificadas, ou seja, os atributos salário, tempo de serviço e número de audiências não foram transformados em vetores binários, e a matriz de dados foi submetida ao processo de análise de componentes principais a fim de avaliar a importância relativa das variáveis que a compõem.

Dentro do teste III o melhor resultado foi obtido mantendo-se as 23 primeiras componentes principais, ou seja, as que apresentam variâncias não nulas. Desta maneira o conjunto não sofreu nenhuma perda de informações. Finalmente a

codificação da saída responsável pelo melhor resultado é aquela onde se divide as saídas por 94.

Resumidamente, o melhor resultado foi obtido no teste III, considerando 23 componentes principais e codificando a saída de acordo com o primeiro processo. O Apêndice XIII mostra os resultados práticos deste teste.

CAPÍTULO V

5. CONCLUSÕES E SUGESTÕES PARA FUTUROS TRABALHOS

5.1 CONCLUSÕES

O aumento da procura pela justiça do trabalho provoca uma necessidade de minimizar o tempo de duração dos processos trabalhistas. A utilização de uma ferramenta matemática que forneça aos usuários do sistema uma perspectiva da duração do tempo do processo, bem como auxilie os juízes na tomada de decisões, vem ao encontro desta necessidade. Sabendo o tempo estimado de duração do processo, as partes envolvidas (reclamante e reclamado) podem optar por um acordo já na primeira audiência. Tal procedimento pode melhorar o atendimento da Justiça do Trabalho, já que os usuários resolvem suas pendências evitando que seu processo se arraste por meses, ou até mesmo por anos, ao mesmo tempo em que descongestiona este serviço público.

A proposta do trabalho foi, então, que – a partir da utilização de técnicas matemáticas apropriadas – se obtenha de forma eficaz e automática uma perspectiva de duração do tempo de um processo trabalhista. Para tanto, foi implementada uma Rede Neural de Múltiplas Camadas ou Rede Neural do tipo *feed-forward* (alimentadas para frente), treinada através do algoritmo *back-propagation* (retro-propagação), utilizando a função de transferência sigmoideal.

Utilizando os dados de processos trabalhistas da 1ª Vara do Trabalho de São José dos Pinhais – Paraná, que são as entradas das redes neurais em questão, as mesmas foram treinadas fazendo-se variar a codificação dos atributos de entrada, o número de neurônios na camada escondida, o conjunto de pesos iniciais e o número de iterações. Assim, as redes fornecem como resposta (saída da RNA), o tempo de duração de cada processo.

A partir da tabela 4.19, verifica-se que o modelo apresentou desempenho bastante satisfatório. Observando, através desta tabela, os melhores resultados de todos os testes, vê-se que, no primeiro processo, os erros variam de 0,06104 a 0,13636 no conjunto de testes, enquanto que no conjunto de treinamento a variação do erro é de 0,02383 a 0,13724. Já no segundo processo o menor erro obtido no

conjunto de testes foi de 0,10350 e o maior foi de 0,16436, enquanto que no conjunto de treinamento essa variação foi de 0,02700 a 0,11461.

Dois critérios foram importantes para a obtenção de resultados satisfatórios: o primeiro trata das codificações efetuadas nos atributos (entradas) da rede; o segundo, trata do enquadramento das saídas à função de transferência logística sigmoidal.

No caso das codificações dos atributos que compõem as entradas da rede, notou-se claramente que os resultados foram mais consistentes quando tal codificação foi aplicada somente às variáveis qualitativas, ou seja, quando as variáveis quantitativas (tempo de serviço, salário e número de audiências) mantiveram seus valores originais. Observando a tabela 4.19, nota-se claramente que os erros, tanto no conjunto de treinamento quanto no conjunto de testes, foram menores no teste III.

Quanto ao enquadramento das saídas à função de transferência, em todos os testes realizados o melhor processo foi aquele em que as saídas foram divididas por 94 (tempo máximo de duração dos processos analisados), já que em todos esses casos tal procedimento apresentou sempre um erro menor. Através da tabela 4.19 pode-se observar, por exemplo, que no teste III (utilizando-se 23 componentes principais) o erro do grupo de teste do primeiro processo é de 0,07108, enquanto que no segundo processo o mesmo tipo de erro é de 0,12000.

Assim, dados novos processos cujos tempos de duração devam ser previstos, a melhor maneira de se obter essa previsão de tempo é seguir os passos do Teste III com 23 componentes principais e com codificação da saída de acordo com o primeiro processo, ou seja, codificar todas as variáveis qualitativas (conforme descrito na seção 2.2.2), gerar as 23 componentes principais através da ACP e utilizar-se dos pesos da RNA gerados no Teste III.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

A partir dos resultados obtidos, sugere-se para o desenvolvimento de trabalhos futuros:

- separação dos processos trabalhistas em dois grupos distintos: processos cujo rito é do tipo RT e processos cujo rito é do tipo PS, uma vez que a justiça costuma tratá-los de maneira diferenciada quanto aos prazos a serem seguidos;
- utilização de outra ferramenta matemática na resolução do mesmo problema, como por exemplo, Regressão Linear Múltipla, a fim de encontrar parâmetros para comparação dos resultados;
- realização de um teste com a codificação somente das variáveis qualitativas e sem ACP.

REFERÊNCIAS

- ADAMOWICZ, E. C. **Reconhecimento de Padrões na Análise Econômico-Financeira de Empresas**. Curitiba, 2000. Dissertação de Mestrado - Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná.
- ALMEIDA, F. C. **Novo modelo organizacional baseado no cérebro humano**. Revista de Administração, 1995, p.46-56.
- ASSOCIAÇÃO NACIONAL DOS MAGISTRADOS DA JUSTIÇA DO TRABALHO. **Composição da Justiça do Trabalho**. Disponível em: <<http://www.anamatra.org.br/justica/composicao/composicao.cfm>> Acesso em: 15 novembro 2006.
- BAESENS, B.; SETIONO, R.; MUES, C. & VANTHIENEN, J. (2003). **Using Neural Network Rule Extraction and Decision Tables for Credit-Risk Evaluation**. Management Science Informs, v. 49, n. 3, p. 312-329.
- BALDIN, M. S. Z. **Redes Neurais na Orientação Profissional**. Curitiba, 2002. Dissertação de Mestrado - Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná.
- BAPTISTELLA, M.; STEINER, M. T. A.; CHAVES NETO, A. **O Uso de Redes Neurais e Regressão Linear Múltipla na Engenharia de Avaliações: Determinação dos Valores Venais de Imóveis Urbanos**. XXXVIII SOBRAPO - SIMPOSIO BRASILEIRO DE PESQUISA OPERACIONAL, Goiânia, GO - 2006
- CASTRO, C. L. **Sistema Inteligente para Previsão On-Line do Índice IBOVEPA baseado em Redes Neurais Artificiais**. Belo Horizonte, 2004. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais.
- CIPRA, B. A. **A Chotic Walk on Wall Street**, SIAM News, may 1992.

COSTA, L. S. **Modelagem do Acesso de Pacientes com Fratura no Fêmur a Hospitais Públicos por Meio de Redes Neurais Artificiais e Regressão Linear Múltipla**. Rio de Janeiro, 2004. Dissertação de Mestrado – Universidade Federal do Rio de Janeiro.

DIN – Departamento de Informática – UEM – Universidade Estadual de Maringá. **Uma Introdução às Redes Neurais**. Disponível em: <<http://www.din.uem.br/ia/neurais/>> Acesso em 12 junho 2006.

FADUM, O. **Artificial Intelligence : expert systems, fuzzy logic and neural network applications in the paper industry**, Pulp & Paper, 1993.

FREIMAN, J. P. **Utilização de Redes Neurais Artificiais na Previsão de Indicadores Financeiros para Avaliação Econômica de Negócios em Situação de Risco**. Itajubá, 2004. Dissertação de Mestrado – Universidade Federal de Itajubá.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2ª Edição, Porto Alegre: Bookman, 2001.

INFANTOSI, A. F. C.; ALMEIDA, R. M. V.; COSTA, J. C. G. D.; ÁVILA, C. A. L.; SUASSUNA, J. H. **Definição de Variáveis em Redes Neurais Artificiais por Análise de Componentes Principais: Aplicação em Transplante Renal**. IX CBIS – Congresso Brasileiro de Informática em Saúde, Ribeirão Preto – SP, 2004.

JOHNSON, R.A.; WICHERN, D.W. **Applied Multivariate Statistical Analysis**. 5.ª Edição, Nova Jersey: Prentice Hall, 2002.

LEMO, E. P.; STEINER, M. T. A.; NIEVOLA, J. C. **Análise de Crédito Bancário por meio de Redes Neurais e Árvores de Decisão: uma Aplicação Simples de Data Mining**. RAUSP - Revista de Administração da Universidade de São Paulo, v. 40, N. 3, 2005.

LOPES, R. N. **Classificação de Ameaças em um Sistema de Defesa Aérea Utilizando Redes Neurais Artificiais**. São José dos Campos, 2004. Dissertação de Mestrado – Instituto Tecnológico Aeroespacial.

LU, H.; SETIONO, R. & LIU, H. (1996). ***Effective Data Mining Using Neural Networks***. IEEE Transactions on Knowledge and Data Engineering, v. 8, n. 6, p.957-961.

MARQUES, J. **Notas de aula da disciplina Análise Multivariada Aplicada a Pesquisa**. Programa de Pós-Graduação em Métodos Numéricos em Engenharia, UFPR, Curitiba, PR, 2005.

MUELLER, A. **Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário**. Florianópolis, 1996. Dissertação de Mestrado - Universidade Federal de Santa Catarina.

OLIVEIRA, M. M. F. **Redes Neurais Artificiais na Predição da Maré Meteorológica em Paranaguá-PR**. Rio de Janeiro, 2004. Dissertação de Mestrado – Universidade Federal do Rio de Janeiro.

REALI, E. H. **Utilização de Inteligência Artificial (Redes Neurais Artificiais) no Gerenciamento da Produção de Frangos de Corte**. Porto Alegre 2004. Dissertação de Mestrado – Universidade Federal do Rio Grande do Sul.

REBOUÇAS, L. **Rede neural vai detectar fraudes com cartões**, Gazeta Mercantil, 1993.

RUDD, J. B. ***Using a neural network system for advanced process control***, Tappi Journal, 1991, p. 153-159.

SCHWARTZ, E. ***Where Neural Networks are already at work***, special report, Business Week, nov. 1992.

STEINER, M. T. A. **Notas de aula da disciplina Aplicações de Pesquisa Operacional**. Programa de Pós-Graduação em Métodos Numéricos em Engenharia, UFPR, Curitiba, PR, 2005.

STEINER, M. T. A. **Reconhecimento de Padrão na Indústria de Papel**, XXVI SBPO, Florianópolis, dez. 1994 - (Conferência).

TAM, K. Y. & KIANG, M. Y. **Managerial Applications of Neural Networks : The Case of Bank Failure Predictions**, Management Sciences, v. 38, n. 7, p. 926-947, 1992.

TST - TRIBUNAL SUPERIOR DO TRABALHO. **Atribuições**. Disponível em: <<http://www.tst.gov.br/>> Acesso em 15 novembro 2006.

VIDAL, L. S. **Utilização de Redes Neurais Artificiais na Previsão de Acidentes e Feridos em Rodovias**. Vitória, 2004. Dissertação de Mestrado – Universidade Federal do Espírito Santo.

YAMAZAKI, A. **Reconhecimento de Padrões em um Nariz Artificial por Redes Neurais**. Recife, 2001. Dissertação de Mestrado – Universidade Federal de Pernambuco.

WOLF, A. S. **Análise Automática de Sinais Eletrocardiográficos por Redes Neurais Artificiais**. Rio de Janeiro, 2004. Dissertação de Mestrado – Pontifícia Universidade Católica do Rio de Janeiro.

APÊNDICES

APÊNDICE I**FICHA DE DADOS****DADOS INICIAIS DO PROCESSO:**

- NR DOS AUTOS: _____
- RITO: () RT () PS
- DATA DO AJUIZAMENTO: _____/_____/_____

DADOS DO AUTOR

- SEXO: () M () F
- NASCIMENTO: _____/_____/_____
- ADMISSÃO: _____/_____/_____
- DISPENSA: _____/_____/_____
- ÚLTIMO SALÁRIO: R\$ _____
- FUNÇÃO: _____
- NR OAB ADVOGADO: _____

DADOS DO RÉU

- QUALIDADE: () FÍSICA () JURÍDICA
- NR OAB ADVOGADO: _____

DADOS DO PROCESSO:

- OBJETO DO PROCESSO:

<input type="checkbox"/> 1. REGISTRO EM CTPS <input type="checkbox"/> 3. FGTS <input type="checkbox"/> 5. SEGURO DESEMPREGO <input type="checkbox"/> 7. INSALUBRIDADE <input type="checkbox"/> 9. ADICIONAL NOTURNO <input type="checkbox"/> 11. MULTA DO ART 467	<input type="checkbox"/> 2. HORAS EXTRAS <input type="checkbox"/> 4. VERBAS RESCISÓRIAS <input type="checkbox"/> 6. VALE-TRANSPORTE <input type="checkbox"/> 8. MULTA DO ART 477 <input type="checkbox"/> 10. DIFERENÇAS SALARIAIS <input type="checkbox"/> 12. DANOS MORAIS
--	---
- NR DE AUDIÊNCIAS: _____
- PERÍCIAS: () SIM () NÃO
- DATA DA SENTENÇA: _____/_____/_____
- RECURSOS: () NÃO () RO () RR
- DATAS DO ACÓRDÃO: TST _____/_____/_____
TRT _____/_____/_____

APÊNDICE II

TABELA A.1 - MATRIZ DE ENTRADA DE DADOS PATA TESTES I E II.

Nr	Objeto do processo												Salário Reclamante		Ri to	Pe ri cia	Tempo de Serviço				A cor do	Profissão			RO	RR	Número de Audiências					
	1	2	3	4	5	6	7	8	9	10	11	12																				
1	1	1	1	1	1	1	1	1	0	0	0	0	0	1	1	1	0	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0
2	0	1	1	0	0	0	0	0	0	1	0	0	0	1	1	1	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	1
3	1	1	1	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	
4	0	1	1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	1	1	1	1	0	0	1	0	0	1	1	0	0	0	0
5	1	0	1	0	0	0	0	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
6	1	1	1	1	0	0	0	1	0	1	0	1	0	0	1	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1
7	0	1	1	0	0	0	0	1	1	0	0	0	0	0	1	1	0	0	1	1	1	0	0	0	1	0	0	0	0	0	0	1
8	0	1	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0	0	1	1	0	0	1	0	0	1	0	0	0	0	1
9	0	1	1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	1
10	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	1	0	1	1	1	1	0	1	0	0	0	1	0	0	0	0	1
11	0	1	0	0	0	0	1	0	0	1	0	1	1	1	1	1	1	0	1	1	1	0	0	1	0	0	0	0	0	0	0	0
12	0	1	0	1	0	0	0	1	0	0	1	0	0	1	1	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
13	0	1	1	1	0	1	1	1	0	0	1	0	0	1	1	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0
14	0	1	1	1	0	0	0	1	0	1	0	0	1	1	1	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0
15	0	1	1	0	0	0	1	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0	1	0	0	1	1	0	0	0	1
16	0	0	1	0	0	0	0	0	0	0	0	0	1	1	1	0	0	1	1	1	1	1	0	0	1	0	0	0	0	0	0	0
17	0	0	1	0	0	0	0	1	0	0	1	0	0	1	1	0	0	0	0	1	1	0	0	1	0	0	0	0	0	0	0	1
18	0	1	1	1	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	1
19	0	1	0	1	0	0	0	0	0	1	1	0	0	0	1	1	0	1	1	1	1	0	0	1	0	0	1	0	0	0	0	0
20	0	1	0	0	0	1	1	1	0	0	0	0	0	1	1	1	1	0	1	1	1	0	1	0	0	0	0	0	0	0	1	1
21	0	1	0	1	1	0	0	1	0	0	0	1	1	1	1	1	0	1	1	1	1	1	0	1	0	1	0	0	0	0	0	0
22	0	1	1	0	0	0	0	1	0	1	0	0	1	1	1	0	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0
23	1	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	1	0	0	0	0	0	0	0	0
24	0	0	0	1	0	0	0	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
25	1	0	1	1	1	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	1
26	0	1	1	0	0	0	1	0	0	1	0	0	0	0	1	1	0	1	1	1	1	0	1	0	0	0	0	0	0	0	1	1
27	0	1	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	0
28	1	0	0	1	1	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0

CONTINUA

CONTINUAÇÃO

Nr	Objeto do processo												Salário Reclamante	Rito	Percia	Tempo de Serviço				Acordo	Profissão				RO	RR	Número de Audiências					
	1	2	3	4	5	6	7	8	9	10	11	12																				
29	1	1	0	0	1	0	0	0	0	1	0	1	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	1	1	
30	1	1	1	1	1	1	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	
31	0	1	1	0	0	0	0	0	0	0	0	1	0	1	1	1	0	0	0	1	1	0	0	1	0	0	0	0	0	0	1	
32	0	1	1	1	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	1	1	1	0	0	0	0	0	0	0	0	0	
33	0	1	0	0	0	0	0	1	0	0	0	0	0	0	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	1	
34	0	1	1	1	0	0	1	1	0	1	0	0	0	0	0	1	1	0	0	1	1	0	1	0	0	0	0	0	1	1	1	
35	0	1	0	0	0	0	0	1	0	0	0	1	0	1	1	1	0	0	0	1	0	0	1	0	0	1	0	0	0	0	1	
36	0	1	0	1	0	0	0	1	0	0	1	0	0	0	1	0	0	0	1	1	1	0	0	1	0	0	0	0	0	0	0	
37	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	1	0	0	0	0	0	0	0	1	1	
38	0	1	1	1	0	0	0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	1	1	0	0	0	0	0	0	0	1	
39	0	0	1	1	0	0	0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	
40	0	1	1	1	1	0	0	0	0	0	0	0	0	1	1	1	0	0	0	1	1	0	1	0	0	0	0	0	0	0	1	
41	0	1	0	1	0	0	0	0	0	1	0	0	1	1	1	1	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	
42	0	1	1	1	0	0	1	0	0	1	0	0	0	0	1	1	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	
43	0	1	1	1	0	0	0	0	0	1	0	0	1	1	1	1	0	0	1	1	1	0	0	0	1	1	1	1	0	0	1	1
44	0	1	0	1	0	0	0	0	1	1	0	0	1	1	1	1	0	0	0	1	1	0	0	1	0	0	1	0	0	0	1	
45	0	1	0	0	1	0	0	1	0	0	0	1	1	1	1	1	0	0	0	0	0	1	0	0	1	0	0	1	0	0	0	
46	0	1	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	0	0	1	1	0	1	0	0	0	0	0	0	0	1	1
47	0	1	1	1	0	1	0	1	0	0	1	0	0	1	1	1	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	1
48	0	1	1	1	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	0	1	0	1	0	1	0	0	0	0	0	0	
49	0	0	1	0	0	0	0	0	0	0	0	0	1	1	1	1	0	1	1	1	1	0	1	0	0	0	1	0	0	0	0	
50	0	1	1	1	0	1	0	0	0	0	0	0	0	1	1	1	0	0	0	1	0	1	0	0	0	0	0	0	0	1	1	
51	0	1	1	1	0	0	0	1	0	1	0	1	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	1	1	
52	0	1	0	1	0	1	0	0	1	0	0	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	
53	0	1	1	1	0	0	1	1	0	0	1	0	1	1	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	1
54	0	0	1	1	1	0	0	1	0	0	1	0	0	0	1	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	0	
55	0	1	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	
56	0	1	0	1	0	0	0	1	0	1	1	0	0	0	0	1	0	1	1	1	1	1	1	0	0	0	0	0	0	0	1	
57	0	1	0	0	0	0	0	1	0	0	0	0	1	1	1	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0	
58	0	1	0	0	0	0	0	1	0	1	0	0	1	1	1	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0	
59	0	1	0	0	0	0	0	0	0	0	0	0	1	1	1	1	0	1	1	1	1	0	1	0	0	0	1	0	0	1	1	
60	0	1	0	0	0	0	0	1	0	0	1	0	0	0	1	1	0	0	0	1	1	0	0	1	0	0	0	0	0	1	1	

CONTINUA

CONTINUAÇÃO

Nr	Objeto do processo												Salário Reclamante	Rito	Percia	Tempo de Serviço	Acordo	Profissão	RO	RR	Número de Audiências											
	1	2	3	4	5	6	7	8	9	10	11	12																				
61	0	1	0	1	0	0	0	0	0	0	0	0	0	1	1	1	0	0	1	1	1	0	0	1	0	0	0	0	0	0	0	0
62	0	1	1	1	0	0	1	0	0	1	0	0	0	0	1	1	0	0	0	1	1	0	0	1	0	0	0	0	0	0	0	0
63	0	1	1	1	0	1	1	0	0	0	0	0	1	1	1	0	0	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0
64	0	1	0	1	0	1	0	0	0	1	0	1	0	0	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1
65	0	1	0	1	0	0	0	1	0	0	1	0	0	0	1	1	0	0	1	1	1	0	0	1	0	0	0	0	0	0	0	0
66	0	1	0	0	0	1	0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	0	0	1	0	0	0	0	0	0	0
67	0	1	0	0	0	0	0	0	1	0	0	0	1	1	1	1	0	0	0	0	1	0	1	0	0	0	1	0	0	0	0	0
68	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	1	1	1	0	1	0	0	0	0	1	1	1
69	0	1	0	1	0	0	1	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0	1	0	0	1	1	0	1	1	1	1
70	0	1	1	0	0	0	1	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0	1	0	0	0	0	0	0	0	1	1
71	0	1	1	1	1	0	1	1	0	0	1	0	0	1	1	1	1	0	1	1	1	0	0	1	0	0	0	1	1	1	1	1
72	0	1	0	1	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	1	1	0	0	1	0	0	1	0	0	0	0	0
73	0	1	0	0	0	1	0	1	0	0	0	1	0	0	1	1	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0
74	0	1	0	1	1	0	0	1	0	0	1	0	1	1	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0
75	0	0	1	1	0	0	0	1	0	1	1	1	0	1	1	1	0	0	1	1	0	0	1	0	0	0	0	0	0	0	0	1
76	0	1	1	1	0	0	0	1	0	0	1	0	0	1	1	1	0	1	1	1	1	0	0	1	0	0	1	0	0	1	1	1
77	0	1	1	0	0	0	1	0	0	0	0	0	0	1	1	1	0	0	1	1	1	0	0	1	0	0	1	0	0	0	0	0
78	0	1	0	1	0	0	0	0	0	0	0	0	0	0	1	1	0	1	1	1	1	0	0	1	0	0	0	0	0	0	1	1
79	0	1	1	1	0	0	1	0	0	0	0	0	1	1	1	1	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0	0
80	0	1	1	1	0	0	1	1	0	0	1	0	0	1	1	1	0	0	0	0	1	1	0	1	0	0	0	0	0	0	0	1
81	0	1	0	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	1	0	0	1	0	0	0	0	0	0	0	1
82	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	1	1	0	1	0	0	0	0	0	0	0	1
83	0	1	0	1	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	1
84	0	1	0	1	1	0	0	1	0	0	1	0	1	1	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0
85	0	1	0	0	0	0	0	1	0	1	1	0	0	1	1	1	0	1	1	1	1	0	1	0	0	0	0	0	0	0	1	1
86	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0	0	1	1	0	0	0	0
87	1	1	1	1	1	1	1	1	0	0	1	0	1	1	1	1	0	1	1	1	0	0	1	0	0	0	0	0	0	0	0	0
88	0	1	1	1	1	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0
89	0	1	1	1	1	0	0	1	0	0	1	1	1	1	1	1	0	0	0	1	1	0	0	1	0	0	0	0	0	0	0	1
90	0	1	1	1	1	0	0	1	0	0	1	1	1	1	1	1	0	0	0	1	1	0	0	1	0	0	0	0	0	0	0	1
91	0	0	0	1	0	0	0	1	0	0	1	0	1	1	1	1	0	0	0	0	1	0	1	0	0	1	1	0	0	0	0	0
92	0	1	0	1	1	0	0	1	0	0	0	0	0	1	1	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0

CONTINUA

CONCLUSÃO

Nr	Objeto do processo												Salário Reclamante	Rito	Perícia	Tempo de Serviço	Acordo	Profissão	RO	RR	Número de Audiências											
	1	2	3	4	5	6	7	8	9	10	11	12																				
93	1	1	0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	0
94	0	1	0	1	0	0	0	1	0	0	1	0	0	0	1	1	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0	1
95	0	1	1	0	0	1	1	0	0	0	0	0	0	0	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	1
96	0	1	0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	1	1	1	1	0	0	0	1	0	1	0	0	0	0	1
97	0	1	1	0	0	0	1	1	0	0	0	0	1	1	1	1	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0	0
98	0	1	0	1	1	0	0	0	0	0	0	0	0	0	1	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0	1	1
99	0	1	1	1	0	0	0	1	0	0	1	1	0	1	1	1	0	0	0	1	1	0	0	0	1	0	0	0	0	0	0	1
100	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	1	1	0	1	1	1	0	0	1	0	0	0	0	1	1	1	1

APÊNDICE III

TABELA A.2 - CODIFICAÇÃO DAS SAÍDAS

NR	SAÍDA	1º PROC	2º PROC	NR	SAÍDA	1º PROC	2º PROC
1	8	0,08511	0,20368	51	32	0,34043	0,69201
2	9	0,09574	0,21973	52	16	0,17021	0,35006
3	26	0,27660	0,56711	53	18	0,19149	0,39192
4	86	0,91489	0,99976	54	6	0,06383	0,17377
5	14	0,14894	0,30994	55	17	0,18085	0,37079
6	22	0,23404	0,47901	56	19	0,20213	0,41336
7	21	0,22340	0,45697	57	14	0,14894	0,30994
8	37	0,39362	0,78191	58	8	0,08511	0,20368
9	14	0,14894	0,30994	59	48	0,51064	0,91747
10	36	0,38298	0,76523	60	33	0,35106	0,71123
11	14	0,14894	0,30994	61	15	0,15957	0,32975
12	14	0,14894	0,30994	62	24	0,25532	0,52320
13	3	0,03191	0,13444	63	8	0,08511	0,20368
14	4	0,04255	0,14681	64	21	0,22340	0,45697
15	89	0,94681	0,99987	65	14	0,14894	0,30994
16	2	0,02128	0,12281	66	21	0,22340	0,45697
17	13	0,13830	0,29067	67	24	0,25532	0,52320
18	14	0,14894	0,30994	68	22	0,23404	0,47901
19	32	0,34043	0,69201	69	79	0,84043	0,99905
20	25	0,26596	0,54523	70	34	0,36170	0,72986
21	4	0,04255	0,14681	71	40	0,42553	0,82765
22	14	0,14894	0,30994	72	2	0,02128	0,12281
23	8	0,08511	0,20368	73	9	0,09574	0,21973
24	7	0,07447	0,18836	74	14	0,14894	0,30994
25	22	0,23404	0,47901	75	26	0,27660	0,56711
26	23	0,24468	0,50111	76	32	0,34043	0,69201
27	6	0,06383	0,17377	77	31	0,32979	0,67225
28	12	0,12766	0,27197	78	27	0,28723	0,58880
29	22	0,23404	0,47901	79	7	0,07447	0,18836
30	34	0,36170	0,72986	80	12	0,12766	0,27197
31	27	0,28723	0,58880	81	42	0,44681	0,85446
32	2	0,02128	0,12281	82	29	0,30851	0,63130
33	13	0,13830	0,29067	83	24	0,25532	0,52320
34	32	0,34043	0,69201	84	26	0,27660	0,56711
35	28	0,29787	0,61021	85	30	0,31915	0,65200
36	5	0,05319	0,15992	86	79	0,84043	0,99905
37	17	0,18085	0,37079	87	23	0,24468	0,50111
38	12	0,12766	0,27197	88	14	0,14894	0,30994
39	10	0,10638	0,23647	89	22	0,23404	0,47901
40	10	0,10638	0,23647	90	21	0,22340	0,45697
41	8	0,08511	0,20368	91	28	0,29787	0,61021
42	8	0,08511	0,20368	92	17	0,18085	0,37079
43	94	1,00000	0,99996	93	8	0,08511	0,20368
44	40	0,42553	0,82765	94	23	0,24468	0,50111
45	12	0,12766	0,27197	95	20	0,21277	0,43507
46	17	0,18085	0,37079	96	43	0,45745	0,86675
47	21	0,22340	0,45697	97	16	0,17021	0,35006
48	9	0,09574	0,21973	98	31	0,32979	0,67225
49	30	0,31915	0,65200	99	18	0,19149	0,39192
50	24	0,25532	0,52320	100	54	0,57447	0,95736

NOTA: 1º PROC é igual à saída dividida por 94 e 2º PROC é igual distribuição normal cumulativa da saída

APÊNDICE IV

EXEMPLO NUMÉRICO DE UMA REDE NEURAL ARTIFICIAL COM UMA CAMADA.

São dados os padrões:

Da classe A (resposta 1): $A_1 = (0,2)$, $A_2 = (1,2)$, $A_3 = (1,3)$

Da classe B (resposta 0): $B_1 = (1,0)$, $B_2 = (2,1)$


Através de uma rede neural, utilizando o algoritmo *back-propagation*, e a função de transferência sigmoideal, devem ser calculados os pesos adequados para que os padrões A e B sejam corretamente mapeados na saída.

Resolução:

Sejam $w_1 = w_2 = \theta = 0$ e $\gamma = 0,8$ (valores arbitrários)

1. Primeira iteração

1.1 Padrão A_1



Propagação *forward*:

$$i^{A1} = \sum_j w_j x_j^{A1} + \theta = w_1 x_1 + w_2 x_2 + \theta = 0.0 + 2.0 + 0 = 0$$

$$a^{A1} = \frac{1}{1 + e^{-i^{A1}}} = \frac{1}{1 + e^{-0}} = 0,5$$

Propagação *backward*:


$$\delta^{A1} = d^{A1} - a^{A1} = 1 - 0,5 = 0,5$$

$$\Delta w_1 = \gamma \cdot x_1 \delta^{A1} = 0,8 \cdot 0 \cdot 0,5 = 0 \rightarrow w_1 = w_{1a} + \Delta w_1 = 0 + 0 = 0$$

$$\Delta w_2 = \gamma \cdot x_2 \delta^{A1} = 0,8 \cdot 2 \cdot 0,5 = 0,8 \rightarrow w_2 = w_{2a} + \Delta w_2 = 0 + 0,8 = 0,8$$

$$\Delta \theta = \gamma \cdot \theta \delta^{A1} = 0,8 \cdot 1 \cdot 0,5 = 0,4 \rightarrow \theta = \theta_a + \Delta \theta = 0 + 0,4 = 0,4$$

1.2 Padrão A_2



Propagação *forward*:

$$i^{A2} = \sum_j w_j x_j^{A2} + \theta = w_1 x_1 + w_2 x_2 + \theta = 0 \cdot 1 + 0,8 \cdot 2 + 0,4 = 2$$

$$a^{A2} = \frac{1}{1 + e^{-i^{A2}}} = \frac{1}{1 + e^{-2}} = 0,88$$

Propagação *backward*:

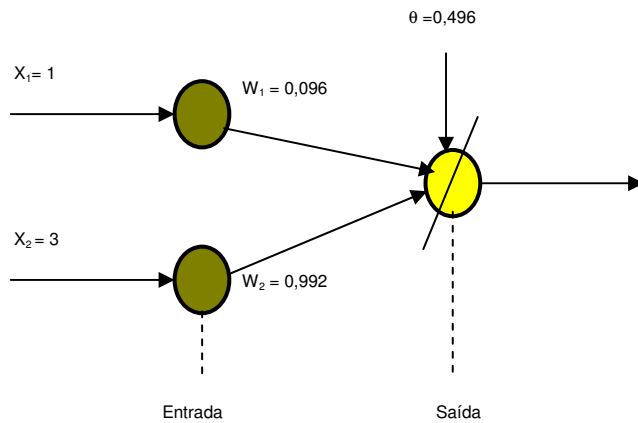
$$\delta^{A2} = d^{A2} - a^{A2} = 1 - 0,88 = 0,12$$

$$\Delta w_1 = \gamma \cdot x_1 \delta^{A2} = 0,8 \cdot 1 \cdot 0,12 = 0,096 \rightarrow w_1 = w_{1a} + \Delta w_1 = 0 + 0,096 = 0,096$$

$$\Delta w_2 = \gamma \cdot x_2 \delta^{A2} = 0,8 \cdot 2 \cdot 0,12 = 0,192 \rightarrow w_2 = w_{2a} + \Delta w_2 = 0,8 + 0,192 = 0,992$$

$$\Delta \theta = \gamma \cdot \theta \delta^{A2} = 0,8 \cdot 1 \cdot 0,12 = 0,096 \rightarrow \theta = \theta_a + \Delta \theta = 0,4 + 0,096 = 0,496$$

1.3 Padrão A₃. Analogamente aos itens 1.1 e 1.2 temos:



Propagação *forward*:

$$i^{A3} = 3,568$$

$$a^{A3} = 0,972$$

Propagação *backward*:


$$\delta^{A3} = 0,0274$$

$$w_1 = 0,118$$

$$w_2 = 1,058$$

$$\theta = 0,518$$

1.4 Padrão B₁. Analogamente aos itens 1.1 e 1.2 temos:



Propagação forward:

$$i^{B1} = 0,636$$

$$a^{B1} = 0,654$$

Propagação backward:


$$\delta^{B1} = -0,654$$

$$w_1 = -0,405$$

$$w_2 = 1,058$$

$$\theta = -0,005$$

1.5 **Padrão B₂**. Analogamente aos itens 1.1 e 1.2 temos:

**Propagação forward:**

$$i^{B2} = 0,243$$

$$a^{B2} = 0,56$$

Propagação backward:

$$\delta^{B2} = -0,56$$

$$w_1 = -1,301$$

$$w_2 = 0,61$$

$$\theta = -0,453$$

Fim da primeira iteração.

Análise da situação atual:

- Pesos: $w_1 = -1,301$ $w_2 = 0,61$ $\theta = -0,453$
- Padrão A₁:
$$i^{A1} = \sum_j w_j x_j^{A1} + \theta = w_1 x_1 + w_2 x_2 + \theta =$$

$$= 0 \cdot (-1,301) + 2 \cdot 0,61 + (-0,453) = 0,767$$

$$a^{A1} = \frac{1}{1 + e^{-i^{A1}}} = 0,68$$
- Padrão A₂: $a^{A2} = 0,37$
- Padrão A₃: $a^{A3} = 0,52$
- Padrão B₁: $a^{B1} = 0,014$
- Padrão B₂: $a^{B2} = 0,079$
- Erro:
$$E = \sum_p E^p = \frac{1}{2} \sum (d^p - a_h^p)^2$$

$$E = \frac{1}{2} [(1 - 0,68)^2 + (1 - 0,37)^2 + (1 - 0,52)^2 + (0 - 0,014)^2 + (0 - 0,079)^2]$$

$$E = 0,377$$

2. Segunda iteração

Apresentam-se novamente todos os padrões começando com os pesos obtidos ao final da primeira iteração. Feito isto se tem:

- Saídas dos padrões:

$$a^{A1} = 0,68; \quad a^{A2} = 0,67; \quad a^{A3} = 0,98; \quad a^{B1} = 0,28; \quad a^{B2} = 0,27$$


- Pesos:

$$w_1 = -1,69; \quad w_2 = 1,46; \quad \theta = -0,37$$

Fim da segunda iteração.**Análise da situação atual:**

- Pesos: $w_1 = -1,69$ $w_2 = 1,46$ $\theta = -0,37$
- Padrão A₁: $a^{A1} = 0,93$

- Padrão A_2 : $a^{A_2} = 0,7$
- Padrão A_3 : $a^{A_3} = 0,91$
- Padrão B_1 : $a^{B_1} = 0,11$
- Padrão B_2 : $a^{B_2} = 0,092$
- Erro: $E = 0,061$
- Interpretação Geométrica:
 $w_1x_1 + w_2x_2 + \theta = 0$
 $-1,69x_1 + 1,46x_2 = 0,37$



- Determinação de classe para um padrão desconhecido:

$$P_1 = (1,4) \quad i^{P_1} = 3,78 \Rightarrow a^{P_1} = 0,977 \Rightarrow \text{Classe } A$$

$$P_2 = (1,1) \quad i^{P_2} = -0,58 \Rightarrow a^{P_2} = 0,36 \Rightarrow \text{Classe } B$$

APÊNDICE V

EXEMPLO NUMÉRICO DE UMA REDE NEURAL ARTIFICIAL COM DUAS CAMADAS.

São dados os padrões:


Da classe A (resposta 1): $A_1 = (0,1)$, $A_2 = (0,2)$, $A_3 = (1,1)$

Da classe B (resposta 0): $B_1 = (2,0)$, $B_2 = (2,1)$

Através de uma rede neural de duas camadas, com três neurônios na camada escondida e um na saída os pesos adequados devem ser calculados para que os padrões A e B sejam corretamente mapeados na saída, utilizando o algoritmo *back-propagation*, e a função de transferência sigmoial. São adotados como pesos Iniciais:

$$\begin{array}{lll}
 w(1,1,1) = 0 & w(1,2,1) = 0 & w(1,3,1) = \theta(1,1) = 0 \\
 w(1,1,2) = 0,1 & w(1,2,2) = -0,1 & w(1,3,2) = \theta(1,2) = 0,1 \\
 w(1,1,3) = -0,1 & w(1,2,3) = 0 & w(1,3,3) = \theta(1,3) = -0,1 \\
 w(2,1,1) = 0 & w(2,2,1) = -0,2 & w(2,3,1) = 0,2 \\
 w(2,4,1) = \theta(2,1) = 0 & &
 \end{array}$$

Taxa de aprendizagem $\gamma = 0,8$



Resolução:

Primeira iteração

Padrão A₁**Propagação forward:**

$$i_{i=1}^{A1} = \sum_j w_{1j} x_j^{A1} + \theta_{1i} = w_{11} x_1 + w_{12} x_2 + \theta_{11} = 0.0 + 0.1 + 0 = 0$$

$$a_{i=1}^{A1} = \frac{1}{1 + e^{-i_{i=1}^{A1}}} = \frac{1}{1 + e^{-0}} = 0,5$$

$$i_{i=2}^{A1} = \sum_j w_{2j} x_j^{A1} + \theta_{2i} = w_{21} x_1 + w_{22} x_2 + \theta_{2i} = 0,1.0 + (-0,1).1 + 0,1 = 0$$

$$a_{i=2}^{A1} = \frac{1}{1 + e^{-i_{i=2}^{A1}}} = \frac{1}{1 + e^{-0}} = 0,5$$

$$i_{i=3}^{A1} = \sum_j w_{3j} x_j^{A1} + \theta_{3i} = w_{31} x_1 + w_{32} x_2 + \theta_{3i} = -0,1.0 + 0,1 - 0,1 = -0,1$$

$$a_{i=3}^{A1} = \frac{1}{1 + e^{-i_{i=3}^{A1}}} = \frac{1}{1 + e^{-0,1}} = 0,475$$

$$i_{h=1}^{A1} = \sum_i w_{hi} a_i^{A1} + \theta_{hi} = w_{11} a_{i=1}^{A1} + w_{12} a_{i=2}^{A1} + w_{13} a_{i=3}^{A1} + \theta_{11} =$$

$$0.0,5 + (-0,2).0,5 + 0,2.0,475 + 0 = -0,005$$

$$a_{h=1}^{A1} = \frac{1}{1 + e^{-i_{h=1}^{A1}}} = \frac{1}{1 + e^{-0,005}} = 0,4987$$

Propagação backward:

$$\Delta^{A1} w(2,1,1)(t) = \gamma \cdot (d^{A1} - a_{h=1}^{A1}) \cdot a_{h=1}^{A1} \cdot (1 - a_{h=1}^{A1}) \cdot a_{h=1}^{A1} \cdot a_{i=1}^{A1}$$

$$= 0,8 \cdot (1 - 0,4987) \cdot 0,4987 \cdot (1 - 0,4987) \cdot 0,5 = 0,05012$$

$$w^{A1}(2,1,1)(t) = w(2,1,1)(t-1) + \Delta w^{A1}(2,1,1)(t) = 0 + 0,05012 = 0,05012$$

$$\Delta^{A1} w(2,2,1)(t) = \gamma \cdot (d^{A1} - a_{h=1}^{A1}) \cdot a_{h=1}^{A1} \cdot (1 - a_{h=1}^{A1}) \cdot a_{h=1}^{A1} \cdot a_{i=2}^{A1}$$

$$= 0,8 \cdot (1 - 0,4987) \cdot 0,4987 \cdot (1 - 0,4987) \cdot 0,5 = 0,05012$$

$$w^{A_1}(2,2,1)(t) = w(2,2,1)(t-1) + \Delta w^{A_1}(2,2,1)(t) = -0,2 + 0,05012 = -0,14988$$

$$\Delta^{A_1} w(2,3,1)(t) = 0,04761 \quad w^{A_1}(2,3,1)(t) = 0,24761$$

$$\Delta^{A_1} w(2,4,1)(t) = 0,10024 \quad w^{A_1}(2,4,1)(t) = 0,10024$$

$$\Delta^{A_1} w(1,1,1)(t) = \gamma \cdot a_{i=1}^{A_1} \cdot (1 - a_{i=1}^{A_1}) \cdot (d^{A_1} - a_{h=1}^{A_1}) \cdot a_{h=1}^{A_1} \cdot (1 - a_{h=1}^{A_1}) \cdot w(2,1,1) \cdot x_1 \\ = 0,8 \cdot 0,5 \cdot (1 - 0,5) \cdot (1 - 0,4987) \cdot 0,4987 \cdot (1 - 0,4987) \cdot 0,05012 \cdot 0 = 0$$

$$w^{A_1}(1,1,1)(t) = w(1,1,1)(t-1) + \Delta w^{A_1}(1,1,1)(t) = 0 + 0 = 0$$

$$\Delta^{A_1} w(1,2,1)(t) = 0,001256 \quad w^{A_1}(1,2,1)(t) = 0,001256$$

$$\Delta^{A_1} w(1,3,1)(t) = 0,001256 \quad w^{A_1}(1,3,1)(t) = 0,001256$$

$$\Delta^{A_1} w(1,1,2)(t) = 0 \quad w^{A_1}(1,1,2)(t) = 0,1$$

$$\Delta^{A_1} w(1,2,2)(t) = -0,003752 \quad w^{A_1}(1,2,2)(t) = -0,103752$$

$$\Delta^{A_1} w(1,3,2)(t) = -0,003752 \quad w^{A_1}(1,3,2)(t) = 0,09625$$

$$\Delta^{A_1} w(1,1,3)(t) = 0 \quad w^{A_1}(1,1,3)(t) = -0,1$$

$$\Delta^{A_1} w(1,2,3)(t) = 0,006192 \quad w^{A_1}(1,2,3)(t) = 0,006192$$

$$\Delta^{A_1} w(1,3,3)(t) = 0,006192 \quad w^{A_1}(1,3,3)(t) = -0,09381$$

Padrão B₁. Procedendo-se analogamente ao padrão A₁ tem-se:

$$w(1,1,1) = 0,000173317 \quad w(1,2,1) = 0,001256237$$

$$w(1,3,1) = 0,001342896 \quad w(1,1,2) = 0,111014548$$

$$w(1,2,2) = -0,103756221 \quad w(1,3,2) = 0,101751053$$

$$w(1,1,3) = -0,110548667 \quad w(1,2,3) = 0,006190447$$

$$w(1,3,3) = -0,099083887 \quad w(2,1,1) = -0,003249275$$

$$w(2,2,1) = -0,211059365 \quad w(2,3,1) = 0,202060152$$

$$w(2,4,1) = -0,006431542$$

Padrão A₂. Procedendo-se analogamente ao padrão A₁ tem-se:

$$w(1,1,1) = 0,000200833 \quad w(1,2,1) = 0,003617176$$

$$w(1,3,1) = 0,002537123 \quad w(1,1,2) = 0,111143149$$

$$w(1,2,2) = -0,111940522 \quad w(1,3,2) = 0,097723203$$

$$w(1,1,3) = -0,110622276 \quad w(1,2,3) = 0,018718488$$

$$w(1,3,3) = -0,092856671 \quad w(2,1,1) = 0,047039055$$

$$w(2,2,1) = -0,1635182 \qquad w(2,3,1) = 0,250075959$$

$$w(2,4,1) = 0,093950922$$

Padrão B₂. Procedendo-se analogamente ao padrão A₁ tem-se:

$$w(1,1,1) = 0,000532321 \qquad w(1,2,1) = 0,003786498$$

$$w(1,3,1) = 0,002704656 \qquad w(1,1,2) = 0,122812995$$

$$w(1,2,2) = -0,106166415 \qquad w(1,3,2) = 0,103527718$$

$$w(1,1,3) = -0,121262453 \qquad w(1,2,3) = 0,013462827$$

$$w(1,3,3) = -0,098144546 \qquad w(2,1,1) = -0,006241988$$

$$w(2,2,1) = -0,222127716 \qquad w(2,3,1) = 0,204753514$$

$$w(2,4,1) = -0,012262713$$

Padrão A₃. Procedendo-se analogamente ao padrão A₁ tem-se:

$$w(1,1,1) = 0,001714674 \qquad w(1,2,1) = 0,004950878$$

$$w(1,3,1) = 0,003869036 \qquad w(1,1,2) = 0,118675533$$

$$w(1,2,2) = -0,110370444 \qquad w(1,3,2) = 0,099323689$$

$$w(1,1,3) = -0,114999049 \qquad w(1,2,3) = 0,019755688$$

$$w(1,3,3) = -0,091851685 \qquad w(2,1,1) = 0,044948929$$

$$w(2,2,1) = -0,16804964 \qquad w(2,3,1) = 0,250526376$$

$$w(2,4,1) = 0,089757187$$

Fim da primeira iteração.

Análise da situação atual:

- Padrão A₁: $a^{A1} = 0,53731$
- Padrão A₂: $a^{A2} = 0,538782$
- Padrão A₃: $a^{A3} = 0,534293$
- Padrão B₁: $a^{B1} = 0,529853$
- Padrão B₂: $a^{B2} = 0,5313$

Erro:

$$E = \sum_p E^p = \frac{1}{2} \sum (d^p - a_h^p)^2$$

$$E = \frac{1}{2} \left[(1 - 0,53731)^2 + (1 - 0,538782)^2 + (1 - 0,534293)^2 + \right. \\ \left. (0 - 0,529853)^2 + (0 - 0,5313)^2 \right]$$

$$E = 0,60335$$

APÊNDICE VI

TABELA A.3 - ATRIBUTOS CONSIDERADOS NO TRABALHO E AS SUAS RESPECTIVAS CODIFICAÇÕES TORNANDO-OS BINÁRIOS

Atributos	Valores originais dos Atributos	Intervalos	Número de padrões em cada intervalo	Entrada 1	Entrada 2	Entrada 3	Entrada 4	Número de Entradas
1.1 Objeto do Processo – Falta de Registro em CPTS (atributo nominal)				I₁	---	---	---	1
	1 = sim	1 = sim	11	1	---	---	---	
	0 = não	0= não	89	0	---	---	---	
1.2 Objeto do Processo – Horas Extras. (atributo nominal)				I₂	---	---	---	1
	1 = sim	1 = sim	87	1	---	---	---	
	0 = não	0= não	13	0	---	---	---	
1.3 Objeto do Processo – FGTS (atributo nominal)				I₃				1
	1 = sim	1 = sim	52	1	---	---	---	
	0 = não	0= não	48	0	---	---	---	
1.4 Objeto do Processo – Verbas Rescisórias (atributo nominal)				I₄				1
	1 = sim	1 = sim	65	1	---	---	---	
	0 = não	0= não	35	0	---	---	---	
1.5 Objeto do Processo – Seguro Desemprego (atributo nominal)				I₅	---	---	---	1
	1 = sim	1 = sim	19	1	---	---	---	
	0 = não	0= não	81	0	---	---	---	
1.6 Objeto do Processo – Vale Transporte (atributo nominal)				I₆	---	---	---	1
	1 = sim	1 = sim	13	1	---	---	---	
	0 = não	0= não	87	0	---	---	---	
1.7 Objeto do Processo – Adicional Insalubridade (atributo nominal)				I₇	---	---	---	1
	1 = sim	1 = sim	21	1	---	---	---	
	0 = não	0= não	79	0	---	---	---	
1.8 Objeto do Processo – Multa Art 477 (atributo nominal)				I₈	---	---	---	1
	1 = sim	1 = sim	55	1	---	---	---	
	0 = não	0= não	45	0	---	---	---	
1.9 Objeto do Processo – Adicional Noturno (atributo nominal)				I₉				1
	1 = sim	1 = sim	4	1	---	---	---	
	0 = não	0= não	96	0	---	---	---	
1.10 Objeto do Processo – Diferenas Salariais (atributo nominal)				I₁₀				1
	1 = sim	1 = sim	28	1	---	---	---	
	0 = não	0= não	72	0	---	---	---	
1.11 Objeto do Processo – Multa Art 467 (atributo nominal)				I₁₁	---	---	---	1
	1 = sim	1 = sim	28	1	---	---	---	
	0 = não	0= não	72	0	---	---	---	

CONTINUA

APÊNDICE VII

TABELA A.4 – VARIAÇÃO DO NÚMERO DE NEURÔNIOS DA CAMADA ESCONDIDA - TESTE III, 23 COMPONENTES PRINCIPAIS, 1º PROCESSO, 50 ITERAÇÕES

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,0851	0,1280	0,0956	0,1118	0,1192	0,1322	0,1059	0,1169	0,1027	0,1004	0,0802	0,0818	0,0953	0,1203	0,1002
0,0957	0,1353	0,0962	0,1710	0,1042	0,1345	0,1329	0,0978	0,1178	0,1232	0,1156	0,1293	0,1166	0,1396	0,1122
0,2766	0,2352	0,3069	0,2335	0,2677	0,2377	0,2738	0,2470	0,2890	0,2803	0,2753	0,2514	0,2829	0,2687	0,2535
0,9149	0,8719	0,8727	0,9014	0,9069	0,9147	0,9181	0,9354	0,9194	0,9194	0,9151	0,9206	0,9163	0,9280	0,9175
0,1489	0,1311	0,1080	0,1753	0,1570	0,1495	0,1257	0,0808	0,1280	0,1472	0,1072	0,1558	0,1522	0,1454	0,1456
0,2340	0,3381	0,2520	0,2612	0,2441	0,2378	0,2396	0,2630	0,2390	0,2360	0,2557	0,2617	0,2369	0,2297	0,2411
0,2234	0,2425	0,2599	0,1925	0,1965	0,2221	0,2203	0,2227	0,2233	0,2319	0,2280	0,2453	0,2268	0,2243	0,2379
0,3936	0,4810	0,4417	0,4361	0,4049	0,3945	0,3965	0,3897	0,4319	0,4063	0,4178	0,3965	0,3972	0,3934	0,3946
0,1489	0,1175	0,1785	0,1422	0,1401	0,1466	0,1257	0,1436	0,1539	0,1283	0,1360	0,1381	0,1585	0,1209	0,1421
0,3830	0,3305	0,3431	0,3766	0,3706	0,3811	0,3918	0,3880	0,3961	0,3809	0,3797	0,3856	0,3943	0,3896	0,3865
0,1489	0,1259	0,3030	0,1577	0,1533	0,1342	0,1583	0,1575	0,1809	0,1620	0,1465	0,1686	0,1550	0,1505	0,1884
0,1489	0,1512	0,1657	0,1399	0,1657	0,1647	0,1656	0,1648	0,1796	0,1637	0,1637	0,1787	0,1471	0,1547	0,1618
0,0319	0,1157	0,0555	0,0341	0,0199	0,0666	0,0489	0,0451	0,0494	0,0635	0,0640	0,0486	0,0650	0,0616	0,0492
0,0426	0,1176	0,0586	0,0279	0,0543	0,0437	0,0305	0,0585	0,0622	0,0579	0,0518	0,0455	0,0551	0,0553	0,0546
0,9468	0,8632	0,8629	0,8998	0,9057	0,9143	0,9165	0,9224	0,9183	0,9121	0,9233	0,9214	0,9233	0,9174	0,9240
0,0213	0,1131	0,0621	0,0209	0,0914	0,0434	0,0495	0,0651	0,0566	0,0511	0,0704	0,0741	0,0619	0,0657	0,0461
0,1383	0,1158	0,0831	0,1356	0,1794	0,1023	0,1719	0,1214	0,1439	0,1605	0,0970	0,1195	0,1267	0,1471	0,1316
0,1489	0,1913	0,1383	0,1918	0,1484	0,1705	0,1456	0,1833	0,1617	0,1374	0,1647	0,1617	0,1500	0,1650	0,1741
0,3404	0,3825	0,3341	0,3342	0,3319	0,3725	0,3318	0,3388	0,3135	0,3291	0,3194	0,3411	0,3386	0,3397	0,3318
0,2660	0,3314	0,2840	0,2790	0,2614	0,2452	0,2486	0,2663	0,2706	0,2700	0,2718	0,2684	0,2864	0,2798	0,2801
0,0426	0,1125	0,0937	0,0592	0,0854	0,0546	0,0763	0,0477	0,0920	0,0658	0,1008	0,0913	0,0794	0,0580	0,0693
0,1489	0,1359	0,0944	0,1136	0,1573	0,1248	0,1442	0,1290	0,1175	0,1594	0,1091	0,1592	0,1238	0,1197	0,1398
0,0851	0,1067	0,0559	0,0839	0,0829	0,0602	0,1220	0,0900	0,0436	0,0738	0,0554	0,0842	0,0776	0,0984	0,0786
0,0745	0,1075	0,1056	0,0661	0,0705	0,0810	0,0357	0,1324	0,0740	0,0987	0,0977	0,0806	0,0787	0,0571	0,0790
0,2340	0,1170	0,2309	0,2237	0,1803	0,2335	0,2316	0,2347	0,1926	0,2209	0,2229	0,2236	0,2254	0,2337	0,2266
0,2447	0,2354	0,3038	0,2398	0,2725	0,2620	0,2630	0,2655	0,2745	0,2335	0,2347	0,2644	0,2514	0,2511	0,2643
0,0638	0,1041	0,0819	0,0244	0,0401	0,0646	0,0386	0,0389	0,0526	0,0574	0,0406	0,0580	0,0562	0,0490	0,0519
0,1277	0,1294	0,1268	0,1315	0,1863	0,1324	0,0970	0,1300	0,1601	0,1372	0,1531	0,1115	0,1353	0,1186	0,1295
0,2340	0,2834	0,2209	0,2533	0,2359	0,2585	0,2379	0,2331	0,2445	0,2471	0,2323	0,2482	0,2413	0,2430	0,2456
0,3617	0,2231	0,3524	0,3507	0,3277	0,3213	0,3570	0,3447	0,3627	0,3577	0,3572	0,3573	0,3512	0,3536	0,3659

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,2872	0,1187	0,1853	0,2622	0,2484	0,2969	0,2822	0,2882	0,3033	0,2587	0,2656	0,2191	0,2968	0,2877	0,2619
0,0213	0,1084	0,0770	0,0207	0,0510	0,0628	0,0338	0,0452	0,0486	0,0542	0,0400	0,0550	0,0572	0,0545	0,0474
0,1383	0,1180	0,1258	0,1427	0,1494	0,1905	0,1385	0,1406	0,1044	0,1505	0,1583	0,1543	0,1182	0,1393	0,1165
0,3404	0,3209	0,3108	0,3628	0,3708	0,3436	0,3490	0,3458	0,3496	0,3362	0,3441	0,3291	0,3486	0,3425	0,3133
0,2979	0,1627	0,3562	0,2931	0,3224	0,2830	0,3019	0,2975	0,3034	0,3022	0,3063	0,3113	0,2981	0,3002	0,3120
0,0532	0,1149	0,0582	0,0425	0,0510	0,0352	0,0445	0,0627	0,0440	0,0476	0,0659	0,0313	0,0301	0,0616	0,0562
0,1809	0,1366	0,0912	0,1354	0,1371	0,1644	0,1197	0,1815	0,1246	0,1671	0,1049	0,1601	0,1455	0,0948	0,1445
0,1277	0,1307	0,0870	0,1157	0,1551	0,0971	0,1081	0,0973	0,1882	0,1203	0,1103	0,0867	0,1183	0,0874	0,0950
0,1064	0,1163	0,0982	0,1088	0,0900	0,1220	0,0999	0,1178	0,0813	0,1016	0,0830	0,1128	0,0787	0,0799	0,0853
0,1064	0,1281	0,1624	0,1025	0,1283	0,0820	0,0757	0,0815	0,1014	0,0966	0,1247	0,1274	0,1127	0,0936	0,1166
0,0851	0,1245	0,0818	0,0798	0,0723	0,0869	0,1023	0,1014	0,0946	0,1014	0,1002	0,0776	0,0813	0,0643	0,0914
0,0851	0,1146	0,0751	0,0625	0,0678	0,0701	0,0971	0,0879	0,0938	0,1061	0,0867	0,0590	0,0507	0,0901	0,0914
1,0000	0,8669	0,8650	0,9034	0,9067	0,9217	0,9194	0,9288	0,9075	0,9265	0,9358	0,9415	0,9134	0,9257	0,9459
0,4255	0,3727	0,2996	0,3745	0,4394	0,4251	0,4303	0,4239	0,4099	0,4268	0,4259	0,4212	0,4220	0,4284	0,4115
0,1277	0,1239	0,0991	0,1142	0,1204	0,1136	0,1470	0,1334	0,1274	0,1384	0,1292	0,1220	0,0991	0,1357	0,1258
0,1809	0,2183	0,2516	0,2500	0,2147	0,2121	0,2003	0,2380	0,2126	0,2134	0,2337	0,2169	0,2084	0,1967	0,2168
0,2234	0,2189	0,2281	0,2280	0,2394	0,2139	0,2204	0,2471	0,2043	0,2214	0,2198	0,2182	0,2225	0,2164	0,2190
0,0957	0,1160	0,0719	0,1083	0,1049	0,1075	0,0970	0,0980	0,1125	0,0937	0,1029	0,0997	0,0920	0,1097	0,1052
0,3191	0,4033	0,3740	0,3400	0,3373	0,3402	0,3171	0,3173	0,3190	0,3208	0,3336	0,3237	0,3147	0,3203	0,3153
0,2553	0,2848	0,2575	0,2141	0,2819	0,2512	0,2807	0,2486	0,2638	0,2607	0,2562	0,2712	0,2509	0,2656	0,2577
0,3404	0,2368	0,3398	0,2753	0,3281	0,3481	0,3451	0,3114	0,3174	0,3494	0,3365	0,3372	0,3356	0,3515	0,3504
0,1702	0,1450	0,1500	0,1677	0,1881	0,1447	0,1734	0,1660	0,1688	0,1384	0,1542	0,1513	0,1688	0,1657	0,1396
0,1915	0,1226	0,1374	0,1486	0,1505	0,2045	0,1710	0,1689	0,1694	0,2135	0,1986	0,1774	0,1921	0,1916	0,1836
0,0638	0,1157	0,0646	0,0636	0,0208	0,0817	0,0368	0,0495	0,0371	0,0399	0,0558	0,0398	0,0587	0,0259	0,0846
0,1809	0,1382	0,1421	0,1012	0,1750	0,1765	0,1892	0,1618	0,1280	0,1321	0,1441	0,1646	0,1565	0,2127	0,1557
0,2021	0,2277	0,1962	0,1817	0,1029	0,1815	0,1967	0,1543	0,1570	0,1790	0,1820	0,1719	0,1832	0,2011	0,1829
0,1489	0,1282	0,0920	0,1317	0,0908	0,1005	0,0990	0,1277	0,0845	0,0796	0,1037	0,0844	0,1294	0,1019	0,1184
0,0851	0,1514	0,1082	0,1229	0,1174	0,0992	0,1176	0,1034	0,0971	0,1036	0,1202	0,1134	0,0922	0,0975	0,1153
0,5106	0,2939	0,3771	0,4992	0,4983	0,5029	0,5065	0,5130	0,4918	0,5174	0,5043	0,5003	0,5080	0,5003	0,5123
0,3511	0,2125	0,2343	0,3076	0,3227	0,2736	0,3155	0,3288	0,2901	0,3310	0,3233	0,3075	0,3259	0,3058	0,3178
0,1596	0,1800	0,2116	0,1977	0,1776	0,1806	0,1837	0,1616	0,1553	0,1929	0,1510	0,1736	0,1847	0,1788	0,2013
0,2553	0,1401	0,2030	0,2509	0,1758	0,2141	0,2051	0,2497	0,1921	0,2192	0,2363	0,2254	0,2394	0,2258	0,2202

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,0851	0,1350	0,0855	0,0694	0,0707	0,0596	0,1108	0,0571	0,0726	0,0585	0,0597	0,0806	0,0727	0,0675	0,0928
0,2234	0,2511	0,2341	0,2652	0,2124	0,2440	0,1919	0,2165	0,2032	0,2152	0,2263	0,2075	0,2116	0,2046	0,2104
0,1489	0,2167	0,2387	0,2072	0,1844	0,2013	0,1951	0,1836	0,2285	0,1578	0,1912	0,2030	0,1849	0,1981	0,1896
0,2234	0,2327	0,2132	0,2129	0,1968	0,2533	0,2217	0,2062	0,2489	0,2363	0,2224	0,2196	0,2264	0,2220	0,2270
0,2553	0,3087	0,3330	0,2713	0,2469	0,2596	0,2485	0,2562	0,2961	0,2555	0,2557	0,2539	0,2628	0,2523	0,2596
0,2340	0,1829	0,1405	0,2731	0,2186	0,2171	0,2290	0,2352	0,2099	0,2288	0,2327	0,2297	0,2518	0,2578	0,2524
0,8404	0,8780	0,8760	0,9103	0,9123	0,8724	0,8667	0,8787	0,8736	0,9187	0,8774	0,8674	0,9298	0,8987	0,9038
0,3617	0,3379	0,3649	0,3758	0,3602	0,3624	0,3699	0,3549	0,3480	0,3615	0,3630	0,3675	0,3503	0,3399	0,3402
0,4255	0,4961	0,3973	0,4267	0,4227	0,4383	0,4244	0,4251	0,4248	0,4229	0,4166	0,4250	0,4157	0,4255	0,4185
0,0213	0,1331	0,0739	0,0244	0,0483	0,0632	0,0567	0,0460	0,0632	0,0361	0,0622	0,0396	0,0458	0,0584	0,0650
0,0957	0,1298	0,1143	0,1144	0,1031	0,0942	0,0730	0,0979	0,0596	0,0812	0,1168	0,1000	0,0691	0,0723	0,0663
0,1489	0,1739	0,1534	0,1750	0,1794	0,0971	0,1515	0,1483	0,1367	0,1292	0,1673	0,1477	0,1696	0,1528	0,1332
0,2766	0,1391	0,3326	0,2560	0,2724	0,2687	0,2658	0,2665	0,2701	0,2716	0,2659	0,2695	0,2719	0,2767	0,2807
0,3404	0,3030	0,1758	0,6618	0,5134	0,7563	0,4375	0,3254	0,5197	0,8755	0,8751	0,6387	0,2777	0,5946	0,5232
0,3298	0,0517	0,1001	0,4919	0,4316	0,6942	0,3884	0,3959	0,2903	0,7581	0,7705	0,5026	0,1524	0,4680	0,6468
0,2872	0,2520	0,1033	0,3703	0,3645	0,7039	0,2888	0,1901	0,1264	0,4146	0,7158	0,3085	0,1503	0,2399	0,5100
0,0745	0,0301	0,0689	0,1385	0,1536	0,5575	0,1883	0,1663	0,1436	0,4379	0,6639	0,3311	0,0932	0,2195	0,3642
0,1277	0,0218	0,0190	0,1215	0,1158	0,5118	0,1014	0,1056	0,1013	0,3952	0,6580	0,1829	0,1103	0,1455	0,1729
0,4468	0,2556	0,0904	0,3477	0,4789	0,5222	0,2255	0,1673	0,1211	0,5463	0,8009	0,2802	0,1886	0,2895	0,4284
0,3085	0,2213	0,1046	0,3151	0,3450	0,7622	0,2271	0,2297	0,1590	0,4673	0,7608	0,3306	0,1531	0,3196	0,5778
0,2553	0,0439	0,0699	0,1709	0,2022	0,7804	0,2200	0,1575	0,1207	0,3093	0,6093	0,2910	0,1117	0,3137	0,4409
0,2766	0,1144	0,0563	0,3313	0,3161	0,4897	0,1869	0,1515	0,1299	0,3630	0,5898	0,3005	0,1248	0,2073	0,3206
0,3191	0,4197	0,1187	0,7225	0,4151	0,6923	0,3272	0,2902	0,2978	0,5889	0,8353	0,4708	0,3651	0,3460	0,6249
0,8404	0,4985	0,4995	0,9362	0,9359	0,9745	0,7498	0,9309	0,7284	0,9576	0,9614	0,8636	0,7796	0,9086	0,8886
0,2447	0,1503	0,0641	0,5148	0,5017	0,6027	0,2371	0,3362	0,1572	0,5407	0,7760	0,4741	0,1435	0,3321	0,2860
0,1489	0,1124	0,0954	0,2210	0,1657	0,4066	0,1505	0,1547	0,0988	0,3320	0,7019	0,2853	0,1050	0,2403	0,3382
0,2340	0,0660	0,0827	0,3253	0,4414	0,4182	0,1848	0,2287	0,1232	0,4753	0,6524	0,3120	0,1432	0,3715	0,3997
0,2234	0,0660	0,0827	0,3253	0,4414	0,4182	0,1848	0,2287	0,1232	0,4753	0,6524	0,3120	0,1432	0,3715	0,3997
0,2979	0,0291	0,0612	0,5066	0,4679	0,7330	0,2261	0,2314	0,3594	0,3659	0,6709	0,5604	0,0862	0,3761	0,6325
0,1809	0,1846	0,0677	0,3266	0,2591	0,4015	0,2211	0,1430	0,1140	0,3351	0,7528	0,2649	0,1216	0,2733	0,3934
0,0851	0,0866	0,0216	0,3208	0,2256	0,6377	0,1619	0,0918	0,0713	0,3847	0,3631	0,2593	0,1004	0,2206	0,2380
0,2447	0,2795	0,1100	0,4733	0,5111	0,7308	0,2660	0,2425	0,1798	0,4187	0,6518	0,3587	0,1707	0,3007	0,4542

CONTINUA

CONCLUSÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,2128	0,0470	0,0581	0,3516	0,1984	0,5344	0,1757	0,2601	0,1159	0,4514	0,7545	0,3157	0,1161	0,2382	0,4859
0,4574	0,4260	0,2511	0,6296	0,6765	0,8323	0,3853	0,4246	0,5055	0,7303	0,8989	0,5522	0,2869	0,5698	0,6111
0,1702	0,0342	0,0557	0,3220	0,1720	0,5475	0,1329	0,2492	0,1686	0,4935	0,6843	0,3196	0,1350	0,2612	0,3909
0,3298	0,3858	0,1097	0,4378	0,4818	0,7179	0,2910	0,2774	0,1358	0,5348	0,8615	0,3937	0,2049	0,3767	0,6124
0,1915	0,0749	0,1178	0,1875	0,3862	0,6741	0,1843	0,2423	0,1287	0,4127	0,5891	0,2202	0,1944	0,4071	0,4394
0,5745	0,4658	0,1355	0,5627	0,7040	0,7771	0,5750	0,4987	0,4404	0,7683	0,9184	0,5750	0,3537	0,4650	0,7321
RMSE Tr	0,0697	0,0530	0,0319	0,0321	0,0269	0,0238	0,0229	0,0309	0,0228	0,0250	0,0238	0,0222	0,0249	0,0219
RMSE Tes	0,1480	0,2029	0,1656	0,1395	0,3692	0,0711	0,0840	0,1204	0,2512	0,4514	0,1404	0,1233	0,1133	0,2105
NEURÔNIOS	1	2	3	4	5	6	7	8	9	10	11	12	13	14

APÊNDICE VIII

TABELA A.5 – VARIAÇÃO DO NÚMERO DE ITERAÇÕES - TESTE III, 23 COMPONENTES PRINCIPAIS, 1º PROCESSO, 6 NEURÔNIOS NA CAMADA ESCONDIDA

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,0851	0,1344	0,1237	0,1156	0,1104	0,1059	0,1030	0,1011	0,0998	0,0987	0,0978	0,0910	0,0860	0,0851
0,0957	0,1407	0,1461	0,1445	0,1391	0,1329	0,1274	0,1229	0,1191	0,1160	0,1134	0,0998	0,0947	0,0960
0,2766	0,2355	0,2467	0,2622	0,2705	0,2738	0,2762	0,2782	0,2798	0,2808	0,2814	0,2794	0,2772	0,2767
0,9149	0,8405	0,8863	0,9038	0,9122	0,9181	0,9229	0,9263	0,9285	0,9299	0,9307	0,9307	0,9199	0,9166
0,1489	0,0789	0,0999	0,1143	0,1224	0,1257	0,1285	0,1312	0,1337	0,1357	0,1374	0,1449	0,1486	0,1487
0,2340	0,2816	0,2747	0,2573	0,2462	0,2396	0,2356	0,2336	0,2327	0,2325	0,2325	0,2331	0,2335	0,2338
0,2234	0,2467	0,2295	0,2234	0,2210	0,2203	0,2200	0,2200	0,2203	0,2207	0,2211	0,2231	0,2236	0,2234
0,3936	0,4554	0,4258	0,4114	0,4011	0,3965	0,3940	0,3929	0,3927	0,3929	0,3932	0,3938	0,3939	0,3935
0,1489	0,0798	0,0753	0,0879	0,1084	0,1257	0,1361	0,1423	0,1458	0,1478	0,1488	0,1496	0,1480	0,1486
0,3830	0,3479	0,3943	0,3921	0,3914	0,3918	0,3910	0,3896	0,3883	0,3873	0,3866	0,3835	0,3826	0,3829
0,1489	0,2035	0,1790	0,1692	0,1635	0,1583	0,1542	0,1513	0,1496	0,1487	0,1484	0,1517	0,1484	0,1488
0,1489	0,1571	0,1592	0,1654	0,1671	0,1656	0,1625	0,1593	0,1566	0,1545	0,1531	0,1503	0,1504	0,1494
0,0319	0,0795	0,0586	0,0541	0,0513	0,0489	0,0469	0,0450	0,0433	0,0418	0,0405	0,0341	0,0310	0,0297
0,0426	0,0472	0,0334	0,0312	0,0308	0,0305	0,0301	0,0299	0,0297	0,0298	0,0299	0,0341	0,0388	0,0385
0,9468	0,8370	0,8816	0,9016	0,9112	0,9165	0,9203	0,9227	0,9239	0,9244	0,9246	0,9264	0,9387	0,9456
0,0213	0,0703	0,0577	0,0535	0,0513	0,0495	0,0483	0,0474	0,0468	0,0464	0,0461	0,0433	0,0325	0,0262
0,1383	0,1357	0,1658	0,1759	0,1752	0,1719	0,1690	0,1662	0,1637	0,1615	0,1599	0,1514	0,1408	0,1386
0,1489	0,1530	0,1413	0,1407	0,1424	0,1456	0,1482	0,1503	0,1520	0,1534	0,1544	0,1518	0,1471	0,1487
0,3404	0,3595	0,3491	0,3345	0,3296	0,3318	0,3358	0,3384	0,3399	0,3407	0,3412	0,3421	0,3405	0,3404
0,2660	0,2053	0,2268	0,2418	0,2444	0,2486	0,2536	0,2580	0,2611	0,2632	0,2645	0,2665	0,2662	0,2660
0,0426	0,1340	0,0959	0,0884	0,0827	0,0763	0,0703	0,0655	0,0618	0,0590	0,0567	0,0454	0,0418	0,0426
0,1489	0,1372	0,1491	0,1493	0,1471	0,1442	0,1412	0,1388	0,1371	0,1361	0,1356	0,1445	0,1497	0,1497
0,0851	0,1620	0,1476	0,1354	0,1275	0,1220	0,1178	0,1144	0,1112	0,1081	0,1051	0,0854	0,0838	0,0848
0,0745	0,0396	0,0371	0,0356	0,0353	0,0357	0,0364	0,0373	0,0382	0,0393	0,0404	0,0500	0,0699	0,0741
0,2340	0,2068	0,2402	0,2315	0,2294	0,2316	0,2347	0,2372	0,2387	0,2396	0,2400	0,2381	0,2344	0,2343
0,2447	0,2963	0,2859	0,2786	0,2709	0,2630	0,2565	0,2521	0,2491	0,2471	0,2457	0,2415	0,2430	0,2442
0,0638	0,0718	0,0451	0,0406	0,0395	0,0386	0,0377	0,0371	0,0369	0,0369	0,0370	0,0408	0,0453	0,0469
0,1277	0,1321	0,1218	0,1051	0,0982	0,0970	0,0977	0,0994	0,1017	0,1043	0,1068	0,1240	0,1279	0,1272
0,2340	0,2425	0,2370	0,2369	0,2376	0,2379	0,2373	0,2366	0,2359	0,2353	0,2349	0,2343	0,2341	0,2341
0,3617	0,1769	0,3079	0,3422	0,3537	0,3570	0,3568	0,3561	0,3558	0,3557	0,3557	0,3589	0,3614	0,3619

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,2872	0,2596	0,2794	0,2855	0,2848	0,2822	0,2811	0,2814	0,2823	0,2833	0,2841	0,2861	0,2871	0,2870
0,0213	0,0640	0,0380	0,0343	0,0340	0,0338	0,0335	0,0332	0,0332	0,0334	0,0337	0,0377	0,0429	0,0420
0,1383	0,1173	0,1053	0,1171	0,1301	0,1385	0,1438	0,1468	0,1481	0,1481	0,1475	0,1377	0,1369	0,1385
0,3404	0,3970	0,3501	0,3532	0,3536	0,3490	0,3444	0,3411	0,3393	0,3382	0,3377	0,3379	0,3401	0,3404
0,2979	0,3922	0,3107	0,3008	0,3008	0,3019	0,3026	0,3027	0,3023	0,3017	0,3011	0,2991	0,2982	0,2980
0,0532	0,0569	0,0441	0,0434	0,0443	0,0445	0,0446	0,0447	0,0448	0,0449	0,0448	0,0416	0,0413	0,0490
0,1809	0,1496	0,1211	0,1161	0,1174	0,1197	0,1233	0,1276	0,1323	0,1371	0,1419	0,1742	0,1819	0,1814
0,1277	0,1217	0,1004	0,1010	0,1052	0,1081	0,1098	0,1113	0,1131	0,1152	0,1173	0,1277	0,1268	0,1270
0,1064	0,1170	0,1016	0,0997	0,1003	0,0999	0,0990	0,0980	0,0971	0,0966	0,0964	0,1008	0,1062	0,1063
0,1064	0,0912	0,0733	0,0723	0,0746	0,0757	0,0756	0,0750	0,0743	0,0739	0,0738	0,0826	0,1050	0,1064
0,0851	0,1118	0,1048	0,1031	0,1029	0,1023	0,1016	0,1005	0,0993	0,0979	0,0965	0,0862	0,0826	0,0839
0,0851	0,1159	0,0919	0,0903	0,0941	0,0971	0,0980	0,0972	0,0958	0,0945	0,0934	0,0885	0,0863	0,0855
1,0000	0,8349	0,8876	0,9037	0,9124	0,9194	0,9260	0,9313	0,9355	0,9388	0,9415	0,9551	0,9687	0,9797
0,4255	0,3791	0,4160	0,4284	0,4306	0,4303	0,4290	0,4276	0,4266	0,4259	0,4255	0,4254	0,4256	0,4255
0,1277	0,1640	0,1673	0,1612	0,1545	0,1470	0,1397	0,1341	0,1307	0,1288	0,1280	0,1288	0,1282	0,1283
0,1809	0,1603	0,2129	0,2142	0,2063	0,2003	0,1972	0,1959	0,1954	0,1952	0,1949	0,1897	0,1823	0,1812
0,2234	0,2176	0,2329	0,2239	0,2211	0,2204	0,2193	0,2181	0,2174	0,2171	0,2170	0,2192	0,2228	0,2235
0,0957	0,1021	0,0830	0,0860	0,0943	0,0970	0,0957	0,0943	0,0936	0,0935	0,0937	0,0958	0,0969	0,0958
0,3191	0,3364	0,3157	0,3166	0,3173	0,3171	0,3171	0,3178	0,3186	0,3192	0,3196	0,3201	0,3191	0,3191
0,2553	0,2854	0,2933	0,2845	0,2814	0,2807	0,2798	0,2782	0,2762	0,2741	0,2721	0,2606	0,2558	0,2554
0,3404	0,2642	0,3086	0,3281	0,3375	0,3451	0,3493	0,3507	0,3504	0,3495	0,3483	0,3431	0,3425	0,3413
0,1702	0,2051	0,1794	0,1731	0,1718	0,1734	0,1755	0,1761	0,1759	0,1753	0,1747	0,1710	0,1699	0,1701
0,1915	0,1797	0,1672	0,1666	0,1685	0,1710	0,1739	0,1764	0,1786	0,1802	0,1815	0,1848	0,1918	0,1917
0,0638	0,0487	0,0393	0,0369	0,0366	0,0368	0,0373	0,0380	0,0389	0,0400	0,0412	0,0558	0,0648	0,0637
0,1809	0,1746	0,1905	0,1908	0,1898	0,1892	0,1904	0,1922	0,1940	0,1952	0,1958	0,1887	0,1828	0,1811
0,2021	0,1627	0,1998	0,2011	0,1982	0,1967	0,1968	0,1978	0,1990	0,1999	0,2006	0,2021	0,2031	0,2024
0,1489	0,1150	0,1062	0,1021	0,1001	0,0990	0,0993	0,1005	0,1022	0,1042	0,1063	0,1309	0,1458	0,1486
0,0851	0,1336	0,1309	0,1247	0,1205	0,1176	0,1155	0,1137	0,1123	0,1111	0,1100	0,1016	0,0902	0,0852
0,5106	0,4858	0,4956	0,5004	0,5042	0,5065	0,5085	0,5088	0,5084	0,5081	0,5079	0,5078	0,5103	0,5107
0,3511	0,1959	0,2518	0,2851	0,3042	0,3155	0,3226	0,3277	0,3314	0,3341	0,3362	0,3462	0,3504	0,3507
0,1596	0,2614	0,2100	0,1954	0,1890	0,1837	0,1793	0,1757	0,1726	0,1700	0,1678	0,1559	0,1563	0,1582
0,2553	0,2009	0,1600	0,1668	0,1852	0,2051	0,2212	0,2319	0,2385	0,2427	0,2454	0,2550	0,2555	0,2554

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,0851	0,2150	0,1441	0,1258	0,1173	0,1108	0,1059	0,1020	0,0991	0,0972	0,0959	0,0911	0,0852	0,0852
0,2234	0,1782	0,1952	0,1940	0,1919	0,1919	0,1939	0,1973	0,2010	0,2044	0,2071	0,2177	0,2233	0,2234
0,1489	0,1990	0,2146	0,2110	0,2035	0,1951	0,1868	0,1800	0,1746	0,1706	0,1676	0,1560	0,1504	0,1503
0,2234	0,1599	0,2036	0,2174	0,2218	0,2217	0,2209	0,2202	0,2198	0,2197	0,2197	0,2226	0,2238	0,2233
0,2553	0,2721	0,2556	0,2494	0,2487	0,2485	0,2490	0,2503	0,2517	0,2527	0,2534	0,2550	0,2554	0,2553
0,2340	0,2160	0,2058	0,2162	0,2253	0,2290	0,2307	0,2322	0,2334	0,2343	0,2351	0,2382	0,2344	0,2340
0,8404	0,8563	0,8915	0,8973	0,8870	0,8667	0,8571	0,8544	0,8538	0,8538	0,8541	0,8548	0,8458	0,8412
0,3617	0,3452	0,3731	0,3683	0,3683	0,3699	0,3684	0,3661	0,3641	0,3627	0,3618	0,3603	0,3618	0,3618
0,4255	0,4670	0,4467	0,4276	0,4224	0,4244	0,4276	0,4295	0,4304	0,4308	0,4308	0,4283	0,4257	0,4255
0,0213	0,0745	0,0587	0,0568	0,0567	0,0567	0,0572	0,0576	0,0577	0,0575	0,0569	0,0451	0,0332	0,0285
0,0957	0,0729	0,0709	0,0722	0,0724	0,0730	0,0744	0,0763	0,0785	0,0807	0,0826	0,0919	0,0934	0,0949
0,1489	0,1164	0,1368	0,1448	0,1485	0,1515	0,1538	0,1554	0,1566	0,1575	0,1580	0,1557	0,1493	0,1487
0,2766	0,2057	0,2511	0,2608	0,2627	0,2658	0,2692	0,2718	0,2736	0,2747	0,2753	0,2756	0,2763	0,2766
0,3404	0,5421	0,5014	0,4775	0,4565	0,4375	0,4182	0,3999	0,3836	0,3693	0,3568	0,2924	0,2509	0,2310
0,3298	0,5556	0,4485	0,4191	0,4032	0,3884	0,3729	0,3564	0,3405	0,3262	0,3136	0,2581	0,2266	0,2060
0,2872	0,4342	0,3714	0,3373	0,3112	0,2888	0,2698	0,2541	0,2417	0,2319	0,2242	0,1920	0,1712	0,1545
0,0745	0,3232	0,2348	0,2128	0,1995	0,1883	0,1784	0,1697	0,1627	0,1572	0,1528	0,1312	0,1164	0,1009
0,1277	0,1294	0,1011	0,1015	0,1026	0,1014	0,0992	0,0968	0,0946	0,0928	0,0914	0,0901	0,0900	0,0825
0,4468	0,3094	0,2607	0,2445	0,2348	0,2255	0,2165	0,2087	0,2024	0,1973	0,1930	0,1674	0,1200	0,0903
0,3085	0,3474	0,2990	0,2693	0,2447	0,2271	0,2158	0,2093	0,2060	0,2043	0,2034	0,1900	0,1629	0,1428
0,2553	0,3522	0,2601	0,2365	0,2254	0,2200	0,2169	0,2148	0,2133	0,2122	0,2112	0,1950	0,1750	0,1606
0,2766	0,1778	0,1916	0,1940	0,1912	0,1869	0,1824	0,1786	0,1755	0,1728	0,1705	0,1585	0,1479	0,1354
0,3191	0,2648	0,3165	0,3262	0,3273	0,3272	0,3256	0,3244	0,3237	0,3228	0,3217	0,3052	0,2827	0,2604
0,8404	0,7454	0,7614	0,7641	0,7570	0,7498	0,7496	0,7518	0,7542	0,7563	0,7581	0,7719	0,7838	0,7903
0,2447	0,3007	0,3389	0,3048	0,2671	0,2371	0,2158	0,2010	0,1908	0,1834	0,1781	0,1636	0,1562	0,1459
0,1489	0,1977	0,1692	0,1595	0,1551	0,1505	0,1447	0,1398	0,1362	0,1338	0,1321	0,1285	0,1094	0,0868
0,2340	0,2001	0,1713	0,1730	0,1793	0,1848	0,1869	0,1881	0,1894	0,1910	0,1929	0,2091	0,1689	0,1273
0,2234	0,2001	0,1713	0,1730	0,1793	0,1848	0,1869	0,1881	0,1894	0,1910	0,1929	0,2091	0,1689	0,1273
0,2979	0,2494	0,2503	0,2472	0,2362	0,2261	0,2196	0,2160	0,2139	0,2122	0,2107	0,1991	0,1832	0,1822
0,1809	0,2713	0,2424	0,2338	0,2276	0,2211	0,2146	0,2088	0,2039	0,1997	0,1961	0,1716	0,1402	0,1159
0,0851	0,2270	0,2047	0,1885	0,1744	0,1619	0,1522	0,1454	0,1403	0,1363	0,1328	0,1152	0,1008	0,0910
0,2447	0,3160	0,3293	0,3114	0,2867	0,2660	0,2505	0,2397	0,2321	0,2265	0,2218	0,1930	0,1752	0,1653

CONTINUA

CONCLUSÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,2128	0,2082	0,1991	0,1929	0,1840	0,1757	0,1684	0,1618	0,1563	0,1517	0,1478	0,1290	0,1119	0,0991
0,4574	0,5246	0,4324	0,4063	0,3945	0,3853	0,3750	0,3641	0,3531	0,3423	0,3320	0,2611	0,2243	0,2194
0,1702	0,1836	0,1508	0,1446	0,1393	0,1329	0,1264	0,1209	0,1166	0,1134	0,1110	0,1058	0,1022	0,0909
0,3298	0,3754	0,3414	0,3207	0,3041	0,2910	0,2809	0,2742	0,2703	0,2680	0,2664	0,2401	0,1640	0,1231
0,1915	0,2088	0,1916	0,1868	0,1846	0,1843	0,1835	0,1829	0,1829	0,1832	0,1839	0,1902	0,1809	0,1585
0,5745	0,5494	0,5765	0,5843	0,5803	0,5750	0,5709	0,5700	0,5711	0,5731	0,5756	0,5833	0,5449	0,5079
RMSE Tr	0,0572	0,0379	0,0318	0,0274	0,0238	0,0213	0,0196	0,0182	0,0171	0,0161	0,0101	0,0057	0,0041
RMSE Tes	0,1053	0,0816	0,0746	0,0715	0,0711	0,0720	0,0733	0,0749	0,0765	0,0782	0,0927	0,1140	0,1295
ITERAÇÕES	10	20	30	40	50	60	70	80	90	100	200	500	1000

APÊNDICE IX

TABELA A.6 – VARIAÇÃO DO NÚMERO DE NEURÔNIOS DA CAMADA ESCONDIDA - TESTE III, 12 COMPONENTES PRINCIPAIS, 1º PROCESSO, 50 ITERAÇÕES

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,0851	0,1659	0,1512	0,1680	0,1588	0,0847	0,1210	0,1456	0,1075	0,1089	0,1198	0,1474	0,0751	0,1289	0,1637
0,0957	0,1423	0,0971	0,1259	0,1006	0,0948	0,0956	0,0804	0,1415	0,0591	0,1102	0,0873	0,0780	0,1030	0,1132
0,2766	0,1720	0,1718	0,2182	0,2250	0,2423	0,2357	0,1909	0,2055	0,2877	0,2126	0,2346	0,2454	0,2731	0,2180
0,9149	0,8052	0,8002	0,8481	0,8583	0,8326	0,8577	0,8535	0,8585	0,8690	0,8140	0,8223	0,8480	0,8395	0,8499
0,1489	0,1453	0,1196	0,0900	0,1291	0,1477	0,1421	0,1664	0,1204	0,1714	0,1673	0,1376	0,1760	0,1625	0,1655
0,2340	0,1574	0,2144	0,2687	0,2158	0,1991	0,2661	0,2006	0,2701	0,2058	0,2869	0,2116	0,2577	0,1707	0,1863
0,2234	0,1471	0,2092	0,2169	0,2102	0,2019	0,2341	0,2558	0,2082	0,2130	0,2198	0,2593	0,2250	0,2194	0,2351
0,3936	0,3929	0,5090	0,4573	0,4552	0,3999	0,4388	0,4142	0,4276	0,4435	0,4567	0,4394	0,4167	0,4168	0,4290
0,1489	0,1500	0,2259	0,1259	0,1363	0,1185	0,0859	0,0615	0,1352	0,0921	0,1709	0,1533	0,1593	0,1196	0,1228
0,3830	0,3844	0,3816	0,3945	0,4352	0,3723	0,3832	0,4072	0,4012	0,3656	0,3986	0,4262	0,4034	0,3777	0,3650
0,1489	0,2311	0,2255	0,3020	0,2686	0,2204	0,2132	0,1894	0,2685	0,2130	0,2014	0,2036	0,1836	0,1950	0,2066
0,1489	0,1626	0,1025	0,1254	0,1541	0,1775	0,1436	0,1415	0,1665	0,1531	0,1493	0,1549	0,1411	0,1341	0,1245
0,0319	0,1469	0,0671	0,0510	0,0664	0,0434	0,0406	0,0554	0,0648	0,0483	0,0553	0,0817	0,0602	0,0722	0,0479
0,0426	0,1440	0,0533	0,0292	0,0497	0,0801	0,0448	0,0396	0,0692	0,0531	0,0847	0,0728	0,0577	0,0680	0,0562
0,9468	0,8763	0,8839	0,8438	0,9062	0,8709	0,8552	0,9002	0,8656	0,8806	0,8732	0,8809	0,8922	0,8939	0,9146
0,0213	0,1391	0,0941	0,0519	0,0830	0,0790	0,0444	0,0761	0,1222	0,0940	0,0743	0,0810	0,0835	0,0683	0,0661
0,1383	0,1360	0,1634	0,0984	0,0900	0,1105	0,1618	0,1472	0,1410	0,1316	0,0714	0,0783	0,1138	0,1457	0,0999
0,1489	0,1411	0,0949	0,1320	0,1019	0,0872	0,1555	0,1198	0,1099	0,1003	0,1132	0,1635	0,1229	0,1272	0,1378
0,3404	0,4269	0,3747	0,3258	0,2432	0,3393	0,3598	0,3686	0,3409	0,3412	0,3882	0,3565	0,3500	0,3732	0,3594
0,2660	0,2100	0,2239	0,2733	0,2544	0,2469	0,3113	0,2756	0,3070	0,2928	0,2744	0,2990	0,2719	0,2712	0,2766
0,0426	0,1669	0,2037	0,1396	0,1064	0,1210	0,1228	0,1176	0,0736	0,0587	0,0893	0,0878	0,1058	0,0876	0,0927
0,1489	0,1283	0,1147	0,0801	0,0753	0,1291	0,1045	0,0943	0,0847	0,1018	0,0736	0,0753	0,0664	0,0961	0,1199
0,0851	0,1271	0,0584	0,0490	0,0621	0,0595	0,0420	0,0886	0,0653	0,0568	0,0668	0,0497	0,0669	0,0551	0,0687
0,0745	0,1338	0,0707	0,0656	0,1545	0,0923	0,1351	0,0989	0,1036	0,0990	0,0854	0,1298	0,0772	0,0804	0,0958
0,2340	0,1636	0,1577	0,1925	0,2035	0,2086	0,2241	0,2034	0,2055	0,1730	0,1298	0,1913	0,2035	0,2218	0,1942
0,2447	0,1857	0,3130	0,2903	0,2923	0,3644	0,2569	0,2739	0,2168	0,2743	0,2729	0,2588	0,2662	0,2786	0,2626
0,0638	0,1261	0,0574	0,0194	0,0551	0,0406	0,0690	0,0473	0,0504	0,0677	0,0407	0,0348	0,0515	0,0332	0,0437
0,1277	0,2335	0,2439	0,1803	0,1931	0,1510	0,1601	0,1341	0,1676	0,1466	0,1637	0,1482	0,1476	0,1333	0,1880
0,2340	0,1858	0,2047	0,2059	0,2745	0,2460	0,2163	0,2438	0,2234	0,2394	0,2108	0,2680	0,2355	0,2623	0,2620
0,3617	0,1764	0,2698	0,2875	0,3108	0,3709	0,2625	0,3566	0,3541	0,3534	0,3484	0,3298	0,3432	0,3341	0,3213

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,2872	0,1280	0,1785	0,2334	0,2163	0,1823	0,2529	0,1454	0,1984	0,2397	0,1544	0,1021	0,2106	0,1921	0,2500
0,0213	0,1314	0,0525	0,0176	0,0525	0,0369	0,0729	0,0453	0,0556	0,0687	0,0444	0,0376	0,0524	0,0353	0,0422
0,1383	0,1330	0,1213	0,1710	0,1201	0,1476	0,1094	0,1623	0,1334	0,1372	0,0839	0,1467	0,1254	0,0944	0,1605
0,3404	0,3432	0,3175	0,3043	0,3331	0,3048	0,3400	0,3453	0,3757	0,3311	0,3424	0,3504	0,3360	0,3535	0,3548
0,2979	0,1571	0,2008	0,2977	0,2611	0,2942	0,3188	0,2880	0,3069	0,3396	0,3057	0,2908	0,3084	0,3693	0,3187
0,0532	0,1339	0,0737	0,0517	0,0613	0,0942	0,0574	0,0845	0,0764	0,0851	0,0945	0,0985	0,0771	0,0849	0,0517
0,1809	0,1564	0,1143	0,1678	0,1614	0,1218	0,1973	0,1975	0,2061	0,1875	0,1740	0,1868	0,1515	0,2023	0,1724
0,1277	0,1375	0,0880	0,0604	0,0630	0,0720	0,0941	0,0845	0,0671	0,1076	0,1288	0,0840	0,0710	0,1012	0,0719
0,1064	0,1374	0,0626	0,0466	0,0954	0,1011	0,1245	0,1030	0,0951	0,1042	0,0972	0,0855	0,0959	0,0914	0,0807
0,1064	0,1555	0,1809	0,0969	0,1404	0,1438	0,1298	0,1189	0,1199	0,0723	0,0955	0,1270	0,0960	0,0795	0,1119
0,0851	0,1490	0,0918	0,0607	0,1309	0,1024	0,1194	0,1304	0,0745	0,1382	0,0890	0,0912	0,1014	0,0711	0,0776
0,0851	0,1459	0,1366	0,0959	0,0965	0,0789	0,0914	0,0799	0,0702	0,0618	0,0967	0,1174	0,0963	0,1053	0,0954
1,0000	0,8738	0,8887	0,8654	0,8995	0,9300	0,9287	0,9261	0,9282	0,9406	0,9148	0,9457	0,9300	0,9379	0,9478
0,4255	0,3467	0,4086	0,4343	0,4228	0,3623	0,3848	0,3938	0,4519	0,4281	0,4380	0,4298	0,4218	0,4220	0,4197
0,1277	0,1658	0,2169	0,1466	0,1171	0,1157	0,1477	0,1176	0,1084	0,1478	0,1458	0,1429	0,1100	0,1565	0,1374
0,1809	0,1412	0,2124	0,2398	0,2555	0,1534	0,2327	0,1892	0,1942	0,2224	0,2011	0,1702	0,2323	0,1846	0,2543
0,2234	0,1383	0,2064	0,2299	0,2624	0,2321	0,2600	0,1760	0,2340	0,2202	0,2423	0,2047	0,2215	0,2090	0,2043
0,0957	0,1517	0,2207	0,1308	0,1043	0,1317	0,1141	0,1039	0,0918	0,1068	0,1031	0,1115	0,1025	0,0862	0,0940
0,3191	0,2958	0,3445	0,3238	0,3098	0,3140	0,3511	0,3267	0,3096	0,3460	0,3306	0,3161	0,3214	0,3293	0,3267
0,2553	0,1744	0,2267	0,2060	0,2028	0,2083	0,2342	0,2175	0,1966	0,2385	0,2060	0,1830	0,2589	0,1854	0,1752
0,3404	0,1452	0,1914	0,2730	0,2213	0,2987	0,2168	0,3275	0,3065	0,3241	0,3048	0,2659	0,3052	0,2909	0,2105
0,1702	0,1580	0,1327	0,1703	0,1922	0,2029	0,1596	0,2048	0,1649	0,1753	0,1760	0,1744	0,1429	0,1616	0,1783
0,1915	0,1598	0,2395	0,2280	0,1950	0,1749	0,1796	0,1549	0,1978	0,2127	0,1582	0,1834	0,1886	0,2184	0,1933
0,0638	0,1500	0,0537	0,0659	0,0516	0,0474	0,0586	0,0933	0,0830	0,0720	0,0503	0,0545	0,0810	0,0889	0,0783
0,1809	0,1726	0,0909	0,1249	0,1700	0,1452	0,1386	0,2034	0,1517	0,1575	0,1760	0,1116	0,1730	0,1578	0,1515
0,2021	0,1560	0,1540	0,1549	0,1854	0,2135	0,1713	0,2029	0,1561	0,1972	0,2182	0,1741	0,1451	0,2030	0,2172
0,1489	0,1523	0,1228	0,0671	0,0653	0,0854	0,0769	0,0806	0,1075	0,0885	0,1114	0,0767	0,1059	0,0920	0,0876
0,0851	0,1549	0,1124	0,1063	0,0972	0,1079	0,1077	0,1049	0,0966	0,1168	0,1311	0,1126	0,0704	0,1001	0,1327
0,5106	0,4341	0,3780	0,5263	0,4880	0,5283	0,5089	0,4999	0,5290	0,4672	0,4867	0,4914	0,5049	0,4875	0,4903
0,3511	0,1585	0,2087	0,2570	0,2515	0,2870	0,2398	0,2804	0,2538	0,2849	0,2340	0,3223	0,3104	0,2100	0,3169
0,1596	0,2156	0,1661	0,1805	0,1880	0,1754	0,1525	0,1469	0,1915	0,1258	0,1677	0,1712	0,1896	0,1509	0,1499
0,2553	0,2217	0,2369	0,2558	0,2769	0,2725	0,2528	0,3037	0,2453	0,2294	0,2345	0,2533	0,2981	0,2557	0,2763

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,0851	0,1724	0,1291	0,1227	0,1019	0,0749	0,0948	0,0614	0,1053	0,0830	0,0988	0,1181	0,0757	0,1085	0,1343
0,2234	0,1898	0,2236	0,2534	0,2465	0,2562	0,2634	0,2625	0,1912	0,2424	0,2449	0,2244	0,2407	0,2126	0,2234
0,1489	0,1712	0,1418	0,1841	0,1959	0,2275	0,2019	0,1675	0,2028	0,1812	0,2004	0,1950	0,1797	0,1962	0,1581
0,2234	0,1690	0,2365	0,2092	0,1801	0,2264	0,1786	0,1864	0,1906	0,2243	0,2465	0,2088	0,2519	0,2492	0,2162
0,2553	0,3838	0,2970	0,2530	0,2683	0,3064	0,2695	0,2616	0,2543	0,2588	0,2367	0,2618	0,2503	0,2732	0,2719
0,2340	0,1726	0,1633	0,2459	0,2324	0,2238	0,2435	0,2342	0,2251	0,2436	0,2284	0,2383	0,2499	0,2826	0,2348
0,8404	0,8897	0,9111	0,8951	0,9204	0,8969	0,8928	0,9379	0,8800	0,9142	0,9135	0,8906	0,9044	0,8959	0,9365
0,3617	0,4507	0,3957	0,3323	0,3497	0,3679	0,3521	0,3543	0,3500	0,3492	0,3749	0,3989	0,3473	0,3665	0,3278
0,4255	0,4394	0,4466	0,4295	0,4354	0,4262	0,4322	0,4366	0,4240	0,4066	0,4371	0,4272	0,4215	0,4251	0,4290
0,0213	0,1493	0,0649	0,1298	0,0641	0,0858	0,0548	0,1028	0,0869	0,0954	0,0822	0,0751	0,0890	0,0704	0,0846
0,0957	0,1420	0,2287	0,0502	0,0565	0,0919	0,0475	0,0997	0,1132	0,0552	0,0800	0,0711	0,0660	0,1304	0,1026
0,1489	0,1712	0,1894	0,1757	0,1508	0,1573	0,1520	0,1453	0,1429	0,1653	0,1354	0,1485	0,1745	0,1531	0,1540
0,2766	0,1536	0,2227	0,3198	0,3126	0,3258	0,2895	0,2833	0,2950	0,2826	0,2978	0,2938	0,2856	0,2902	0,3268
0,3404	0,1703	0,3734	0,2385	0,3456	0,1774	0,0987	0,5253	0,3264	0,2099	0,3923	0,3497	0,3432	0,4676	0,5199
0,3298	0,3052	0,4937	0,2386	0,5476	0,2035	0,1376	0,5649	0,4940	0,2555	0,3826	0,5231	0,4097	0,4811	0,7567
0,2872	0,1987	0,3806	0,1496	0,2545	0,0811	0,0506	0,3485	0,3104	0,1338	0,1949	0,2816	0,1905	0,2500	0,3822
0,0745	0,1486	0,4173	0,1321	0,1656	0,0778	0,0504	0,2123	0,2222	0,0958	0,1598	0,3805	0,1778	0,2882	0,4664
0,1277	0,0333	0,1541	0,0766	0,1158	0,0623	0,0252	0,1901	0,2390	0,0786	0,2514	0,2688	0,1517	0,2624	0,2650
0,4468	0,3330	0,4654	0,2820	0,4617	0,1181	0,0723	0,2959	0,3415	0,1486	0,1663	0,4274	0,2059	0,3104	0,5180
0,3085	0,2031	0,3951	0,1977	0,2472	0,1092	0,0617	0,4002	0,3087	0,1787	0,2648	0,4886	0,1845	0,2789	0,5187
0,2553	0,2731	0,4696	0,2640	0,3646	0,0963	0,0589	0,4669	0,3910	0,2317	0,2758	0,5577	0,2114	0,3876	0,7068
0,2766	0,1303	0,3022	0,1191	0,1291	0,1009	0,0447	0,2622	0,1815	0,1553	0,1488	0,2788	0,1589	0,2840	0,4303
0,3191	0,0760	0,2546	0,1784	0,2523	0,1185	0,0931	0,3346	0,3598	0,2169	0,3059	0,3721	0,2839	0,4074	0,4692
0,8404	0,4990	0,5039	0,7545	0,6396	0,2734	0,6136	0,9281	0,6178	0,8413	0,7522	0,7754	0,5659	0,7606	0,9237
0,2447	0,3558	0,7684	0,3897	0,3648	0,0733	0,1142	0,3794	0,5181	0,3581	0,3966	0,5841	0,2370	0,6302	0,5477
0,1489	0,1947	0,4312	0,1246	0,1604	0,0967	0,0576	0,2937	0,1652	0,1134	0,1017	0,2746	0,1450	0,1969	0,4442
0,2340	0,0428	0,2168	0,1102	0,2126	0,1864	0,0938	0,3306	0,2455	0,2292	0,1463	0,2770	0,2311	0,2691	0,2324
0,2234	0,0428	0,2168	0,1102	0,2126	0,1864	0,0938	0,3306	0,2455	0,2292	0,1463	0,2770	0,2311	0,2691	0,2324
0,2979	0,4338	0,6379	0,1228	0,3452	0,1669	0,1842	0,5829	0,5593	0,5615	0,6399	0,7460	0,2835	0,5120	0,7139
0,1809	0,2003	0,3491	0,1335	0,1395	0,1003	0,0451	0,2152	0,1292	0,1553	0,1005	0,3035	0,1703	0,2060	0,4447
0,0851	0,0738	0,1982	0,0537	0,0558	0,0280	0,0255	0,1425	0,0629	0,0684	0,0328	0,1527	0,0642	0,1057	0,2196
0,2447	0,0825	0,2623	0,2209	0,1965	0,1036	0,0594	0,4390	0,2511	0,1669	0,2458	0,3355	0,1671	0,3059	0,4262

CONTINUA

CONCLUSÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,2128	0,0932	0,3805	0,1050	0,2493	0,0599	0,0346	0,1954	0,2389	0,1707	0,1861	0,4008	0,1516	0,2833	0,4865
0,4574	0,3505	0,5844	0,5991	0,6788	0,1707	0,2037	0,8526	0,6783	0,5905	0,4814	0,8045	0,5249	0,6871	0,8236
0,1702	0,0507	0,2452	0,0872	0,1274	0,0784	0,0376	0,2386	0,2248	0,1394	0,1512	0,2422	0,1164	0,2811	0,3298
0,3298	0,3654	0,5207	0,3275	0,4145	0,1568	0,1505	0,4622	0,3543	0,3216	0,2030	0,6619	0,2183	0,4417	0,6266
0,1915	0,0283	0,1933	0,1587	0,1361	0,1770	0,0655	0,3210	0,3669	0,1795	0,4528	0,3858	0,2188	0,4780	0,3557
0,5745	0,4174	0,7992	0,3301	0,5925	0,4668	0,2797	0,7056	0,5435	0,5685	0,5174	0,5093	0,5873	0,6833	0,7637
RMSE Tr	0,0801	0,0663	0,0498	0,0475	0,0410	0,0411	0,0402	0,0394	0,0339	0,0428	0,0427	0,0322	0,0376	0,0382
RMSE Tes	0,1407	0,1975	0,1129	0,0948	0,1890	0,1937	0,1544	0,1239	0,1080	0,1259	0,1960	0,0947	0,1465	0,2498
NEURÔNIOS	1	2	3	4	5	6	7	8	9	10	11	12	13	14

APÊNDICE X

TABELA A.7 – VARIAÇÃO DO NÚMERO DE ITERAÇÕES - TESTE III, 12 COMPONENTES PRINCIPAIS, 1º PROCESSO, 4 NEURÔNIOS NA CAMADA ESCONDIDA

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,0851	0,0891	0,0916	0,1213	0,1478	0,1588	0,1627	0,1632	0,1620	0,1599	0,1574	0,1321	0,0861	0,0726
0,0957	0,0703	0,0685	0,0797	0,0910	0,1006	0,1065	0,1096	0,1111	0,1118	0,1124	0,1198	0,1210	0,1111
0,2766	0,1453	0,1985	0,2176	0,2182	0,2250	0,2329	0,2395	0,2448	0,2491	0,2527	0,2739	0,2794	0,2773
0,9149	0,6849	0,8019	0,8364	0,8527	0,8583	0,8591	0,8582	0,8575	0,8574	0,8580	0,8857	0,9034	0,9060
0,1489	0,0998	0,1160	0,1241	0,1257	0,1291	0,1324	0,1354	0,1385	0,1417	0,1449	0,1575	0,1621	0,1581
0,2340	0,1951	0,1693	0,1879	0,2100	0,2158	0,2172	0,2173	0,2171	0,2170	0,2172	0,2271	0,2384	0,2249
0,2234	0,2084	0,2093	0,1882	0,1953	0,2102	0,2178	0,2210	0,2218	0,2214	0,2207	0,2256	0,2158	0,2214
0,3936	0,4370	0,4367	0,4353	0,4471	0,4552	0,4587	0,4598	0,4595	0,4584	0,4568	0,4379	0,4150	0,4111
0,1489	0,0989	0,0971	0,1134	0,1257	0,1363	0,1417	0,1435	0,1435	0,1428	0,1418	0,1383	0,1515	0,1703
0,3830	0,3760	0,4178	0,4200	0,4297	0,4352	0,4361	0,4349	0,4328	0,4300	0,4266	0,3944	0,3879	0,3879
0,1489	0,4690	0,3005	0,2864	0,2738	0,2686	0,2676	0,2680	0,2684	0,2685	0,2683	0,2598	0,1831	0,1600
0,1489	0,2012	0,1980	0,1806	0,1627	0,1541	0,1500	0,1481	0,1471	0,1465	0,1457	0,1326	0,1212	0,1453
0,0319	0,1188	0,0818	0,0742	0,0671	0,0664	0,0675	0,0688	0,0703	0,0719	0,0735	0,0854	0,0647	0,0545
0,0426	0,0689	0,0592	0,0537	0,0509	0,0497	0,0488	0,0481	0,0473	0,0466	0,0459	0,0440	0,0685	0,0552
0,9468	0,7333	0,8409	0,8776	0,8965	0,9062	0,9129	0,9181	0,9221	0,9252	0,9276	0,9396	0,9106	0,9316
0,0213	0,0803	0,0976	0,0992	0,0919	0,0830	0,0767	0,0727	0,0701	0,0685	0,0675	0,0666	0,0618	0,0552
0,1383	0,1347	0,0985	0,0918	0,0899	0,0900	0,0898	0,0895	0,0893	0,0892	0,0894	0,1125	0,1432	0,1220
0,1489	0,1092	0,1135	0,1025	0,1007	0,1019	0,1027	0,1031	0,1032	0,1033	0,1034	0,1076	0,1139	0,1291
0,3404	0,2107	0,2371	0,2383	0,2406	0,2432	0,2449	0,2461	0,2474	0,2492	0,2514	0,2784	0,3245	0,3298
0,2660	0,3446	0,2804	0,2680	0,2590	0,2544	0,2552	0,2583	0,2615	0,2639	0,2654	0,2687	0,2562	0,2652
0,0426	0,1268	0,1207	0,1163	0,1106	0,1064	0,1027	0,0991	0,0959	0,0933	0,0914	0,0888	0,0880	0,0665
0,1489	0,0775	0,0670	0,0676	0,0707	0,0753	0,0785	0,0802	0,0812	0,0819	0,0825	0,0913	0,1228	0,1521
0,0851	0,0570	0,0772	0,0797	0,0698	0,0621	0,0577	0,0552	0,0539	0,0537	0,0543	0,0703	0,0624	0,0885
0,0745	0,2100	0,1825	0,1671	0,1615	0,1545	0,1477	0,1412	0,1348	0,1286	0,1226	0,0926	0,0412	0,0303
0,2340	0,1260	0,2068	0,2010	0,2023	0,2035	0,2045	0,2052	0,2061	0,2076	0,2096	0,2267	0,2277	0,2324
0,2447	0,2502	0,2838	0,3009	0,3012	0,2923	0,2850	0,2802	0,2768	0,2741	0,2716	0,2496	0,2382	0,2494
0,0638	0,0696	0,0651	0,0616	0,0583	0,0551	0,0523	0,0501	0,0483	0,0467	0,0453	0,0336	0,0314	0,0206
0,1277	0,1170	0,1932	0,2014	0,1970	0,1931	0,1902	0,1871	0,1840	0,1809	0,1778	0,1554	0,1370	0,1371
0,2340	0,2463	0,2987	0,3047	0,2862	0,2745	0,2675	0,2626	0,2588	0,2558	0,2534	0,2463	0,2165	0,2193
0,3617	0,1002	0,1243	0,2126	0,2926	0,3108	0,3195	0,3256	0,3298	0,3326	0,3342	0,3420	0,3604	0,3655

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,2872	0,1405	0,1271	0,1832	0,2075	0,2163	0,2212	0,2243	0,2266	0,2283	0,2297	0,2301	0,2602	0,2808
0,0213	0,0774	0,0669	0,0611	0,0558	0,0525	0,0498	0,0478	0,0460	0,0445	0,0432	0,0324	0,0310	0,0198
0,1383	0,1216	0,0955	0,1006	0,1088	0,1201	0,1285	0,1348	0,1395	0,1431	0,1455	0,1464	0,1641	0,1565
0,3404	0,3736	0,3470	0,3345	0,3343	0,3331	0,3312	0,3304	0,3308	0,3319	0,3336	0,3444	0,3493	0,3448
0,2979	0,2869	0,2627	0,2711	0,2645	0,2611	0,2593	0,2582	0,2575	0,2570	0,2569	0,2559	0,2957	0,3081
0,0532	0,0935	0,1021	0,0868	0,0707	0,0613	0,0547	0,0503	0,0474	0,0454	0,0441	0,0454	0,0322	0,0306
0,1809	0,1214	0,1514	0,1486	0,1551	0,1614	0,1645	0,1667	0,1687	0,1705	0,1719	0,1789	0,2005	0,2050
0,1277	0,0876	0,0728	0,0654	0,0622	0,0630	0,0640	0,0647	0,0652	0,0656	0,0658	0,0564	0,0528	0,0607
0,1064	0,1232	0,1110	0,1071	0,0990	0,0954	0,0922	0,0893	0,0870	0,0853	0,0838	0,0725	0,0685	0,0931
0,1064	0,1165	0,1455	0,1564	0,1486	0,1404	0,1348	0,1310	0,1283	0,1262	0,1243	0,1071	0,0935	0,0987
0,0851	0,1088	0,1208	0,1234	0,1280	0,1309	0,1323	0,1332	0,1339	0,1346	0,1354	0,1396	0,1120	0,1118
0,0851	0,1280	0,1016	0,0998	0,0973	0,0965	0,0964	0,0965	0,0966	0,0967	0,0967	0,0924	0,0943	0,0875
1,0000	0,7668	0,8559	0,8747	0,8888	0,8995	0,9066	0,9118	0,9158	0,9189	0,9212	0,9310	0,9622	0,9704
0,4255	0,3442	0,4111	0,4239	0,4244	0,4228	0,4214	0,4204	0,4193	0,4175	0,4152	0,4106	0,4193	0,4226
0,1277	0,1197	0,1140	0,1162	0,1144	0,1171	0,1209	0,1235	0,1247	0,1245	0,1233	0,1139	0,1191	0,1329
0,1809	0,1845	0,2042	0,2245	0,2454	0,2555	0,2580	0,2571	0,2544	0,2507	0,2465	0,2135	0,1947	0,1868
0,2234	0,2720	0,2622	0,2643	0,2597	0,2624	0,2644	0,2657	0,2666	0,2671	0,2671	0,2434	0,2375	0,2269
0,0957	0,1239	0,1098	0,1101	0,1053	0,1043	0,1050	0,1055	0,1055	0,1049	0,1041	0,0966	0,0962	0,0903
0,3191	0,3210	0,3184	0,3076	0,3086	0,3098	0,3117	0,3142	0,3165	0,3186	0,3204	0,3236	0,3184	0,3222
0,2553	0,2157	0,1874	0,2042	0,2056	0,2028	0,2009	0,1997	0,1994	0,2002	0,2018	0,2238	0,2464	0,2523
0,3404	0,1665	0,1794	0,1942	0,2061	0,2213	0,2362	0,2500	0,2616	0,2705	0,2771	0,3122	0,3346	0,3358
0,1702	0,2154	0,2156	0,2158	0,2015	0,1922	0,1877	0,1859	0,1855	0,1860	0,1869	0,1831	0,1758	0,1721
0,1915	0,2114	0,1947	0,1964	0,1957	0,1950	0,1942	0,1928	0,1914	0,1901	0,1893	0,1970	0,1891	0,1941
0,0638	0,0880	0,0694	0,0642	0,0571	0,0516	0,0474	0,0442	0,0419	0,0404	0,0395	0,0445	0,0375	0,0356
0,1809	0,1111	0,1085	0,1306	0,1537	0,1700	0,1783	0,1821	0,1841	0,1854	0,1866	0,1985	0,1928	0,1670
0,2021	0,2229	0,2084	0,1771	0,1762	0,1854	0,1921	0,1966	0,1994	0,2011	0,2020	0,2019	0,1950	0,2039
0,1489	0,0713	0,0550	0,0555	0,0596	0,0653	0,0686	0,0700	0,0705	0,0705	0,0705	0,0710	0,0898	0,1025
0,0851	0,1054	0,0849	0,0820	0,0871	0,0972	0,1049	0,1100	0,1136	0,1164	0,1188	0,1322	0,1202	0,1059
0,5106	0,4499	0,4885	0,4936	0,4926	0,4880	0,4846	0,4831	0,4832	0,4843	0,4860	0,5024	0,5228	0,5128
0,3511	0,2757	0,2517	0,2505	0,2505	0,2515	0,2522	0,2526	0,2531	0,2537	0,2545	0,2612	0,2812	0,2939
0,1596	0,2921	0,2517	0,2174	0,1968	0,1880	0,1838	0,1818	0,1810	0,1810	0,1810	0,1655	0,1536	0,1512
0,2553	0,3543	0,2977	0,2860	0,2761	0,2769	0,2794	0,2808	0,2812	0,2809	0,2802	0,2696	0,2660	0,2627

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,0851	0,2050	0,1480	0,1305	0,1114	0,1019	0,0972	0,0945	0,0930	0,0920	0,0910	0,0858	0,0789	0,0798
0,2234	0,2886	0,2314	0,2433	0,2496	0,2465	0,2423	0,2385	0,2353	0,2330	0,2313	0,2266	0,2326	0,2320
0,1489	0,2177	0,2306	0,2156	0,2024	0,1959	0,1929	0,1919	0,1920	0,1925	0,1933	0,1997	0,1925	0,2032
0,2234	0,1252	0,1521	0,1812	0,1842	0,1801	0,1764	0,1738	0,1721	0,1708	0,1699	0,1924	0,2224	0,2148
0,2553	0,3700	0,3325	0,3062	0,2846	0,2683	0,2598	0,2566	0,2566	0,2584	0,2610	0,2610	0,2654	0,2600
0,2340	0,1883	0,2403	0,2282	0,2325	0,2324	0,2299	0,2279	0,2267	0,2263	0,2266	0,2322	0,2296	0,2115
0,8404	0,7680	0,8678	0,8980	0,9127	0,9204	0,9254	0,9290	0,9317	0,9339	0,9356	0,9458	0,8435	0,8419
0,3617	0,4312	0,3581	0,3579	0,3541	0,3497	0,3465	0,3440	0,3423	0,3412	0,3407	0,3479	0,3551	0,3459
0,4255	0,3973	0,4513	0,4491	0,4379	0,4354	0,4357	0,4364	0,4373	0,4383	0,4394	0,4305	0,4330	0,4314
0,0213	0,0871	0,1014	0,0859	0,0726	0,0641	0,0588	0,0557	0,0541	0,0535	0,0535	0,0454	0,0339	0,0279
0,0957	0,0376	0,0274	0,0383	0,0492	0,0565	0,0603	0,0620	0,0626	0,0627	0,0625	0,0600	0,0586	0,0879
0,1489	0,1333	0,1497	0,1592	0,1583	0,1508	0,1448	0,1401	0,1368	0,1350	0,1347	0,1570	0,1666	0,1514
0,2766	0,3019	0,3101	0,3132	0,3148	0,3126	0,3083	0,3039	0,3001	0,2971	0,2951	0,2945	0,2896	0,2897
0,3404	0,2948	0,3007	0,3192	0,3350	0,3456	0,3494	0,3495	0,3479	0,3455	0,3424	0,3016	0,2122	0,1843
0,3298	0,3685	0,3738	0,4561	0,5142	0,5476	0,5618	0,5646	0,5622	0,5576	0,5523	0,5302	0,6778	0,6687
0,2872	0,2262	0,2188	0,2302	0,2419	0,2545	0,2637	0,2693	0,2723	0,2731	0,2721	0,2340	0,1728	0,1620
0,0745	0,1473	0,1274	0,1482	0,1595	0,1656	0,1704	0,1739	0,1764	0,1779	0,1785	0,1628	0,1663	0,1754
0,1277	0,1429	0,1018	0,1046	0,1094	0,1158	0,1197	0,1211	0,1208	0,1194	0,1172	0,0891	0,0349	0,0246
0,4468	0,3151	0,3642	0,4067	0,4382	0,4617	0,4812	0,4964	0,5076	0,5153	0,5202	0,5264	0,4234	0,3525
0,3085	0,1888	0,2340	0,2462	0,2487	0,2472	0,2445	0,2409	0,2366	0,2315	0,2256	0,1581	0,1170	0,1302
0,2553	0,2479	0,2887	0,3325	0,3541	0,3646	0,3728	0,3789	0,3830	0,3852	0,3857	0,3541	0,3043	0,3297
0,2766	0,1437	0,1413	0,1471	0,1395	0,1291	0,1206	0,1133	0,1071	0,1022	0,0984	0,0940	0,0933	0,0866
0,3191	0,2563	0,2421	0,2374	0,2439	0,2523	0,2554	0,2541	0,2495	0,2426	0,2343	0,1839	0,1215	0,0983
0,8404	0,6232	0,6578	0,6435	0,6390	0,6396	0,6383	0,6344	0,6284	0,6214	0,6137	0,5427	0,2080	0,1366
0,2447	0,2656	0,2729	0,3167	0,3427	0,3648	0,3784	0,3839	0,3838	0,3803	0,3746	0,3209	0,2808	0,1997
0,1489	0,1018	0,1256	0,1568	0,1640	0,1604	0,1571	0,1540	0,1510	0,1480	0,1448	0,1125	0,0960	0,1240
0,2340	0,1935	0,1803	0,2052	0,2126	0,2126	0,2096	0,2052	0,2004	0,1958	0,1917	0,1692	0,0987	0,0593
0,2234	0,1935	0,1803	0,2052	0,2126	0,2126	0,2096	0,2052	0,2004	0,1958	0,1917	0,1692	0,0987	0,0593
0,2979	0,4264	0,4075	0,3987	0,3702	0,3452	0,3247	0,3088	0,2972	0,2889	0,2828	0,2459	0,0461	0,0241
0,1809	0,1153	0,1384	0,1534	0,1486	0,1395	0,1322	0,1258	0,1199	0,1143	0,1091	0,0762	0,0878	0,1005
0,0851	0,0538	0,0548	0,0605	0,0579	0,0558	0,0542	0,0526	0,0509	0,0490	0,0470	0,0279	0,0203	0,0202
0,2447	0,2277	0,2209	0,2067	0,2000	0,1965	0,1916	0,1855	0,1786	0,1716	0,1647	0,1174	0,1122	0,1316

CONTINUA

CONCLUSÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,2128	0,1832	0,1505	0,1999	0,2305	0,2493	0,2606	0,2660	0,2674	0,2663	0,2637	0,2564	0,2053	0,1695
0,4574	0,5958	0,6672	0,6622	0,6671	0,6788	0,6841	0,6863	0,6875	0,6879	0,6874	0,6617	0,5487	0,4023
0,1702	0,1230	0,0982	0,1152	0,1239	0,1274	0,1263	0,1226	0,1177	0,1126	0,1077	0,0789	0,0546	0,0350
0,3298	0,2291	0,3518	0,4069	0,4225	0,4145	0,4048	0,3963	0,3888	0,3816	0,3741	0,3071	0,2734	0,2417
0,1915	0,1762	0,1574	0,1474	0,1413	0,1361	0,1285	0,1205	0,1128	0,1058	0,0995	0,0643	0,0333	0,0207
0,5745	0,4838	0,5461	0,5632	0,5823	0,5925	0,5921	0,5862	0,5767	0,5648	0,5510	0,4208	0,2464	0,3485
RMSE Tr	0,0916	0,0681	0,0573	0,0505	0,0475	0,0457	0,0444	0,0434	0,0426	0,0418	0,0357	0,0240	0,0195
RMSE Tes	0,0852	0,0799	0,0829	0,0893	0,0948	0,0986	0,1013	0,1033	0,1050	0,1065	0,1221	0,1969	0,2071
ITERAÇÕES	10	20	30	40	50	60	70	80	90	100	200	500	1000

APÊNDICE XI

TABELA A.8 – VARIAÇÃO DO NÚMERO DE NEURÔNIOS DA CAMADA ESCONDIDA - TESTE III, 10 COMPONENTES PRINCIPAIS, 1º PROCESSO, 50 ITERAÇÕES

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,0851	0,1622	0,0895	0,1250	0,1309	0,1296	0,1036	0,1064	0,1030	0,1814	0,1158	0,1779	0,1480	0,0669	0,1097
0,0957	0,1637	0,1099	0,0714	0,1275	0,1197	0,0874	0,0980	0,1364	0,1185	0,0967	0,1043	0,1169	0,0704	0,1189
0,2766	0,1730	0,1717	0,2003	0,1897	0,2368	0,1840	0,2064	0,2272	0,2831	0,2463	0,2399	0,2075	0,2504	0,1997
0,9149	0,7542	0,7460	0,7886	0,8136	0,8079	0,8357	0,8276	0,8571	0,8361	0,8374	0,8344	0,8204	0,8598	0,8311
0,1489	0,1892	0,1322	0,1455	0,1792	0,1618	0,1764	0,1269	0,0888	0,0814	0,1561	0,1247	0,1124	0,1338	0,1482
0,2340	0,1669	0,2351	0,2985	0,1824	0,1829	0,2531	0,2343	0,2427	0,2230	0,2268	0,2257	0,2566	0,2163	0,1987
0,2234	0,2186	0,2528	0,2266	0,2729	0,2652	0,2531	0,2936	0,2153	0,2488	0,2552	0,1776	0,2473	0,2369	0,2295
0,3936	0,3058	0,5776	0,4085	0,4694	0,4571	0,4370	0,4417	0,4024	0,4422	0,4105	0,4610	0,3660	0,3753	0,4122
0,1489	0,1722	0,2118	0,0411	0,0693	0,0313	0,1199	0,1509	0,0924	0,0759	0,0718	0,1162	0,0543	0,1454	0,0791
0,3830	0,3499	0,3275	0,3771	0,4235	0,4276	0,4072	0,3944	0,4307	0,3872	0,4097	0,4077	0,3841	0,3671	0,3994
0,1489	0,2167	0,2223	0,2452	0,1813	0,2154	0,2762	0,2263	0,2310	0,2300	0,1972	0,2314	0,2482	0,1908	0,1962
0,1489	0,1877	0,1416	0,1506	0,1515	0,1647	0,1519	0,1606	0,1560	0,1232	0,1624	0,1422	0,1529	0,1838	0,1476
0,0319	0,1736	0,0443	0,0735	0,0655	0,0671	0,0844	0,0415	0,0646	0,0827	0,0540	0,0869	0,0512	0,0797	0,0557
0,0426	0,1677	0,1094	0,0376	0,0593	0,0289	0,0455	0,0469	0,0739	0,0444	0,0745	0,0645	0,0426	0,0504	0,0521
0,9468	0,8688	0,8166	0,8647	0,8700	0,8475	0,8734	0,9036	0,8603	0,8739	0,8732	0,8551	0,8772	0,9210	0,8909
0,0213	0,1861	0,0868	0,0893	0,0739	0,0533	0,0675	0,0829	0,0702	0,0793	0,1097	0,0725	0,0905	0,0838	0,0796
0,1383	0,1667	0,1846	0,1200	0,1226	0,0774	0,1531	0,0823	0,0865	0,1485	0,1443	0,1448	0,1130	0,1040	0,1389
0,1489	0,1603	0,1048	0,1360	0,1733	0,1258	0,1210	0,1474	0,1203	0,1322	0,1208	0,1297	0,1097	0,0784	0,1487
0,3404	0,3707	0,3799	0,3846	0,3650	0,3572	0,3282	0,3500	0,3953	0,3551	0,3431	0,3515	0,4510	0,3641	0,3948
0,2660	0,2038	0,3598	0,2744	0,2978	0,2358	0,2662	0,2303	0,3074	0,2521	0,2692	0,2886	0,2928	0,2769	0,2977
0,0426	0,1490	0,2010	0,0725	0,0896	0,0781	0,0909	0,0779	0,0806	0,0878	0,1033	0,0832	0,0763	0,0832	0,0699
0,1489	0,1454	0,0972	0,0827	0,1160	0,0733	0,0767	0,0996	0,0709	0,1293	0,0837	0,0844	0,0619	0,0897	0,1052
0,0851	0,1427	0,0597	0,0448	0,0551	0,0560	0,0459	0,0552	0,0624	0,0645	0,0576	0,0408	0,0438	0,1073	0,0611
0,0745	0,1536	0,1139	0,1210	0,0922	0,1309	0,1385	0,1495	0,1009	0,0921	0,0919	0,1226	0,1148	0,1238	0,0947
0,2340	0,1631	0,2096	0,2073	0,2302	0,2137	0,2372	0,1935	0,2283	0,1845	0,2196	0,1869	0,2083	0,1499	0,1926
0,2447	0,2237	0,2205	0,2661	0,2744	0,3012	0,2525	0,2784	0,2583	0,2662	0,2990	0,2922	0,2683	0,2778	0,2523
0,0638	0,1392	0,0319	0,0461	0,0639	0,0332	0,0464	0,0289	0,0673	0,0390	0,0709	0,0452	0,0390	0,0732	0,0588
0,1277	0,1649	0,2157	0,1994	0,1231	0,1394	0,1670	0,1775	0,1376	0,1835	0,1209	0,1612	0,1403	0,1843	0,1561
0,2340	0,1380	0,1777	0,2355	0,2366	0,2575	0,2479	0,2440	0,2349	0,2365	0,2292	0,2224	0,2354	0,2550	0,2648
0,3617	0,1425	0,1678	0,2457	0,3598	0,2733	0,2974	0,2584	0,3581	0,2707	0,3307	0,2935	0,3010	0,3540	0,3516

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,2872	0,1450	0,1841	0,2142	0,2625	0,1637	0,2851	0,2063	0,1808	0,2210	0,1509	0,0929	0,1644	0,1703	0,1939
0,0213	0,1494	0,0333	0,0464	0,0673	0,0322	0,0468	0,0298	0,0688	0,0394	0,0723	0,0504	0,0394	0,0647	0,0597
0,1383	0,1507	0,0901	0,0979	0,0825	0,1085	0,0959	0,1171	0,0832	0,0766	0,0997	0,0883	0,1076	0,1096	0,0923
0,3404	0,4296	0,3765	0,3291	0,3470	0,3574	0,3060	0,3347	0,3443	0,3304	0,3479	0,3013	0,3382	0,3661	0,3229
0,2979	0,1684	0,2425	0,2815	0,3199	0,3270	0,3398	0,3162	0,3096	0,3328	0,3531	0,2723	0,3152	0,3479	0,3542
0,0532	0,1554	0,1135	0,0851	0,0803	0,0768	0,0538	0,0603	0,1017	0,0581	0,0736	0,1065	0,0699	0,0866	0,0659
0,1809	0,1559	0,1194	0,1364	0,1573	0,1534	0,1752	0,1740	0,1276	0,1407	0,1604	0,1577	0,1529	0,1812	0,1429
0,1277	0,1468	0,0593	0,0683	0,0651	0,0578	0,0792	0,0591	0,0600	0,0751	0,0609	0,0648	0,0487	0,0635	0,0756
0,1064	0,1518	0,1585	0,0787	0,0783	0,0639	0,1133	0,0709	0,0983	0,1112	0,1216	0,1296	0,0723	0,1201	0,0796
0,1064	0,1494	0,1981	0,1278	0,1085	0,1101	0,1585	0,2135	0,1229	0,1185	0,1408	0,1099	0,1201	0,1040	0,1300
0,0851	0,1458	0,0660	0,0708	0,1135	0,1186	0,0841	0,0863	0,1239	0,0763	0,1306	0,1064	0,1325	0,1153	0,1448
0,0851	0,1446	0,0677	0,0985	0,1264	0,1166	0,1139	0,0946	0,0800	0,1173	0,0832	0,1222	0,1051	0,0558	0,1079
1,0000	0,8603	0,8438	0,8770	0,8926	0,8919	0,9103	0,9215	0,9342	0,9286	0,9262	0,9352	0,9277	0,9096	0,9377
0,4255	0,5179	0,3659	0,4300	0,4443	0,4021	0,4317	0,4034	0,3777	0,4013	0,4028	0,4299	0,3935	0,4033	0,3813
0,1277	0,1347	0,2255	0,0938	0,1573	0,1546	0,1302	0,1485	0,1391	0,1324	0,0992	0,1526	0,1388	0,1227	0,1332
0,1809	0,1458	0,1325	0,2086	0,1916	0,2049	0,2104	0,2263	0,1773	0,2282	0,1802	0,2204	0,1995	0,1892	0,1809
0,2234	0,1565	0,2377	0,2159	0,2252	0,2600	0,1984	0,2350	0,2394	0,2048	0,2171	0,2288	0,2434	0,2067	0,2279
0,0957	0,1486	0,2066	0,1311	0,1051	0,1271	0,0801	0,0730	0,0948	0,1103	0,0900	0,1157	0,1032	0,1002	0,1078
0,3191	0,4828	0,3493	0,3981	0,3421	0,3163	0,3552	0,3473	0,3168	0,3231	0,3258	0,3308	0,3144	0,3246	0,3314
0,2553	0,1424	0,2201	0,2491	0,2315	0,2655	0,2842	0,2670	0,2469	0,1727	0,2450	0,1677	0,2384	0,2146	0,2297
0,3404	0,1346	0,1867	0,2609	0,2353	0,2313	0,2055	0,2342	0,2338	0,2518	0,2228	0,2393	0,1918	0,3158	0,2371
0,1702	0,1571	0,2355	0,2098	0,1421	0,2322	0,1904	0,1505	0,1640	0,1816	0,1758	0,1899	0,1719	0,1586	0,1791
0,1915	0,1552	0,1706	0,2448	0,1998	0,1610	0,2067	0,1535	0,1691	0,2587	0,2010	0,2164	0,1494	0,1960	0,2112
0,0638	0,1369	0,0652	0,0544	0,0531	0,1145	0,0792	0,0830	0,0761	0,0784	0,0708	0,0930	0,0967	0,1096	0,0809
0,1809	0,1364	0,1138	0,0989	0,1565	0,1615	0,0956	0,1737	0,1701	0,1209	0,1409	0,1400	0,1785	0,1530	0,1554
0,2021	0,1459	0,1033	0,1323	0,1730	0,1295	0,1594	0,1416	0,1969	0,1391	0,1737	0,1735	0,1686	0,1386	0,1641
0,1489	0,1363	0,0486	0,0559	0,0657	0,0714	0,0868	0,0872	0,1091	0,0893	0,0987	0,0752	0,1148	0,1213	0,0909
0,0851	0,1391	0,0714	0,1066	0,1247	0,1241	0,0947	0,1075	0,1377	0,1330	0,0944	0,1034	0,1536	0,1291	0,1501
0,5106	0,1530	0,4636	0,4876	0,4627	0,4874	0,4555	0,4860	0,4914	0,5257	0,4905	0,4939	0,5020	0,5125	0,5171
0,3511	0,1560	0,1804	0,2526	0,2821	0,2457	0,2893	0,2572	0,2283	0,2279	0,2553	0,1957	0,2369	0,2912	0,2763
0,1596	0,1754	0,2275	0,2076	0,1455	0,1931	0,1534	0,1947	0,2143	0,1949	0,2032	0,2188	0,1970	0,2114	0,1749
0,2553	0,2063	0,2176	0,2995	0,3006	0,2775	0,3083	0,2693	0,2842	0,2782	0,2900	0,2708	0,2978	0,3014	0,3114

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,0851	0,1688	0,1823	0,0801	0,0667	0,0741	0,1279	0,1007	0,0721	0,1398	0,0864	0,0972	0,0977	0,1055	0,1172
0,2234	0,1791	0,2619	0,3257	0,2469	0,2397	0,2031	0,2580	0,2722	0,2677	0,2867	0,2897	0,2767	0,2748	0,2945
0,1489	0,1855	0,2132	0,1793	0,1818	0,2077	0,1845	0,2115	0,2116	0,2007	0,2065	0,2004	0,1895	0,1909	0,1599
0,2234	0,1788	0,2379	0,1471	0,1327	0,2028	0,1435	0,2209	0,1959	0,2347	0,1773	0,2068	0,1893	0,2086	0,2117
0,2553	0,1996	0,2460	0,2834	0,2538	0,2378	0,2735	0,2428	0,2968	0,2578	0,2837	0,2841	0,2740	0,2867	0,2684
0,2340	0,2039	0,1787	0,2304	0,2486	0,2658	0,2322	0,2524	0,2168	0,1812	0,2047	0,1616	0,1837	0,1424	0,1990
0,8404	0,8725	0,8551	0,8886	0,9144	0,8966	0,9357	0,9531	0,8903	0,9174	0,9065	0,8742	0,9194	0,8679	0,9380
0,3617	0,2905	0,4119	0,3660	0,3257	0,3480	0,3359	0,3727	0,3665	0,3469	0,3682	0,3809	0,3878	0,3662	0,3421
0,4255	0,5723	0,4403	0,4432	0,4766	0,4746	0,4675	0,4300	0,4455	0,4516	0,4327	0,4406	0,4428	0,4308	0,4369
0,0213	0,1965	0,0613	0,0775	0,0673	0,0711	0,0614	0,0967	0,1013	0,0949	0,0775	0,0774	0,1294	0,0807	0,0871
0,0957	0,1586	0,0617	0,0556	0,0355	0,0946	0,0527	0,0729	0,0324	0,0832	0,0232	0,1050	0,0630	0,0694	0,0488
0,1489	0,1610	0,2172	0,1511	0,1464	0,1589	0,1661	0,1708	0,1424	0,1695	0,1807	0,1729	0,1960	0,1356	0,1479
0,2766	0,1885	0,2056	0,3001	0,2658	0,3021	0,2503	0,3075	0,2854	0,2936	0,3164	0,3107	0,2847	0,2740	0,2977
0,3404	0,2581	0,6215	0,2005	0,2560	0,1174	0,4150	0,6787	0,5378	0,6323	0,4306	0,4095	0,3917	0,4041	0,1800
0,3298	0,2534	0,6197	0,2917	0,4346	0,2061	0,5327	0,8165	0,5508	0,7789	0,5957	0,4594	0,4969	0,5071	0,3486
0,2872	0,1515	0,4432	0,1519	0,1255	0,1043	0,2814	0,5287	0,3413	0,3988	0,3032	0,2547	0,3125	0,3110	0,1134
0,0745	0,1145	0,4127	0,1743	0,1585	0,0980	0,3199	0,5405	0,2101	0,5156	0,2365	0,2013	0,2558	0,2063	0,1408
0,1277	0,0912	0,2675	0,0640	0,1679	0,0772	0,1303	0,3207	0,1745	0,4379	0,1933	0,1153	0,1321	0,1621	0,0633
0,4468	0,1521	0,5524	0,2435	0,2415	0,2083	0,4376	0,5892	0,4909	0,4384	0,3616	0,2951	0,4160	0,3843	0,1624
0,3085	0,1417	0,4547	0,2003	0,1462	0,1344	0,3068	0,6418	0,3214	0,4051	0,3727	0,2808	0,3257	0,3563	0,1526
0,2553	0,1758	0,4747	0,3178	0,2380	0,2144	0,3759	0,7130	0,4015	0,5361	0,4213	0,3359	0,3974	0,3435	0,1968
0,2766	0,0599	0,4331	0,1162	0,1180	0,0844	0,2689	0,5368	0,2625	0,4488	0,2487	0,1951	0,2175	0,1731	0,1184
0,3191	0,1048	0,4091	0,1386	0,1708	0,1891	0,2343	0,5527	0,3432	0,6200	0,4243	0,3773	0,3082	0,3204	0,1594
0,8404	0,4959	0,9121	0,6928	0,7419	0,6833	0,7508	0,9569	0,9344	0,8806	0,8815	0,8124	0,8541	0,8584	0,8029
0,2447	0,1312	0,7090	0,3268	0,3048	0,2896	0,4947	0,6329	0,4436	0,8115	0,3555	0,4588	0,4301	0,3114	0,1618
0,1489	0,0759	0,3980	0,1334	0,1071	0,0578	0,3034	0,6020	0,2008	0,3716	0,2601	0,1682	0,2519	0,2019	0,1211
0,2340	0,0484	0,4736	0,0687	0,3097	0,0426	0,2281	0,4492	0,3112	0,5342	0,3650	0,1818	0,1336	0,2893	0,1450
0,2234	0,0484	0,4736	0,0687	0,3097	0,0426	0,2281	0,4492	0,3112	0,5342	0,3650	0,1818	0,1336	0,2893	0,1450
0,2979	0,2879	0,7823	0,2954	0,3918	0,4211	0,5014	0,7588	0,6333	0,7632	0,5878	0,3142	0,4506	0,5425	0,2808
0,1809	0,0682	0,4196	0,1187	0,1056	0,0791	0,2915	0,5811	0,2298	0,3174	0,2355	0,1830	0,2631	0,1876	0,1137
0,0851	0,0492	0,1963	0,0420	0,0446	0,0292	0,1144	0,2652	0,0811	0,2302	0,1082	0,0666	0,0914	0,1113	0,0429
0,2447	0,1061	0,4226	0,1722	0,1596	0,1024	0,2906	0,6093	0,3579	0,3198	0,3066	0,2631	0,3068	0,2908	0,1178

CONTINUA

CONCLUSÃO

VALOR DESEJADO	NEURÔNIOS NA CAMADA ESCONDIDA													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
0,2128	0,0770	0,4673	0,2023	0,2114	0,0647	0,2882	0,5880	0,2638	0,3870	0,3363	0,2370	0,2464	0,2769	0,1848
0,4574	0,4280	0,5313	0,4629	0,4896	0,4305	0,5576	0,9210	0,6388	0,7399	0,7000	0,4439	0,6715	0,8126	0,5094
0,1702	0,0562	0,2936	0,1041	0,1065	0,0469	0,1362	0,5274	0,1500	0,5281	0,1929	0,1401	0,1527	0,2164	0,1128
0,3298	0,1505	0,5240	0,3890	0,3179	0,1446	0,4029	0,7040	0,4798	0,5962	0,4801	0,4335	0,4341	0,4590	0,2305
0,1915	0,1325	0,5915	0,0786	0,1819	0,1371	0,1973	0,5984	0,2884	0,5353	0,2823	0,2469	0,1788	0,2764	0,1387
0,5745	0,4166	0,8454	0,4874	0,5096	0,5808	0,8151	0,9469	0,7254	0,8134	0,6526	0,5887	0,8015	0,6678	0,5513
RMSE Tr	0,0971	0,0756	0,0525	0,0441	0,0504	0,0460	0,0461	0,0443	0,0468	0,0443	0,0523	0,0513	0,0398	0,0414
RMSE Tes	0,1518	0,2474	0,1073	0,0959	0,1375	0,1200	0,3498	0,1294	0,2901	0,1307	0,0768	0,1089	0,1135	0,1077
NEURÔNIOS	1	2	3	4	5	6	7	8	9	10	11	12	13	14

APÊNDICE XII

TABELA A.9 – VARIAÇÃO DO NÚMERO DE ITERAÇÕES - TESTE III, 10 COMPONENTES PRINCIPAIS, 1º PROCESSO, 11 NEURÔNIOS NA CAMADA ESCONDIDA

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,0851	0,1201	0,1760	0,1894	0,1863	0,1779	0,1683	0,1584	0,1482	0,1388	0,1313	0,1140	0,0984	0,0894
0,0957	0,0711	0,0761	0,0852	0,0957	0,1043	0,1097	0,1117	0,1116	0,1107	0,1098	0,1044	0,0857	0,0862
0,2766	0,1414	0,1749	0,2005	0,2249	0,2399	0,2471	0,2478	0,2457	0,2444	0,2451	0,2697	0,2779	0,2767
0,9149	0,6665	0,7419	0,7845	0,8130	0,8344	0,8532	0,8703	0,8845	0,8948	0,9023	0,9207	0,9065	0,9113
0,1489	0,1387	0,1209	0,1243	0,1266	0,1247	0,1241	0,1276	0,1341	0,1400	0,1436	0,1473	0,1487	0,1484
0,2340	0,1529	0,1774	0,2005	0,2171	0,2257	0,2320	0,2378	0,2415	0,2414	0,2393	0,2302	0,2338	0,2340
0,2234	0,2127	0,1957	0,1840	0,1776	0,1776	0,1815	0,1867	0,1924	0,1984	0,2044	0,2310	0,2286	0,2232
0,3936	0,5157	0,5068	0,4879	0,4739	0,4610	0,4509	0,4424	0,4344	0,4276	0,4223	0,3938	0,3968	0,3944
0,1489	0,1433	0,1126	0,1101	0,1134	0,1162	0,1180	0,1194	0,1214	0,1237	0,1258	0,1570	0,1580	0,1513
0,3830	0,4706	0,4367	0,4154	0,4097	0,4077	0,4043	0,4002	0,3980	0,3973	0,3967	0,3892	0,3795	0,3821
0,1489	0,2293	0,2312	0,2268	0,2265	0,2314	0,2407	0,2486	0,2473	0,2383	0,2266	0,1682	0,1489	0,1473
0,1489	0,1261	0,1171	0,1232	0,1324	0,1422	0,1521	0,1598	0,1635	0,1638	0,1627	0,1542	0,1424	0,1409
0,0319	0,1107	0,0943	0,0917	0,0901	0,0869	0,0823	0,0773	0,0732	0,0698	0,0669	0,0538	0,0435	0,0307
0,0426	0,0605	0,0556	0,0576	0,0616	0,0645	0,0654	0,0649	0,0645	0,0647	0,0649	0,0522	0,0411	0,0391
0,9468	0,7920	0,8075	0,8288	0,8428	0,8551	0,8670	0,8794	0,8919	0,9023	0,9101	0,9369	0,9448	0,9456
0,0213	0,1339	0,1055	0,0895	0,0796	0,0725	0,0678	0,0653	0,0642	0,0632	0,0618	0,0520	0,0426	0,0313
0,1383	0,1339	0,1316	0,1341	0,1410	0,1448	0,1442	0,1422	0,1417	0,1423	0,1427	0,1430	0,1399	0,1380
0,1489	0,0933	0,1013	0,1144	0,1241	0,1297	0,1314	0,1307	0,1299	0,1302	0,1310	0,1274	0,1392	0,1464
0,3404	0,3927	0,3707	0,3601	0,3544	0,3515	0,3496	0,3466	0,3418	0,3367	0,3331	0,3423	0,3428	0,3416
0,2660	0,2691	0,2997	0,2948	0,2908	0,2886	0,2856	0,2834	0,2840	0,2859	0,2871	0,2765	0,2707	0,2675
0,0426	0,1754	0,1095	0,0940	0,0881	0,0832	0,0792	0,0758	0,0743	0,0746	0,0753	0,0652	0,0533	0,0429
0,1489	0,0620	0,0669	0,0733	0,0797	0,0844	0,0880	0,0921	0,0984	0,1068	0,1160	0,1506	0,1525	0,1505
0,0851	0,0749	0,0627	0,0518	0,0451	0,0408	0,0378	0,0356	0,0339	0,0328	0,0320	0,0354	0,0658	0,0781
0,0745	0,1131	0,1110	0,1175	0,1224	0,1226	0,1195	0,1143	0,1080	0,1015	0,0955	0,0714	0,0828	0,0754
0,2340	0,2010	0,1943	0,1899	0,1874	0,1869	0,1909	0,1979	0,2042	0,2088	0,2125	0,2319	0,2374	0,2355
0,2447	0,2268	0,2647	0,2844	0,2909	0,2922	0,2901	0,2848	0,2793	0,2752	0,2718	0,2435	0,2408	0,2440
0,0638	0,0514	0,0440	0,0432	0,0442	0,0452	0,0459	0,0460	0,0456	0,0448	0,0440	0,0436	0,0516	0,0426
0,1277	0,2188	0,1941	0,1743	0,1654	0,1612	0,1592	0,1574	0,1552	0,1526	0,1499	0,1324	0,1243	0,1259
0,2340	0,1341	0,1941	0,2254	0,2281	0,2224	0,2198	0,2220	0,2267	0,2312	0,2344	0,2360	0,2337	0,2333
0,3617	0,1774	0,2227	0,2399	0,2657	0,2935	0,3124	0,3259	0,3362	0,3438	0,3495	0,3591	0,3586	0,3606

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,2872	0,0768	0,0816	0,0840	0,0876	0,0929	0,1021	0,1157	0,1327	0,1506	0,1669	0,2546	0,2819	0,2880
0,0213	0,0613	0,0506	0,0487	0,0495	0,0504	0,0510	0,0509	0,0502	0,0493	0,0484	0,0479	0,0540	0,0462
0,1383	0,0799	0,0771	0,0779	0,0816	0,0883	0,0996	0,1161	0,1366	0,1576	0,1756	0,1971	0,1557	0,1420
0,3404	0,3626	0,3443	0,3235	0,3098	0,3013	0,2991	0,2997	0,3030	0,3091	0,3158	0,3390	0,3414	0,3408
0,2979	0,2061	0,2349	0,2514	0,2636	0,2723	0,2795	0,2865	0,2957	0,3059	0,3140	0,3198	0,3041	0,2982
0,0532	0,1326	0,1297	0,1237	0,1151	0,1065	0,0989	0,0925	0,0873	0,0828	0,0788	0,0623	0,0629	0,0570
0,1809	0,1437	0,1374	0,1414	0,1472	0,1577	0,1739	0,1915	0,2035	0,2092	0,2119	0,1992	0,1875	0,1854
0,1277	0,0732	0,0654	0,0652	0,0652	0,0648	0,0644	0,0635	0,0617	0,0593	0,0571	0,0570	0,0831	0,1142
0,1064	0,1365	0,1296	0,1291	0,1299	0,1296	0,1274	0,1224	0,1159	0,1093	0,1032	0,0666	0,0835	0,1039
0,1064	0,1652	0,1523	0,1351	0,1208	0,1099	0,1025	0,0977	0,0952	0,0936	0,0922	0,1089	0,1147	0,1108
0,0851	0,1067	0,0996	0,1002	0,1030	0,1064	0,1096	0,1123	0,1141	0,1150	0,1155	0,1003	0,0819	0,0806
0,0851	0,0907	0,0939	0,1053	0,1158	0,1222	0,1237	0,1211	0,1158	0,1099	0,1047	0,0883	0,0984	0,0951
1,0000	0,8470	0,8946	0,9166	0,9283	0,9352	0,9393	0,9422	0,9446	0,9468	0,9488	0,9611	0,9764	0,9870
0,4255	0,5217	0,4675	0,4506	0,4399	0,4299	0,4191	0,4105	0,4065	0,4061	0,4071	0,4208	0,4256	0,4257
0,1277	0,1722	0,1578	0,1571	0,1563	0,1526	0,1473	0,1407	0,1349	0,1323	0,1323	0,1304	0,1240	0,1275
0,1809	0,1549	0,1777	0,2004	0,2133	0,2204	0,2252	0,2287	0,2305	0,2304	0,2302	0,2271	0,1868	0,1814
0,2234	0,2036	0,2181	0,2269	0,2278	0,2288	0,2305	0,2308	0,2295	0,2282	0,2278	0,2298	0,2212	0,2238
0,0957	0,2085	0,1517	0,1280	0,1196	0,1157	0,1133	0,1101	0,1067	0,1036	0,1008	0,0826	0,0942	0,0961
0,3191	0,3160	0,3208	0,3234	0,3292	0,3308	0,3316	0,3318	0,3306	0,3290	0,3274	0,3218	0,3182	0,3185
0,2553	0,1720	0,1828	0,1798	0,1727	0,1677	0,1660	0,1664	0,1667	0,1670	0,1686	0,2454	0,2559	0,2549
0,3404	0,1408	0,1766	0,1954	0,2150	0,2393	0,2646	0,2867	0,3003	0,3074	0,3119	0,3385	0,3422	0,3405
0,1702	0,1966	0,2007	0,1963	0,1907	0,1899	0,1914	0,1921	0,1913	0,1894	0,1868	0,1716	0,1695	0,1703
0,1915	0,1510	0,1719	0,2037	0,2170	0,2164	0,2103	0,2039	0,1994	0,1963	0,1936	0,1777	0,1921	0,1909
0,0638	0,1153	0,1073	0,1009	0,0962	0,0930	0,0912	0,0895	0,0873	0,0849	0,0829	0,0858	0,0749	0,0650
0,1809	0,1267	0,1381	0,1388	0,1383	0,1400	0,1418	0,1424	0,1414	0,1396	0,1380	0,1517	0,1836	0,1819
0,2021	0,1549	0,1709	0,1750	0,1747	0,1735	0,1706	0,1672	0,1650	0,1640	0,1639	0,1876	0,2044	0,2052
0,1489	0,0922	0,0915	0,0848	0,0795	0,0752	0,0705	0,0660	0,0625	0,0599	0,0579	0,0576	0,1267	0,1477
0,0851	0,1061	0,1144	0,1100	0,1064	0,1034	0,0994	0,0961	0,0949	0,0952	0,0959	0,0995	0,0966	0,0890
0,5106	0,4247	0,4812	0,4935	0,4930	0,4939	0,4929	0,4924	0,4946	0,4971	0,4991	0,5062	0,5121	0,5110
0,3511	0,1599	0,1687	0,1741	0,1842	0,1957	0,2083	0,2213	0,2337	0,2440	0,2518	0,3022	0,3431	0,3487
0,1596	0,2287	0,2209	0,2145	0,2149	0,2188	0,2240	0,2257	0,2201	0,2095	0,1974	0,1392	0,1481	0,1580
0,2553	0,2817	0,2973	0,2898	0,2810	0,2708	0,2625	0,2592	0,2610	0,2644	0,2669	0,2534	0,2585	0,2574

CONTINUA

CONTINUAÇÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,0851	0,1469	0,1214	0,1096	0,1023	0,0972	0,0933	0,0898	0,0869	0,0847	0,0836	0,0880	0,0749	0,0834
0,2234	0,2282	0,2561	0,2714	0,2844	0,2897	0,2865	0,2762	0,2648	0,2560	0,2499	0,2355	0,2231	0,2231
0,1489	0,1842	0,1837	0,1884	0,1945	0,2004	0,2060	0,2097	0,2094	0,2059	0,2015	0,1767	0,1606	0,1579
0,2234	0,2413	0,2283	0,2191	0,2111	0,2068	0,2050	0,2043	0,2041	0,2042	0,2045	0,1962	0,2183	0,2231
0,2553	0,3239	0,3087	0,3033	0,2948	0,2841	0,2755	0,2709	0,2682	0,2662	0,2645	0,2542	0,2544	0,2550
0,2340	0,2055	0,1952	0,1811	0,1687	0,1616	0,1625	0,1720	0,1857	0,1974	0,2050	0,2246	0,2272	0,2303
0,8404	0,8630	0,8791	0,8802	0,8772	0,8742	0,8718	0,8695	0,8663	0,8619	0,8568	0,8482	0,8434	0,8413
0,3617	0,4756	0,4104	0,3899	0,3839	0,3809	0,3763	0,3692	0,3622	0,3577	0,3557	0,3589	0,3596	0,3606
0,4255	0,5224	0,4612	0,4470	0,4459	0,4406	0,4333	0,4273	0,4240	0,4231	0,4235	0,4174	0,4243	0,4264
0,0213	0,0962	0,0941	0,0850	0,0793	0,0774	0,0772	0,0771	0,0763	0,0750	0,0735	0,0574	0,0367	0,0306
0,0957	0,0660	0,0827	0,0911	0,0974	0,1050	0,1137	0,1212	0,1251	0,1247	0,1213	0,0921	0,0971	0,0963
0,1489	0,1402	0,1561	0,1674	0,1716	0,1729	0,1728	0,1729	0,1737	0,1753	0,1766	0,1635	0,1478	0,1471
0,2766	0,3094	0,3837	0,3687	0,3341	0,3107	0,2925	0,2795	0,2727	0,2702	0,2699	0,2732	0,2760	0,2770
0,3404	0,3734	0,3983	0,4081	0,4094	0,4095	0,4117	0,4168	0,4237	0,4299	0,4354	0,4728	0,4660	0,4719
0,3298	0,3669	0,4171	0,4342	0,4457	0,4594	0,4764	0,4954	0,5130	0,5260	0,5348	0,5766	0,5228	0,4224
0,2872	0,2996	0,2945	0,2764	0,2634	0,2547	0,2491	0,2431	0,2339	0,2222	0,2105	0,1657	0,1638	0,1441
0,0745	0,2075	0,2173	0,2170	0,2093	0,2013	0,1939	0,1852	0,1752	0,1652	0,1567	0,1383	0,1679	0,1603
0,1277	0,1111	0,1102	0,1111	0,1117	0,1153	0,1225	0,1318	0,1423	0,1519	0,1596	0,2072	0,2324	0,2445
0,4468	0,3213	0,3418	0,3250	0,3085	0,2951	0,2799	0,2587	0,2309	0,2036	0,1822	0,1643	0,2085	0,1929
0,3085	0,3044	0,3081	0,2952	0,2846	0,2808	0,2811	0,2806	0,2772	0,2729	0,2690	0,2632	0,3181	0,2914
0,2553	0,3082	0,3298	0,3347	0,3341	0,3359	0,3400	0,3420	0,3395	0,3345	0,3299	0,3626	0,4409	0,4011
0,2766	0,2268	0,2236	0,2175	0,2074	0,1951	0,1829	0,1722	0,1652	0,1621	0,1610	0,1697	0,1996	0,1996
0,3191	0,3385	0,3600	0,3652	0,3705	0,3773	0,3836	0,3862	0,3872	0,3901	0,3957	0,5048	0,4996	0,5174
0,8404	0,7452	0,7947	0,8072	0,8096	0,8124	0,8189	0,8297	0,8419	0,8521	0,8597	0,8777	0,9219	0,9462
0,2447	0,3744	0,4011	0,4301	0,4547	0,4588	0,4418	0,4146	0,3868	0,3623	0,3417	0,3005	0,4685	0,5727
0,1489	0,2478	0,2328	0,2078	0,1859	0,1682	0,1536	0,1407	0,1295	0,1205	0,1131	0,0776	0,0938	0,0889
0,2340	0,1910	0,1853	0,1794	0,1798	0,1818	0,1854	0,1906	0,1961	0,2004	0,2031	0,2201	0,1580	0,1214
0,2234	0,1910	0,1853	0,1794	0,1798	0,1818	0,1854	0,1906	0,1961	0,2004	0,2031	0,2201	0,1580	0,1214
0,2979	0,3273	0,3624	0,3720	0,3543	0,3142	0,2593	0,2074	0,1723	0,1512	0,1380	0,1223	0,2689	0,2746
0,1809	0,2413	0,2296	0,2110	0,1958	0,1830	0,1720	0,1623	0,1547	0,1495	0,1455	0,1233	0,1447	0,1327
0,0851	0,1073	0,0932	0,0822	0,0739	0,0666	0,0598	0,0531	0,0469	0,0417	0,0376	0,0250	0,0241	0,0167
0,2447	0,2596	0,2683	0,2691	0,2655	0,2631	0,2618	0,2607	0,2597	0,2585	0,2570	0,2803	0,3665	0,3303

CONTINUA

CONCLUSÃO

VALOR DESEJADO	ITERAÇÕES												
	10	20	30	40	50	60	70	80	90	100	200	500	1000
0,2128	0,2042	0,2290	0,2298	0,2311	0,2370	0,2445	0,2489	0,2472	0,2397	0,2289	0,1532	0,1151	0,0934
0,4574	0,4796	0,4713	0,4577	0,4463	0,4439	0,4512	0,4656	0,4820	0,4961	0,5063	0,4709	0,4434	0,3782
0,1702	0,1425	0,1499	0,1514	0,1471	0,1401	0,1310	0,1208	0,1117	0,1042	0,0980	0,0651	0,0506	0,0378
0,3298	0,3875	0,4203	0,4276	0,4315	0,4335	0,4327	0,4267	0,4145	0,3999	0,3859	0,3286	0,4777	0,4163
0,1915	0,1945	0,2204	0,2311	0,2381	0,2469	0,2568	0,2677	0,2805	0,2940	0,3070	0,3949	0,4168	0,4239
0,5745	0,5226	0,5796	0,5894	0,5888	0,5887	0,5845	0,5693	0,5434	0,5130	0,4836	0,3331	0,3733	0,2685
RMSE Tr	0,0834	0,0682	0,0611	0,0562	0,0523	0,0488	0,0453	0,0419	0,0387	0,0361	0,0233	0,0107	0,0055
RMSE Tes	0,0610	0,0655	0,0710	0,0747	0,0768	0,0785	0,0818	0,0866	0,0919	0,0970	0,1275	0,1335	0,1486
ITERAÇÕES	10	20	30	40	50	60	70	80	90	100	200	500	1000

APÊNDICE XIII

TABELA A.10 - RESULTADOS PRÁTICOS DO TESTE III COM 23 COMPONENTES

Saída da RNA		Tempo de Processo		Saída da RNA		Tempo de Processo	
Desejada	Obtida	Desejado	Obtido	Desejada	Obtida	Desejado	Obtido
0,085	0,106	8	10	0,340	0,345	32	32
0,096	0,133	9	12	0,170	0,173	16	16
0,277	0,274	26	26	0,191	0,171	18	16
0,915	0,918	86	86	0,064	0,037	6	3
0,149	0,126	14	12	0,181	0,189	17	18
0,234	0,240	22	23	0,202	0,197	19	18
0,223	0,220	21	21	0,149	0,099	14	9
0,394	0,396	37	37	0,085	0,118	8	11
0,149	0,126	14	12	0,511	0,506	48	48
0,383	0,392	36	37	0,351	0,315	33	30
0,149	0,158	14	15	0,160	0,184	15	17
0,149	0,166	14	16	0,255	0,205	24	19
0,032	0,049	3	5	0,085	0,111	8	10
0,043	0,030	4	3	0,223	0,192	21	18
0,947	0,917	89	86	0,149	0,195	14	18
0,021	0,050	2	5	0,223	0,222	21	21
0,138	0,172	13	16	0,255	0,248	24	23
0,149	0,146	14	14	0,234	0,229	22	22
0,340	0,332	32	31	0,840	0,867	79	81
0,266	0,249	25	23	0,362	0,370	34	35
0,043	0,076	4	7	0,426	0,424	40	40
0,149	0,144	14	14	0,021	0,057	2	5
0,085	0,122	8	11	0,096	0,073	9	7
0,074	0,036	7	3	0,149	0,152	14	14
0,234	0,232	22	22	0,277	0,266	26	25
0,245	0,263	23	25	0,340	0,438	32	41
0,064	0,039	6	4	0,330	0,388	31	37
0,128	0,097	12	9	0,287	0,289	27	27
0,234	0,238	22	22	0,074	0,188	7	18
0,362	0,357	34	34	0,128	0,101	12	10
0,287	0,282	27	27	0,447	0,226	42	21
0,021	0,034	2	3	0,309	0,227	29	21
0,138	0,138	13	13	0,255	0,220	24	21
0,340	0,349	32	33	0,277	0,187	26	18
0,298	0,302	28	28	0,319	0,327	30	31
0,053	0,045	5	4	0,840	0,750	79	70
0,181	0,120	17	11	0,245	0,237	23	22
0,128	0,108	12	10	0,149	0,150	14	14
0,106	0,100	10	9	0,234	0,185	22	17
0,106	0,076	10	7	0,223	0,185	21	17
0,085	0,102	8	10	0,298	0,226	28	21
0,085	0,097	8	9	0,181	0,221	17	21
1,000	0,919	94	86	0,085	0,162	8	15
0,426	0,430	40	40	0,245	0,266	23	25
0,128	0,147	12	14	0,213	0,176	20	17
0,181	0,200	17	19	0,457	0,385	43	36
0,223	0,220	21	21	0,170	0,133	16	12
0,096	0,097	9	9	0,330	0,291	31	27
0,319	0,317	30	30	0,191	0,184	18	17
0,255	0,281	24	26	0,574	0,575	54	54