

Renata Chaomey Wo

**Um Sistema de Resposta Automática via *Web*
para o Desafio SEBRAE**

**Rio de Janeiro - RJ
2005**

Um Sistema de Resposta Automática via *Web* para o Desafio SEBRAE

Renata Chaomey Wo

Universidade Federal do Rio de Janeiro – UFRJ
Instituto de Matemática - IM
Núcleo de Computação Eletrônica - NCE
Dissertação de Mestrado

Grau: Mestrado em Informática

Orientador: Antonio Juarez Alencar
D.Phil. em Ciência da Computação - Oxford University

**Rio de Janeiro - RJ
2005**

Um Sistema de Resposta Automática via *Web* para o Desafio SEBRAE

Renata Chaomey Wo

Dissertação de Mestrado submetida ao corpo docente do Programa de Pós-Graduação em Informática do Instituto de Matemática e Núcleo de Computação Eletrônica (IM/NCE) – Universidade Federal do Rio de Janeiro – UFRJ, como parte dos requisitos necessários à obtenção do grau de Mestre.

Aprovada por:

_____ - Orientador

Prof. Antonio Juarez Alencar, D.Phil.

Prof. Eber Assis Schmitz, Ph.D.

Prof^a. Claudia Lage Rebello da Motta, D.Sc.

Prof. Marcio de Oliveira Barros, D.Sc.

Rio de Janeiro - RJ
2005

W837

Wo, Renata Chaomey.

Um sistema de resposta automática via web para o desafio Sebrae. Rio de Janeiro : UFRJ/IM/NCE, 2005.
136 p. : il.

Dissertação (Mestrado em Informática) – Universidade Federal do Rio de Janeiro. Instituto de Matemática. Núcleo de Computação Eletrônica, 2005.

Orientador: Antonio Juarez Sylvio de Menezes de Alencar.

1.Sistemas de resposta automática 2.Redes neurais
3. Desafio Sebrae I. Alencar, Antonio Juarez Sylvio de Menezes de, Orient. II. Universidade Federal do Rio de Janeiro. Instituto de Matemática. Núcleo de Computação Eletrônica. III. Título.

AGRADECIMENTOS

Antes de mais nada, agradeço a Deus por ter possibilitado o início e a conclusão desta importante conquista em minha vida e pela inspiração nos momentos decisivos.

Ao professor Juarez, pela orientação impecável ao longo de todo o processo de confecção desta dissertação.

A meus pais e minhas irmãs, pelo incentivo constante e pela compreensão no decorrer deste período.

Ao Gláucio, pelo carinho, companheirismo e compreensão durante este anos de trabalho.

Aos meus amigos, que me apoiaram e me incentivaram nos momentos mais difíceis.

Em especial, ao meu amigo e mestre Eugênio pelo apoio oferecido durante estes anos. E a minha amiga Alissandra, pelos ótimos momentos de amizade e pelos incentivos nas horas mais necessárias.

A todos que, ao longo deste período, estiveram torcendo por mim.

RESUMO

WO, Renata Chaomey. Um Sistema de Resposta Automática via *Web* para o Desafio SEBRAE. Orientador: Antonio Juarez Alencar. Rio de Janeiro: UFRJ/IM/NCE, 2005. Dissertação.

Vivemos em uma era na qual um número cada vez maior de organizações utiliza a Internet para comercializar os produtos e serviços que oferecem à sociedade. Na medida em que o número de consumidores aumenta em todo o mundo, aumenta também o volume de solicitações de informações direcionadas às organizações que fornecem os produtos e serviços que estes consumidores desejam adquirir.

Para atender ao aumento da demanda por informações via Internet, muitas organizações têm optado por oferecer serviços de atendimento *on-line* na forma de endereços de correio eletrônico (*e-mail*) e serviços de atendimento em tempo real através de facilidades do tipo *chat*¹ com operadores de *telemarketing*.

Nesta dissertação, apresentamos os passos necessários para a construção de sistemas de resposta automática baseados na tecnologia de redes neurais que sejam capazes de prover uma maior rapidez no atendimento à solicitação de informações, uma padronização das respostas, às custas de uma alta taxa de acerto nas respostas enviadas aos clientes. Os passos que propomos são exemplificados através da construção de um sistema de resposta automática para o Desafio SEBRAE.

¹ O serviço de atendimento via *Chat* é uma forma de comunicação onde os usuários trocam informações em tempo real.

ABSTRACT

WO, Renata Chaomey. Um Sistema de Resposta Automática via *Web* para o Desafio SEBRAE. Orientador: Antonio Juarez Alencar. Rio de Janeiro: UFRJ/IM/NCE, 2005. Dissertação.

We live in a time in which an increasing number of companies use the Internet to sell products and services to society. As the number of customers increases in the entire world, so does the demand for on-line information about these products and services.

To attend this increasing demand, many companies have opted to provide customer support over email or real time services by on-line conversation (chat programs) with hired telemarketing operators.

In this paper, we present a stepwise approach in the construction of automatic question answering systems based on neural network technologies, capable of providing greater performance on customer support by standardizing answers and increasing response speed, including a high rate of correct answers sent to the customers. The proposed steps are given through the example of an automatic question answering system built for “Desafio SEBRAE”.

LISTA DE SIGLAS

ADALINE	-	ADaptive Llinear NEuron
ART	-	Adaptative Ressonance Theory
Cebrae	-	Centro Brasileiro de Apoio à Pequena e Média Empresa
IBGE	-	Instituto Brasileiro de Geografia e Estatística
MCP	-	McCulloch-Pitts
MLP	-	MultiLayer Perceptron
MPEs	-	Micro e Pequenas Empresas
PIB	-	Produto Interno Bruto
RNAs	-	Redes Neurais Artificiais
SEBRAE	-	Serviço Brasileiro de Apoio às Micro e Pequenas Empresas

LISTA DE FIGURAS

Figura 1.1: Distribuição da receita das empresas, segundo o seu porte.....	4
Figura 1.2: Participação das MPEs no Brasil, segundo a sua receita	5
Figura 1.3: Distribuição do pessoal ocupado das empresas, segundo o seu porte....	5
Figura 1.4: Participação das MPEs no Brasil, segundo o pessoal ocupado.....	6
Figura 1.5: Participação das MPEs no Brasil.....	6
Figura 2.1: População e percentual de usuários da Internet no Mundo - 2005	14
Figura 3.1: Componentes de um neurônio biológico	26
Figura 3.2: Neurônio de McCulloch e Pitts	28
Figura 3.3: Função Linear	30
Figura 3.4: Função Rampa.....	30
Figura 3.5: Função Degrau.....	31
Figura 3.6: Função Sigmóide.....	31
Figura 3.7: Rede com apenas uma camada.....	34
Figura 3.8: Rede com múltiplas camadas	35
Figura 3.9: Rede cíclica	35
Figura 3.10: Rede fracamente conectada	36
Figura 3.11: Arquitetura básica da rede perceptron	39
Figura 3.12: Fronteira de decisão da rede perceptron.....	40
Figura 3.13: Rede MLP com duas camadas escondidas	42
Figura 3.14: Superfície de erro de uma rede MLP.....	43
Figura 3.15: Ajuste dos pesos dos neurônios na camada de saída	44
Figura 3.16: Fluxo de processamento do algoritmo <i>back-propagation</i>	45
Figura 4.1: Mensagem com sua resposta personalizada	49
Figura 4.2: Mensagem com múltiplos temas associados	49
Figura 4.3: Processo de manipulação das mensagens	50
Figura 4.4: Processo de manipulação das respostas	51
Figura 4.5: Mensagem e sua Resposta.....	52
Figura 4.6: Arquitetura do sistema de resposta automática	53
Figura 4.7: Processo de tokenização	54
Figura 4.8: Processo de tradução.....	56
Figura 4.9: Transcrição fonológica	57
Figura 4.10: Processo de redução dos verbos aos seus infinitivos	58

Figura 4.11: Exemplo de remoção das <i>stop words</i>	60
Figura 4.12: Separação de duas classes por um grupo de fonemas.....	66
Figura 4.13: Valor de diminuição da diversidade para a transcrição /sabeR/	67
Figura 4.14: Valor de diminuição da diversidade para a transcrição /materiaw/	68
Figura 5.1: Perguntas contidas na base de conhecimento	84
Figura 6.1: Exemplo de ambiente de comunicação com o participante de desafio ..	99

LISTA DE TABELAS

Tabela 4.1: Grupos de fonemas relevantes.....	61
Tabela 4.2: Cálculo do índice Gini.....	65
Tabela 4.3: Ferramentas utilizadas na construção do modelo quantitativo	72
Tabela 5.1: Melhor resultado obtido no sistema de resposta automática	74
Tabela 5.2: Número de fonemas relevantes selecionados por experimento	75
Tabela 5.3: Resultados obtidos sob a perspectiva do participante.....	76
Tabela 5.4: Perspectiva do desenvolvedor do modelo matemático.....	76
Tabela 5.5: Perspectiva do gestor do desafio.....	77
Tabela 5.6: Perspectiva do desenvolvedor do modelo por número de fonemas	78
Tabela 5.7: Tradução sob a perspectiva do participante	79
Tabela 5.8: Tradução sob a perspectiva do gestor do desafio	80
Tabela 5.9: Tradução sob a perspectiva do desenvolvedor do modelo.....	80
Tabela 5.10: Transcrição sob a perspectiva do participante	81
Tabela 5.11: Transcrição sob a perspectiva do gestor do desafio.....	82
Tabela 5.12: Transcrição sob a perspectiva do desenvolvedor do modelo	82
Tabela 5.13: Redução dos verbos sob a perspectiva do participante	83
Tabela 5.14: Redução dos verbos sob a perspectiva do gestor do desafio	84
Tabela 5.15: Redução dos verbos sob a perspectiva do desenvolvedor do modelo	84
Tabela 5.16: Análise geral sob a perspectiva do participante do desafio	85
Tabela 5.17: Análise geral sob a perspectiva do gestor do desafio.....	85
Tabela 5.18: Análise geral sob a perspectiva do desenvolvedor do modelo	86

LISTA DE EXEMPLOS

Exemplo 4.1: Base de conhecimento utilizada na extração dos fonemas relevantes	60
Exemplo 4.2: Conexões na rede neural de acordo com o número de entradas.....	62
Exemplo 4.3: Indicação do grau de homogeneidade em um conjunto de objetos....	63
Exemplo 4.4: Perguntas contidas na base de conhecimento	65
Exemplo 4.5: Codificação dos grupos de fonemas relevantes	69

SUMÁRIO

CAPÍTULO 1. INTRODUÇÃO	1
1.1 O SEBRAE.....	1
1.2 As Micro e Pequenas Empresas.....	3
1.3 O Fechamento de MPes.....	7
1.4 O que é o Desafio SEBRAE.....	10
1.5 Como o Desafio SEBRAE Funciona.....	10
1.6 O Serviço de Atendimento ao Cliente do Desafio SEBRAE.....	12
1.7 Organização da Dissertação	12
CAPÍTULO 2. ATENDIMENTO AO CLIENTE.....	14
CAPÍTULO 3. REDES NEURAS ARTIFICIAIS.....	22
3.1 Breve Histórico	22
3.2 Neurônio Biológico.....	25
3.3 Neurônio Artificial: Modelo MCP.....	27
3.4 Funções de Ativação	29
3.5 O que são Redes Neurais Artificiais?	31
3.6 Principais Arquiteturas das Redes Neurais Artificiais.....	33
3.7 Aprendizado das Redes Neurais	36
3.8 Redes Perceptron	38
3.9 Redes MultiLayer Perceptron (MLP).....	42
3.10 Exemplos de Aplicações e uso de Redes Neurais	46
CAPÍTULO 4. MÉTODOS E FERRAMENTAS DE PESQUISA	48
4.1 Obtenção dos Dados.....	48
4.2 Manipulação das Mensagens.....	49
4.3 Manipulação das Respostas	50
4.4 Preparação dos Dados.....	52
4.5 Especificação da Rede Neural.....	70
4.6 Ferramentas Utilizadas.....	71
CAPÍTULO 5. ANÁLISE DOS RESULTADOS	73
5.1 Melhor Resultado	74
5.2 Processo de Seleção do Melhor Modelo.....	75
5.3 Variações no processo de construção do modelo quantitativo.....	78
CAPÍTULO 6. CONCLUSÕES E TRABALHOS FUTUROS.....	87
6.1 Discussão.....	87
6.2 Conclusões.....	96
6.3 Sugestões para Trabalhos Futuros	97

CAPÍTULO 7. REFERÊNCIAS BIBLIOGRÁFICAS	101
ANEXO I.....	108
ANEXO II.....	113
ANEXO III.....	120

CAPÍTULO 1. INTRODUÇÃO

1.1 O SEBRAE

Apesar de ter passado a existir oficialmente em 1990, a história do Serviço Brasileiro de Apoio às Micro² e Pequenas³ Empresas (SEBRAE) começa bem antes disso, no início dos anos 70, com a criação do Centro Brasileiro de Apoio à Pequena e Média Empresa (Cebrae).

Na época, a administração nacionalista do General Emílio Garrastazu Médici, motivada pelo crescimento acelerado do produto interno bruto, entendeu que havia a necessidade de criação de um órgão voltado para realização de programas, projetos e atividades de apoio ao desenvolvimento de micro, pequenas e médias empresas, tais como: programas de formação de consultores para empresas de pequeno porte e atividades de suporte ao empresariado (divulgação de informações e orientação), nas áreas de tecnologia, crédito e mercado (SEBRAE, 2004E).

Quase vinte anos mais tarde, no Governo do Sr. Fernando Collor de Mello, através da Lei 8.029, de 12 de abril de 1990, o Cebrae foi desvinculado da Administração Pública Federal, tornando-se um serviço social autônomo (GOVERNO BRASILEIRO, 1990A).

No mesmo ano, o Decreto-Lei 99.570, determina que o Cebrae passará a denominar-se Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE) e dispõe sobre as responsabilidades e a organização deste órgão, que passa a se constituir numa sociedade civil sem fins lucrativos (GOVERNO BRASILEIRO, 1990B).

O fato do SEBRAE ser uma sociedade civil faz com que ele esteja impedido de distribuir os eventuais excedentes operacionais, brutos ou líquidos, do exercício de suas atividades, entre os seus sócios ou associados, conselheiros, diretores,

² Uma empresa é considerada uma micro-empresa, no comércio ou no setor de serviços, quando ela possui até 9 empregados. Na indústria, as micro-empresas são aquelas que possuem até 19 empregados (SEBRAE, 2004C).

³ Uma empresa é classificada como pequena empresa, no comércio ou no setor de serviços, quando ela possui de 10 a 49 empregados. Na indústria, as pequenas empresas são aquelas que possuem de 20 a 99 empregados (SEBRAE, 2004C).

empregados ou doadores. Todos estes excedentes, por força da Lei número 9.790, de 23 de março de 1999, têm que ser aplicados integralmente na consecução de seus objetivos (GOVERNO BRASILEIRO, 1999).

Embora seja uma sociedade civil, o SEBRAE recebe subvenções das empresas, que por força da Lei número 8.154, de 28 de dezembro de 1990, são obrigadas a destinarem 0,3% do total de sua folha de pagamento para o custeio da instituição. Esse dinheiro é recolhido aos cofres públicos, mais precisamente ao Instituto Nacional de Seguro Social (INSS), que em seguida repassa ao SEBRAE (SEBRAE, 2004D). Outras fontes de recursos da organização são as parcerias com entidades nacionais e internacionais e a cobrança dos serviços prestados aos seus clientes.

Composto por representantes da iniciativa privada e também do governo, o SEBRAE desempenha função de utilidade pública de caráter nacional, ou seja, apoiar e fomentar a criação, a expansão e a modernização das micro e pequenas empresas (MPEs), capacitando-as para melhor desempenhar o seu papel no desenvolvimento econômico e social do país, como elemento distribuidor de renda, formador de empreendedores e gerador de empregos (SEBRAE, 2004C).

Para atender os micro e pequenos empresários, oferecendo desde informações básicas da legislação em vigor até consultoria integrada das diversas funções de negócio, a estrutura do SEBRAE segue algumas diretrizes que estão diretamente relacionadas aos principais problemas enfrentados pelo segmento empresarial (SEBRAECE, 2004A), a saber:

- Estímulo à modernização das práticas de gestão empresarial;
- Promoção contínua do desenvolvimento tecnológico;
- Disponibilização de uma ampla variedade de cursos de capacitação profissional;
- Ampliação do grau de informação empresarial⁴;

⁴ A ampliação do grau de informação empresarial é feita através de programas de educação para empreendedores que desejam aperfeiçoar conhecimentos em áreas como finanças, marketing, recursos humanos e gestão para micro e pequenas empresas (SEBRAE, 2004H).

- Estímulo à cooperação entre as empresas;
- Criação de condições que levem ao tratamento jurídico diferenciado às empresas de pequeno porte e
- Desenvolvimento e implantação de programas de apoio à comercialização dos produtos e serviços de pequenos empreendimentos através de feiras⁵ e rodadas de negócio⁶.

Essas diretrizes foram criadas com o intuito de propiciar às micro e pequenas empresas um ambiente para realização de negócios com menor carga tributária, menos burocracia, facilidade no acesso ao crédito, à tecnologia e ao conhecimento. Neste sentido o SEBRAE promove centenas de projetos gerenciados pelas diversas Unidades de Negócios e de Gestão em todos os estados da federação. Dentre esses projetos destaca-se o “Desafio SEBRAE – Jogos de Empresas”, uma atividade que é objeto de estudo desta dissertação (SEBRAE, 2004B).

1.2 As Micro e Pequenas Empresas

Uma questão que freqüentemente aguça a curiosidade daqueles que tomam contato com o SEBRAE são as razões que levam uma organização de porte, que executa uma quantidade invejável de atividades de grande valor para a sociedade, a se dedicar ao segmento das micro e pequenas empresas.

Os micro e pequenos negócios, constituídos por empresas tais como: quitandas, mercearias, sapatarias, cabeleireiros, bazares, armarinhos, etc., vêm ganhando, ao longo destas últimas décadas, uma participação cada mais significativa nos setores de comércio e serviços, aumentando a geração de postos de trabalho e receita do país (IBGE, 2003).

⁵ As feiras são utilizadas como instrumentos para promoção do seu negócio. Oferecem a possibilidade imediata de apresentação do produto ou serviço, ao vivo e diretamente, aos potenciais compradores e interessados (SEBRAE, 2004G).

⁶ As rodadas de negócios são eventos virtuais (Internet) ou físicos (locais determinados), de curta duração, realizados através de reuniões de negócios entre empresários que demandam e ofertam produtos e serviços (SEBRAE, 2004F).

O Estudo Especial sobre Micro e Pequenas Empresas, elaborado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) em 2003, relata, de forma detalhada, o comportamento das MPEs no mercado brasileiro (IBGE, 2003). O estudo faz uma comparação do perfil das micro e pequenas empresas de comércio e serviços, em operação entre 1985 e 2001, provendo informações sobre sua estrutura de produção, participação nos respectivos mercados, produtividade, faturamento e remuneração da mão-de-obra de acordo com o porte das empresas.

Segundo o Estudo Especial sobre Micro e Pequenas Empresas (*op. cit.*), a receita bruta das MPEs em operação no país aumentou 12,4%, entre 1985 e 2001. Neste mesmo período, a receita bruta das médias e grandes empresas caiu 8,3%. Em 1985, a receita bruta das MPEs respondeu por 19,0% do Produto Interno Bruto (PIB) brasileiro, sendo que em 2001 elas responderam por 22,3%. Ver Figuras 1.1 e 1.2.

Receita das empresas de comércio e serviços,
segundo o porte da empresa - 1985/2001

Porte da empresa	Receita (1 000 000 000 R\$)		
	1985 (1)	1994 (1)	2001
Total	786,9	776,6	752,9
Micro e pequenas empresas	149,6	153,8	168,2
Médias e grandes empresas	637,3	622,8	584,7

Fontes: IBGE, Diretoria de Pesquisas, Censo Cadastrar 1994, Pesquisa Anual de Comércio 2001 e Pesquisa Anual de Serviços 2001; Censo de empresas, Rio de Janeiro: IBGE, 1991. Acima do título: Censos econômicos 1985.

(1) Valores atualizados com base na variação do IGP-DI.

Figura 1.1: Distribuição da receita das empresas, segundo o seu porte.




Figura 1.2: Participação das MPEs no Brasil, segundo a sua receita

Além disso, conforme pode ser observado nas Figuras 1.3 e 1.4, o número de pessoas ocupadas⁷ no segmento das MPEs mais que dobrou, passando de 3,4 milhões em 1985, 50,7% do total de pessoas ocupadas no setor de comércio e serviços, para 7,3 milhões em 2001, ou seja, 60,8%.

**Pessoal ocupado das empresas de comércio e serviços,
segundo o porte da empresa - 1985/2001**

Porte da empresa	Pessoal ocupado (1 000 pessoas)		
	1985	1994	2001
Total	6 774,4	8 119,0	11 995,3
Micro e pequenas empresas	3 436,3	3 816,3	7 290,7
Médias e grandes empresas	3 338,1	4 302,7	4 704,6

Fontes: IBGE, Diretoria de Pesquisas, Censo de Cadastro 1994, Pesquisa Anual de Comércio 2001 e Pesquisa Anual de Serviços 2001; Censo de empresas, Rio de Janeiro: IBGE, 1991. Acima do título: Censos econômicos 1985.

Figura 1.3: Distribuição do pessoal ocupado das empresas, segundo o seu porte

⁷ O termo pessoal ocupado engloba trabalhadores formais e informais, empregadores, militares, trabalhadores domésticos, autônomos e ocupados sem remuneração (NAJBERG, MORAES, IKEDA, 2002).

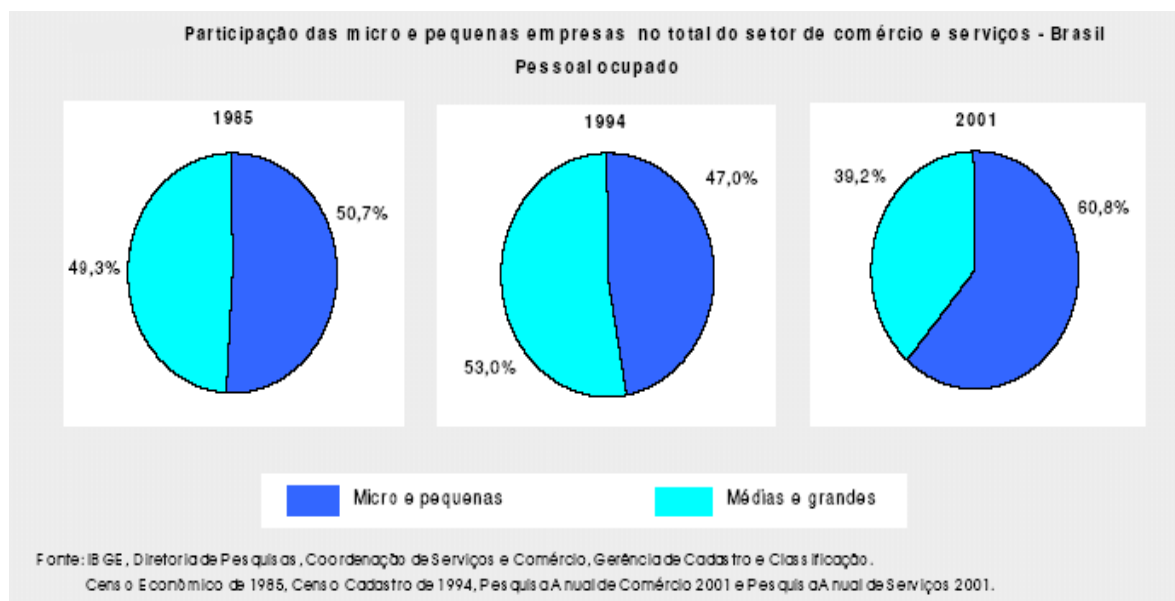


Figura 1.4: Participação das MPEs no Brasil, segundo o pessoal ocupado

A Figura 1.5 mostra que o número de MPEs do setor de comércio e serviços, que correspondia a 95,5% do total de empresas deste setor em 1985, atingiu 97,6% em 2001.




Figura 1.5: Participação das MPEs no Brasil

Segundo os dados disponíveis no *site* do SEBRAE na Internet, o número de MPEs tende a aumentar gradualmente nos próximos anos (SEBRAECE, 2004B). Este fato é consequência das seguintes razões:

- A tendência das empresas de maior porte de se transformarem em conglomerados de pequenas empresas, face ao tratamento diferenciado, simplificado e favorecido das empresas de pequeno porte, relativo aos impostos e às contribuições;
- A estabilidade do segmento de franquias⁸ que oferece ao franqueado a oportunidade de trabalhar com uma marca conhecida, em um negócio previamente testado e aprovado no mercado;
- O fortalecimento do processo de sub-contratação de cadeias de pequenos fornecedores, no qual as empresas deixam de fabricar os produtos e serviços que não constituem a sua atividade principal e passam a concentrar esforços e preocupações naquilo que é realmente importante;
- O espírito empreendedor e o desejo de independência e realização pessoal que motivam o executivo a estabelecer a sua própria empresa;
- A informatização e robotização das empresas que acaba por diminuir a necessidade de pessoal nos níveis técnicos e gerenciais e
- A terceirização de serviços públicos.

É importante se notar que o aumento da quantidade de MPEs em operação no país tende, não somente, a aumentar a participação destas empresas no PIB , mas também no número total de pessoas ocupadas no país.

1.3 O Fechamento de MPEs

A despeito do aumento da importância das MPEs para o desenvolvimento do país, deve ser observado que nem todos os indicadores deste setor são positivos. A grande maioria das MPEs, por exemplo, abre falência logo nos primeiros anos de vida, por dificuldades burocráticas na obtenção de crédito e até por falta de orientação e conhecimento dos futuros empresários (RYDLEWSKI, 2004).

⁸ Método de comercialização de produtos ou serviços no qual o franqueado obtém o direito de uso de uma marca e opera de acordo com um padrão de qualidade estabelecido pelo franqueador em troca do pagamento de um determinado valor.

De acordo com informações apresentadas no *site* do SEBRAE na Internet (SEBRAECE, 2004B), isso ocorre porque, em geral, a maioria desses empreendedores possui uma ou mais das seguintes características:

- Não possuem formação acadêmica;
- Aprenderam o ofício na prática como empregado;
- São oriundos da área de produção ou de vendas;
- Possuem aversão a controles e informações ;
- Decidem empiricamente;
- Limitam-se a acompanhar a concorrência;
- São individualistas;
- Têm visão e preocupação imediatistas;
- São descrentes de mudanças e aprendizagem;
- São desinformados;
- Não investem em auto desenvolvimento;
- Pertencem a nova classe de jovens empresários e
- São executivos oriundos de médias e grandes empresas e aposentados com experiência em grandes organizações.

Em conseqüência, falta a estes empreendedores:

- O conhecimento formal necessário para absorver rapidamente os conceitos, métodos e tecnologias que surgem a todo instante;
- A experiência de como administrar uma empresa no papel de dono;

- Uma compreensão mais profunda do papel e funcionamento das demais funções de negócio que fazem parte de uma organização, tais como: marketing, estratégia, recursos humanos, etc.;
- A habilidade para implementar os mecanismos de controle e informação necessários para a tomada de decisões racionais baseadas em fatos;
- A capacidade de efetuar a leitura correta do mercado para identificar, com precisão, as organizações, produtos e serviços com os quais está disputando a sua fatia de mercado;
- A vontade de aumentar a competitividade de seus negócios através da incorporação das opiniões e sugestões de sua equipe de trabalho;
- Uma visão estratégica de longo prazo de seu negócio;
- A disposição de acompanhar rapidamente as mudanças ocorridas no mercado;
- A compreensão da importância do autodesenvolvimento num mundo que se modifica e atualiza rapidamente;
- A maturidade necessária para administrar uma empresa, sendo vítimas, mais freqüentes, das armadilhas do mercado;
- A clareza de idéias que permite compreender que a administração de empresas de pequeno porte é necessariamente diferente da administração de empresas de médio e grande porte.

Diante do que foi demonstrado pelo estudo realizado pelo IBGE sobre as micro e pequenas empresas, o SEBRAE enxerga o segmento das MPEs como um meio promissor para o desenvolvimento do país. No entanto, ao notar o histórico dos futuros empresários e os problemas por eles enfrentados para abrir um novo negócio, o SEBRAE percebe a necessidade em direcionar e orientar esses futuros empreendedores, pois eles são a base para a formação das MPEs. Com este objetivo, essa sociedade civil sem fins lucrativos lança, anualmente, diversos programas e projetos para melhor atender os micro e pequenos empresários.

1.4 O que é o Desafio SEBRAE

A ampliação do acesso a programas de educação contínua⁹ e a disseminação da cultura empreendedora são as bases da política educacional estabelecida pelo SEBRAE. Esta política se propõe a assegurar às micro e pequenas empresas condições para uma evolução sustentável, através do convencimento e da qualificação de novos empreendedores (SCOCUGLIA, 2004).

As iniciativas sistemáticas que buscam a formação de atuais e futuros empreendedores são, hoje, estrategicamente importantes para a nossa sociedade. Uma dessas iniciativas é o programa “Desafio SEBRAE – Jogos de Empresas”, ou simplesmente Desafio SEBRAE, lançado pelo SEBRAE em parceria com o Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia da Universidade Federal do Rio de Janeiro (COPPE/UFRJ).

O Desafio SEBRAE, criado em 2000 no Brasil e implantado em 2003 na Argentina, Chile, Uruguai e Paraguai, é um jogo virtual que simula o dia-a-dia de uma empresa, elaborado especialmente para o público universitário (SEBRAE, 2004A). Seu objetivo é estimular os alunos de cursos superiores a tornarem-se empreendedores ensinando-os como elaborar estratégias de negócio e administrar empresas.

O SEBRAE busca, através de programas como o Desafio SEBRAE, estabelecer os alicerces de uma educação empreendedora popular que projetem as MPEs como um dos núcleos centrais responsáveis pelas mudanças sociais (SCOCUGLIA, 2004).

1.5 Como o Desafio SEBRAE Funciona

O Desafio SEBRAE é um jogo virtual onde os participantes são submetidos a uma grande variedade situações que ocorrem comumente no mundo dos negócios. Destacam-se aqui a compra de matéria-prima, formulação de preços de produtos, capacitação de funcionários, análise da concorrência e do volume de investimento

⁹ A educação contínua é caracterizada pelo conjunto das atividades educacionais que servem para manter, desenvolver ou aumentar o conhecimento.

em marketing, comunicação e pesquisa & desenvolvimento, entre outras (SANTOS, 2002).

Em quatro anos de existência, o Desafio SEBRAE ofereceu a mais de 110 mil universitários a oportunidade de experimentarem os sentimentos de realização, conquista e responsabilidade por que passam os dirigentes de empresas de todos os portes e tipos (BORGES, GONDIM, 2004). Entretanto, no Desafio SEBRAE, também estão presentes a frustração e o estresse que fazem parte da vida do empresário. Afinal, das milhares de equipes que se inscrevem anualmente, apenas uma sai vencedora.

Os participantes do Desafio SEBRAE podem ter qualquer idade, serem oriundos de qualquer classe social e morar em qualquer região do País. As únicas exigências reais são que estejam matriculados em Instituições de Ensino Superior (IES), credenciadas pelo Ministério da Educação (MEC), e que tenham acesso a um equipamento de computação que possa ser conectado a Internet (FERREIRA, 2004). Os estudantes interessados em participar da competição precisam formar equipes de três a cinco pessoas, que disputam para saber qual delas administra melhor uma empresa, utilizando a Internet como ferramenta de troca de informações (SEBRAE, 2004A).

O número de participantes do Desafio SEBRAE vem crescendo rapidamente, desde o ano 2000, quando foi realizado pela primeira vez. Em 2004, este número deve voltar a aumentar, substancialmente, com a entrada de participantes da Argentina, Chile, Uruguai e Paraguai. Na tabela 1.1, é apresentado o número de inscritos em cada ano de competição (BORGES, 2003). Tudo isso serve para demonstrar a relevância do Desafio SEBRAE na difusão e estímulo do empreendedorismo no contexto Sul-Americano.

Ano	Equipes Inscritas	Total de Universitários
2000	200	1.000
2001	3.200	15.000
2002	10.000	43.000
2003	11.000	54.700

Tabela 1.1: Estimativa do Número de Participantes do Desafio SEBRAE

1.6 O Serviço de Atendimento ao Cliente do Desafio SEBRAE

O Desafio SEBRAE disponibiliza aos participantes do jogo, desde o momento da sua inscrição, um sistema de *help desk*, destinado ao esclarecimento de dúvidas e ao recebimento de sugestões e reclamações (FERREIRA, 2004).

Na medida em que o número de participantes do desafio aumenta, aumenta também o número de questões que são apresentadas ao sistema de *help desk*. Um eventual congestionamento do serviço de *help desk* pode ter conseqüências desastrosas para os competidores, que pressionados pelo tempo podem se ver obrigados a tomarem decisões equivocadas por falta de orientação adequada. Em conseqüência, através dos anos, este serviço tem sido alvo de modificações constantes, com vistas a atender cada participante no menor tempo possível.

Este trabalho apresenta um sistema de resposta automática às perguntas destinadas ao *help desk* do Desafio SEBRAE. O sistema de resposta automática filtra, de forma inteligente, as diversas perguntas destinadas ao *help desk*, respondendo automaticamente aquelas cuja resposta se encontra armazenada no seu universo de conhecimento. As demais são encaminhadas aos operadores de plantão. O Sistema é baseado no uso de uma variedade de técnicas e métodos de inteligência computacional, com destaque para o uso de redes neurais artificiais.

1.7 Organização da Dissertação

Este trabalho encontra-se estruturado da seguinte forma.

O capítulo 2 apresenta as pesquisas mais relevantes realizadas na mesma linha de investigação deste estudo e discute como ele se conecta com tais pesquisas.

Uma revisão dos conceitos que orientam a construção e uso de Redes Neurais, necessária para um melhor entendimento deste trabalho, é realizada no capítulo 3.

No capítulo 4 são descritos os processos de obtenção, manipulação e preparação dos dados para construir o sistema.

Os resultados de nossa pesquisa são apresentados e discutidos no capítulo 5.

Finalmente, no capítulo 6 são destacadas as conclusões e as contribuições oferecidas por este estudo, assim como as sugestões para os futuros trabalhos de pesquisa relacionados a esta dissertação.

CAPÍTULO 2. ATENDIMENTO AO CLIENTE

De acordo com uma recente pesquisa desenvolvida pela empresa Internet World Stats (<http://www.internetworldstats.com/>), efetuada em 233 países, o número de usuários que acessam à Internet de casa cresceu 160% no período de 2000 a 2005, alcançando o total de 938 milhões de pessoas (INTERNET WORLD STATS, 2005), vide Figura 2.1.

WORLD INTERNET USAGE AND POPULATION STATISTICS						
World Regions	Population (2005 Est.)	Population % of World	Internet Usage, Latest Data	Usage Growth 2000-2005	% Population (Penetration)	World Users %
Africa	896,721,874	14.0 %	16,174,600	258.3 %	1.8 %	1.7 %
Asia	3,622,994,130	56.4 %	323,756,956	183.2 %	8.9 %	34.5 %
Europe	731,018,523	11.4 %	269,036,096	161.0 %	36.8 %	28.7 %
Middle East	260,814,179	4.1 %	21,770,700	311.9 %	8.3 %	2.3 %
North America	328,387,059	5.1 %	223,392,807	106.7 %	68.0 %	23.8 %
Latin America/Caribbean	546,723,509	8.5 %	68,130,804	277.1 %	12.5 %	7.3 %
Oceania / Australia	33,443,448	0.5 %	16,448,966	115.9 %	49.2 %	1.8 %
WORLD TOTAL	6,420,102,722	100.0 %	938,710,929	160.0 %	14.6 %	100.0 %

Figura 2.1: População e percentual de usuários da Internet no Mundo - 2005

A partir da completa liberação do uso da Internet com fins comerciais, no início dos anos 90 (OKIN, 2005), inúmeros produtos e serviços vêm sendo oferecidos através da rede, tais como: jornais, revistas, livros, CDs, eletrodomésticos, pacotes de viagem, passagens aéreas, automóveis, filmes, acesso a dicionários etc. (REPONEN, 2002).

Do ponto de vista do consumidor, a rede mundial de computadores pode trazer inúmeras vantagens, a saber:

- A conveniência de não necessitar sair de casa para adquirir um bem ou serviço a qualquer hora do dia, evitando possíveis inconvenientes como trânsitos, filas, etc;

- A comparação entre produtos tornou-se mais fácil e rápida, já que o consumidor tem nas mãos mais informações para fazer uma escolha adequada às suas necessidades.

Espera-se para os próximos anos um grande crescimento do número de consumidores e, conseqüentemente, um aumento substancial no número de empresas que vendem produtos pela Internet, na variedade e quantidade de produtos comercializados em *websites*; e no volume de transações comerciais realizadas na rede (ROSSI, MOTTA, 2003).

Uma vez que o consumidor tenha considerado a possibilidade de comparar um produto na Internet, é natural que ele queira tirar suas dúvidas sobre o produto em questão em tempo real via Internet.

As solicitações são dos mais diversos tipos, variando desde o envio de sugestões e reclamações, como também a requisição de informações envolvendo suporte técnico, aquisição de novos produtos e serviços, etc (READ, FLEISCHER, 2002).

No entanto, à medida que ocorre o aumento do número de consumidores na Internet ocorre também um crescimento no volume de solicitações de informações encaminhadas às empresas que fornecem os produtos e serviços que os consumidores almejam obter.

Para contornar o problema de excesso de solicitação de informações e manter um bom nível de relacionamento com seus clientes, as empresas têm recorrido a estratégias envolvendo a expansão ou mesmo a inovação dos serviços de atendimento ao cliente (SAC) (STERNE, 2000), a saber:

- Telefone – o cliente liga para a central de atendimento da empresa para tirar a sua dúvida diretamente com um operador. Por exemplo: a central de atendimento do projeto de educação Escolha24Horas (<http://www.escola24horas.com.br/>) que funciona das 8:00h às 20:00h;
- Voz sobre IP (Voice over Internet Protocol - VoIP) – cliente pode ser comunicar por voz com os operadores de *telemarketing* através de um

sistema de voz sobre IP. Por exemplo: a central de atendimento da empresa de consultoria em informática 2S (<http://www.2s.com.br>) que funciona de segunda a sexta das 9:00h às 18:00h;

- *Chat* – o cliente se comunica, em tempo real, através de texto com os operadores de *telemarketing* da empresa. Por exemplo: o sistema de atendimento *chat online* da empresa de banda larga Velox (<http://www.velox.com.br>) que funciona de segunda a sexta das 8:00 às 19:30h e sábado das 8:00 às 18:00h;
- Mecanismos de busca – semelhante ao mecanismo de busca da ferramenta Google (<http://www.google.com>), neste tipo de sistema de atendimento, o cliente fornece uma lista de palavras, como forma de consulta, e recebe uma lista de documentos que contém estas palavras. Por exemplo: o sistema de atendimento do Banco do Brasil (<http://www.bb.com.br>);
- FAQ (*Frequently Asked Questions*) – a empresa disponibiliza para o cliente uma lista de dúvidas freqüentes. Por exemplo: a rede de supermercados Pão de Açúcar (<http://www.paodeacucar.com.br>);
- *E-mail* – o cliente para tirar as suas dúvidas, deve enviar um e-mail à empresa fornecedora do produto ou serviço. Por exemplo: o sistema de atendimento da operadora de telefonia celular Claro (<http://www.claro.com.br>).

Analisando os serviços de atendimento encontrados no mercado, verificamos que os serviços como telefone, voz por IP e *chat* utilizam um operador de *telemarketing* para interagir diretamente com o cliente, em tempo real.

Embora muitas vezes esta seja uma solução onde o cliente possa se sentir mais a vontade para se comunicar com a empresa fornecedora de produtos ou serviços, esses sistemas de atendimento tendem a funcionar apenas no horário de funcionamento da empresa prestadora de serviço. Como no caso do atendimento via *chat* da empresa de banda larga Velox que funciona apenas de segunda a sexta das 8:00 às 19:30h e sábado das 8:00 às 18:00h.

Em adição, este tipo de solução pode afetar financeiramente o gestor da empresa, uma vez que para manter um serviço de qualidade ao consumidor é necessário contratar um razoável número de operadores de *telemarketing*.

Já os tipos de sistemas de atendimento que utilizam os mecanismos de busca, embora sejam ferramentas eficientes capazes de responder pesquisas prontamente, a uma taxa de centenas ou milhares de consultas por segundo; é importante notarmos que ela nem sempre é a solução ideal pelo fato de não disponibilizar uma resposta exata e sim uma variedade de documentos muitas vezes de pouca relevância.

Neste sentido, o usuário precisa possuir tempo, ou mesmo estar disposto a pesquisar a informação que necessita nos documentos retornados.

Por exemplo, suponha que um cliente da H.Stern acabou de adquirir uma jóia caríssima e deseja tirar uma dúvida sobre este produto ou mesmo sobre o processo de compra em um sistema de resposta automática semelhante ao Google.

No entanto, ao invés deste cliente receber uma resposta precisa e personalizada, o sistema fornecerá uma lista de documentos que contenham as palavras que o cliente utilizou para descrever o seu problema. Esse acontecimento provavelmente é inadmissível para um cliente H.Stern sendo, portanto, um fator de dissonância junto ao cliente.

Além disso, é interessante considerarmos que nem sempre a resposta a uma dúvida conterá os termos utilizados na pesquisa, limitando assim os resultados obtidos.

O mesmo fator de dissonância que ocorre nos SAC's que são desenvolvidos baseados nos mecanismos de busca acontece também com os sistemas de atendimento que disponibilizam aos clientes apenas a lista das perguntas mais freqüentes, ou seja, os FAQ's.

Por exemplo, em uma empresa nuclear, o operador possivelmente não terá tempo para procurar a informação que necessita dentre as listadas no FAQ, principalmente, em situações de emergência.

Em relação aos sistemas de atendimento que utiliza o *e-mail* como forma de comunicação com o cliente, é comum encontramos soluções onde o operador de *telemarketing* é encarregado de responder estes *e-mails*.

Embora, esta solução não possua o mesmo fator de dissonância existente nos mecanismos de busca e FAQ's, uma vez que é fornecida uma resposta ao consumidor e não uma lista de documentos, esta resposta não é enviada em tempo real.

Em adição, por ser necessário um operador para responder as mensagens enviadas pelos clientes, esta solução está associada a um custo extra para o gestor do negócio.

Portanto, podemos verificar que em geral, apesar da Internet funcionar 24 x 7 x 365, os serviços de atendimento *on-line* tendem a funcionar apenas durante o horário de funcionamento da empresa fornecedora de um produto ou serviço (de 8h às 18h).

Neste sentido, a empresa pode facilmente, se deparar com uma situação em que seja incapaz de responder, em tempo hábil, a custos competitivos, todas as necessidades de informações de seus clientes.

Uma alternativa para este tipo de problema é a tecnologia de sistemas computadorizados de resposta que tem se apresentado como uma solução atraente tanto para aumentar a velocidade e capacidade de atendimento das solicitações de informações de clientes e *prospects*¹⁰, quanto para reduzir os custos de serviços de atendimento ao cliente (SACs).

Esta tecnologia permite o desenvolvimento de sistemas capazes de detectar a existência de solicitações de informações, identificar corretamente o seu conteúdo e prover, automaticamente, as respostas adequadas a cada solicitação (CHAMPION, 2003).

¹⁰ Clientes em potencial.

Um dos principais benefícios propiciados pela existência da Internet é a possibilidade dos consumidores procurarem, de acordo com sua conveniência, pela melhor oferta dos produtos e serviços que desejam adquirir.

Sistemas de resposta automática via *web* favorecem a existência de mecanismos de resposta a questões levantadas naturalmente pelo consumidor durante ou após o processo de compra, que estão disponíveis 24 horas por dia, todos os dias da semana nos 365 dias do ano.

Na literatura, encontramos sistemas de resposta automática desenvolvidos com base nas mais diversas tecnologias, tais como: processamento de linguagem natural, regras de inferência, ontologias, *machine learning*, etc (BILOTTI, 2004).

Para extrair as informações contidas em um texto escrito em linguagem natural, muitas soluções de sistemas de resposta automática realizam, sobre o texto em questão, processamentos, utilizando análise morfológica¹¹, léxica¹², sintática¹³ e semântica¹⁴ (DALE *et. al.*, 2000).

O processamento de linguagem natural é freqüentemente aplicado em conjunto com outras técnicas, tal como a utilização de regras de inferência, para estabelecer a resposta a uma determinada questão (SIMMONS, 1970).

Um exemplo desta combinação é o sistema de resposta automática Quarc (*Q*Uestion *A*nswering for *R*eadin*G* *C*omprehesion). Construído por Riloff e Thelen (2000), o Quarc é um sistema baseado em regras construídas manualmente, a partir de experimentos com 55 testes de compreensão de leitura.

O Quarc, desenvolvido para auxiliar a compreensão de textos em inglês, baseia-se em questões do tipo “*WH*” (*Who, What, When, Where, Why*). Por exemplo: “*When will the game begin?*” (“Quando o jogo começará?”). Em adição, como cada

¹¹ Análise morfológica é o ato de estudar diversas palavras na frase, separadamente, visando sua classe gramatical (artigo, preposição, adjetivo, etc.)

¹² Análise léxica é o processo de analisar a entrada de caracteres separando-os em seqüências chamadas tokens

¹³ Análise sintática trata da disposição dos itens lexicais (tokens) em uma sentença e das relações existentes entre eles.

¹⁴ Análise semântica trabalha com o mapeamento das sentenças para uma representação de seu significado.

tipo de questão “WH” está relacionado com diferentes tipos de resposta, foi definido um grupo de regras separadas para cada tipo de questão.

Neste sentido, uma vez fornecidos uma questão e um texto, o Quarc efetua um *parse* sobre esta questão e todas as sentenças existentes no texto e realiza análises morfológicas (artigo, adjetivo, preposição, etc.) e semânticas das palavras extraídas tanto do texto quanto da questão.

Posteriormente, regras de inferência léxicas e semânticas para pesquisar um indício de que a sentença existente no texto interpretado contém a resposta para a questão levantada, ou seja, as regras de inferência são aplicadas a cada sentença no texto para descobrir aquela que melhor responde a pergunta em questão.

Uma outra tecnologia desenvolvida recentemente nos sistemas de resposta automática é a ontologia. Muitas vezes, ontologias para domínios formais são utilizadas como fontes de conhecimento para a extração de informação, permitindo aos sistemas desempenhar inferências taxonômicas simples e resolver ambigüidades na classificação das palavras.

Como no sistema de resposta automática AQUA (*Ontology – based Question Answering System*) desenvolvido por Vargas-Vera e Motta, em 2004. AQUA combina técnicas de processamento de linguagem natural, ontologia, lógica e busca de informações em um ambiente uniforme.

O AQUA utiliza as ontologias na transcrição das perguntas em sentenças lógicas. Essa transcrição é feita através da descoberta das similaridades entre as relações existentes na pergunta em questão e as relações existentes nas estruturas ontológicas (VARGAS-VERA, MOTTA, 2004).

Uma vez que estas similaridades sejam detectadas, é feita a representação lógica da pergunta em questão. Esta forma lógica será aplicada sobre a base de conhecimento a fim de obter uma resposta adequada.

Em geral, os sistemas de resposta automática incluem um componente que classifica as perguntas escritas em linguagem natural, em relação ao tipo de resposta esperada (FEIGUINA, KEGL, 2005). Por exemplo, o sistema ILQUA que utiliza categorias como pessoa, localização, data, quantidade e organização para

identificar a resposta a qual uma determinada pergunta está associada (WU *et.al.*, 2004).

Na maioria destes sistemas, este trabalho é feito utilizando regras léxico-sintáticas construídas manualmente, como por exemplo, a aplicação Quarc descrita anteriormente.

No entanto, a construção destas regras exige um grande esforço manual e um especialista com experiência suficiente para identificar as regras existentes no domínio da aplicação.

Uma alternativa para este problema é o uso de algoritmos de aprendizado para realizar esta classificação, a fim de diminuir o esforço manual empregado e aumentar a portabilidade da aplicação.

Em adição, a utilização da técnica de aprendizado de máquina como base para o desenvolvimento de sistemas de resposta automática possui grandes vantagens por ser adaptável, robusta e flexível, pelo fato de não ser necessário um especialista construir manualmente um grupo de regras e continuamente melhorar e adaptar este grupo de regras (NG *et.al.*, 2000).

Em nosso trabalho, apresentamos uma solução de sistema de resposta automática baseada no aprendizado de máquina, mais especificamente, baseada na tecnologia de redes neurais.

O objetivo de utilizar a tecnologia de redes neurais, como base de nosso sistema de resposta automática, é fornecer corretamente uma resposta à mensagem enviada pelo cliente através de um sistema simples de resposta automática. Além de comprovar que através deste sistema é possível obter um alto grau de precisão nas respostas enviadas.

Em outras palavras, mostrar que é possível construir um sistema simples de resposta automática com uma alta taxa de acerto nas respostas enviadas, sem ser necessário realizar um processo de inferência manual, ou mesmo uma análise profunda sobre a linguagem natural utilizada na escrita das mensagens.

CAPÍTULO 3. REDES NEURAIS ARTIFICIAIS

O cérebro é tido como um processador altamente complexo e poderoso que realiza várias tarefas de maneira paralela. Para isso, ele conta com uma rede multidimensional de 100 bilhões de neurônios que realizam, em conjunto, o processamento necessário (BRAGA, CARVALHO, LUDERMIR, 1998).

Neste contexto, surgem as redes neurais artificiais (RNAs), inspiradas na própria natureza das redes de neurônios. A idéia é realizar o processamento de informações, tendo como princípio a organização de neurônios do cérebro. Como o cérebro humano é capaz de aprender e tomar decisões baseadas na aprendizagem, as redes neurais artificiais devem possuir as mesmas habilidades. Assim, uma rede neural artificial pode ser interpretada como um paradigma de processamento capaz de armazenar conhecimento baseado em experiência e aprendizagem, disponibilizando o conhecimento adquirido para a aplicação em questões correlatas (BRAGA, CARVALHO, LUDERMIR, 1998).

Em termos mais formais, as redes neurais artificiais designam uma família de métodos matemáticos para solução de problemas complexos cujo funcionamento é baseado na forma como o cérebro humano processa informações.

3.1 Breve Histórico

O desenvolvimento das redes neurais artificiais tem suas origens nos estudos neurobiológicos que ocorreram a partir do início da década de 40, quando o psiquiatra e neuro-anatomista Warren McCulloch, em conjunto com o matemático Walter Pitts, desenvolveu um modelo artificial do neurônio biológico chamado MCP (MCCULLOCH, PITTS *apud* BRAGA, CARVALHO, LUDERMIR, 1998).

O modelo MCP, ou modelo de McCulloch-Pitts, implementa uma função de soma baseada em duas variáveis onde os pesos das conexões entre os nodos correspondem às sinapses inibidoras e excitadoras de um neurônio verdadeiro (ASSEF, 1999). Portanto, o trabalho de McCulloch e Pitts se concentra em descrever um modelo artificial de um neurônio e apresentar as suas capacidades computacionais ao invés de tentar implementar técnicas de aprendizado.

O aprendizado por redes biológicas e artificiais veio a ser objeto de estudo somente alguns anos mais tarde, através do trabalho do biólogo e psicólogo Donald Hebb (PAULA, 2000). Hebb revelou como o aprendizado de redes neurais é obtido através da variação dos pesos de entrada dos nodos e propôs uma teoria para explicar o aprendizado em nodos biológicos baseada no reforço das ligações sinápticas entre nodos excitados (HEBB *apud* BRAGA, CARVALHO, LUDERMIR, 1998).

Em seu trabalho, Hebb defende que o peso de uma conexão sináptica deve ser fortalecido, caso dois neurônios, em lados distintos da sinapse, sejam ativados sincronamente. Entretanto, se os neurônios forem ativados assincronamente, a sinapse deve ser enfraquecida ou mesmo eliminada. Em outras palavras, se o neurônio pré-sináptico possuir grande influência na ativação do neurônio pós-sináptico, a conexão entre eles deve ser intensificada (ASSEF, 1999). Esse procedimento de ajuste de pesos, freqüentemente chamado de regra de Hebb, é considerado o marco inicial para os algoritmos de treinamento das RNAs (BRAGA, CARVALHO, LUDERMIR, 1998).

Posteriormente, em 1958, o psicólogo Frank Rosenblatt inventou uma classe de redes artificiais chamada perceptron, que é baseada no modelo de neurônio de McCulloch e Pitts (ZURADA, 1995).

Rosenblatt provou com o seu novo modelo que, se as RNAs com nodos MCP fossem acrescidas de sinapses ajustáveis, elas poderiam ser treinadas para classificar certos tipos de padrões. Juntamente com o perceptron, Rosenblatt propôs um algoritmo para treinar a rede com o objetivo de executar determinadas funções. A saída da rede é inicialmente aleatória, mas através do ajuste gradual dos pesos, o perceptron é treinado para fornecer saídas de acordo com os dados do conjunto de treinamento. Como será visto na seção 3.8, o perceptron é somente capaz de classificar grupos que sejam linearmente separáveis (BRAGA, CARVALHO, LUDERMIR, 1998).

Praticamente na mesma época em que surgiu o perceptron, os pesquisadores Bernard Widrow e Marcian Hoff propuseram um modelo matemático chamado ADALINE (*ADaptive LINear Element*). Enquanto o perceptron foi apresentado por

Rosenblatt em uma revista de psicologia, o ADALINE foi submetido em uma conferência do IRE (*Institute of Radio Eletronics*) atual IEEE (*Institute of Electrical and Eletronic Engineers*).

O enfoque inicial do ADALINE era na área de processamento de sinais, mas posteriormente foi utilizado na área de Redes Neurais Artificiais, sendo que seu nome passou a significar *ADaptive Linear NEuron* (WIDROW, HOFF *apud* BRAGA, CARVALHO, LUDERMIR, 1998). A diferença do modelo ADALINE para os perceptrons reside na forma de treinamento, que é baseada na minimização do erro médio quadrático (ASSEF, 1999). No entanto, ambos chegam a uma mesma fórmula de ajuste dos pesos sinápticos utilizado no treinamento da rede.

Contudo, em 1969, o entusiasmo pelas redes neurais foi abafado pela publicação do livro “Perceptrons: Uma Introdução para a Geometria Computacional¹⁵”, por Marvin Minsk e Seymour Papert, onde os autores analisam as limitações das redes perceptrons (MINSK, PAPERT *apud* BRAGA, CARVALHO, LUDERMIR, 1998). No livro, eles mostram que existe uma interessante classe de problemas que a rede perceptron não resolve, ou seja, casos que não são linearmente separáveis. Esta publicação teve uma enorme repercussão no meio acadêmico, desencorajando os investimentos em pesquisas relacionadas às redes neurais. Em conseqüência, as redes neurais caíram praticamente no esquecimento até a década de 80 (ASSEF, 1999).

Apesar do adormecimento das pesquisas em RNAs, nos anos 70, um importante trabalho sobre mapas auto-organizados foi desenvolvido por Teuvo Kohonen, que propôs um modelo de rede neural que não exigia, durante a fase de aprendizado, uma constante comparação de valores estimados com valores de saída previamente conhecidos, em outras palavras, o modelo realizava um treinamento não supervisionado (KOHONEN *apud* BRAGA, CARVALHO, LUDERMIR, 1998).

Em 1976, Steven Grossberg estabeleceu um novo princípio de mapas auto-organizados baseado na teoria de ressonância adaptativa. No modelo proposto, as RNAs aprendem de forma contínua sem perder os conhecimentos previamente

¹⁵ Texto traduzido pelo autor.

adquiridos. Essas redes chamam-se *ART* (Adaptative Ressonance Theory) (GROSSBERG *apud* BAXTER, 1991).

Foi somente em 1982, que as redes neurais artificiais tiveram parte do seu prestígio recuperado através das publicações do biofísico John Hopfield que chamou a atenção para as propriedades associativas das RNAs (HOPFIELD *apud* SONDAK, SONDAK, 1989). A grande contribuição de Hopfield foi apresentar a relação entre redes recorrentes auto-associativas e sistemas físicos, conseqüentemente, abrindo espaço para a utilização de teorias correntes da Física para estudar tais modelos (BRAGA, CARVALHO, LUDERMIR, 1998).

Em adição, o prestígio das redes neurais foi, em 1986, retomado com força total através da apresentação, por Rumelhart, Hinton e Williams, do algoritmo de treinamento *back-propagation*. Este algoritmo amplia o potencial do perceptron de modo a permitir a superação das limitações do modelo primitivo (RUMELHART, HINTON, WILLIAMS *apud* SONDAK, SONDAK, 1989).

Embora a popularização do *back-propagation* tenha surgido a partir de 1986, ele foi, na verdade, concebido muito antes, com diferentes objetivos, por diferentes pesquisadores como: Werbos em 1974 (WERBOS *apud* SARKAR, 1995), Parker em 1985 (PARKER *apud* SARKAR, 1995) e Le Cun em 1986 (CUN *apud* SARKAR, 1995).

Este algoritmo possibilita a utilização de redes do tipo perceptron com múltiplas camadas, também conhecidas como *Multilayer Perceptron*, ou simplesmente MLP, baseando-se no método do gradiente decrescente, como será mostrado na seção 3.9 (KROSE, SMAGT, 1996).

Nesta seção, foram apresentados alguns modelos de redes neurais, escolhidos por serem os precursores nesta área de estudo e, conseqüentemente, por servirem de base para a definição dos paradigmas das atuais RNAs.

3.2 Neurônio Biológico

O neurônio biológico é uma célula que pode ser dividida em três componentes, cada um com funções específicas, porém complementares:

- um corpo celular ou soma,
- um axônio tubular e
- várias ramificações arbóreas, conhecidas como dendritos.

Na Figura 3.1 estão ilustrados, de forma simplificada, os componentes do neurônio.




Figura 3.1: Componentes de um neurônio biológico

O corpo celular integra os estímulos, ou impulsos nervosos, que chegam pelos dendritos e são oriundos de outros neurônios (MCCULLOCH, 1952). A funcionalidade provida pelos dendritos é receber informações através dos impulsos nervosos e conduzi-las até o corpo celular. Neste local, a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros neurônios, também conhecidos como nodos, passando pelo axônio do neurônio origem e atingindo os dendritos dos neurônios seguintes (FRENGER, 1991).

A conexão entre o axônio de um neurônio e o dendrito de outro é denominada sinapse. As sinapses podem ser de dois tipos: excitatórias ou inibitórias. É através das sinapses que os nodos se unem funcionalmente, formando as redes neurais (FU, 1999). As sinapses trabalham como válvulas, sendo capazes de controlar a transmissão de impulsos, ou seja, o fluxo da informação entre os neurônios na rede

neural. O efeito das sinapses é variável e é esta variação que possibilita ao neurônio capacidade de aprendizado (BRAGA, CARVALHO, LUDERMIR, 1998).

Nas sinapses, pode-se observar a distinção entre o neurônio que envia os estímulos elétricos e o que recebe, ou seja, o neurônio subsequente. Neste sentido, o neurônio que se encontra antes da comunicação é caracterizado como pré-sináptico e o que fica depois é o pós-sináptico (PAULA, 2000).

Os sinais oriundos dos nodos pré-sinápticos são passados para o corpo do neurônio, onde são comparados com outros sinais recebidos por ele. Quando um nível de excitação é atingido, a célula "dispara", ou seja, transmite um sinal através de seu axônio para as células seguintes (nodos pós-sinápticos). É importante lembrar que os ramos de um só axônio podem estabelecer sinapses com outros neurônios. Este sistema simples é responsável pela maioria das funções realizadas pelo nosso cérebro (RUMELHART, WIDROW, LEHR, 1994).

A seção seguinte mostra como algumas das propriedades dos neurônios biológicos tornaram-se a base para a formação das RNAs, a saber:

- O elemento processador recebe vários sinais.
- Os sinais são ponderados pela intensidade da sinapse receptora.
- O elemento processador integra as entradas ponderadas.
- Sob certas circunstâncias, o neurônio transmite uma determinada saída.
- A saída de um neurônio pode conectar-se a entrada de vários outros neurônios.

3.3 Neurônio Artificial: Modelo MCP

O modelo de neurônio criado por McCulloch e Pitts (*op. cit.*), em 1943, foi a base para o projeto das redes neurais artificiais. Embora o modelo seja uma simplificação do que se sabia a respeito do neurônio biológico na época, ao longo do tempo ele deu origem a ferramentas poderosas para solução dos mais variados tipos de problemas (ASSEF, 1999).

Com vistas a desenvolver um neurônio artificial com funcionalidades análogas ao neurônio biológico, McCulloch e Pitts criaram um modelo matemático chamado MCP. Este modelo utiliza um conjunto de entradas x_1, x_2, \dots, x_n , que representam os dendritos, e apenas uma saída y , que representa o axônio. Para simular o comportamento das sinapses, as entradas do neurônio possuem pesos acoplados w_1, w_2, \dots, w_n , cujos valores podem ser positivos ou negativos, dependendo se as sinapses correspondentes são excitatórias ou inibitórias, respectivamente.

O efeito de uma sinapse particular i , no nodo pós-sináptico, é dado pelo produto $x_i w_i$. Neste sentido, os pesos determinam o grau de intensidade dos sinais de disparo recebidos por um neurônio através de uma conexão (PAULA, 2000). Uma ilustração do neurônio artificial é apresentada na Figura 3.2.




Figura 3.2: Neurônio de McCulloch e Pitts

No modelo MCP, a ativação do neurônio é obtida através da aplicação de uma "função de ativação", f , que ativa sua saída ou não, dependendo da soma ponderada das suas entradas. Em outras palavras, o parâmetro da função de ativação de um neurônio é a soma do produto das entradas com seus respectivos pesos. Quando este valor calculado ultrapassa um valor pré-determinado, θ , conhecido como limiar de excitação ou *threshold*, o neurônio transmite um sinal, simulando uma sinapse excitatória. Caso contrário, o sinal não será transmitido, correspondendo a uma sinapse inibitória. Portanto, o neurônio MCP tem sua saída ativa quando:

$$\sum_{i=1}^n x_i w_i \geq \theta$$

onde n é o número de entradas do neurônio, w_i é o peso associado à entrada x_i , e θ é o limiar de excitação do neurônio (NOTARI, 1997). Por outro lado, a saída do neurônio fica inativa quando:

$$\sum_{i=1}^n x_i \cdot w_i < \theta$$

A partir do modelo proposto por McCulloch e Pitts foram derivados vários outros modelos de redes neurais com diferentes funções de ativação. Na próxima seção, serão descritos alguns dos tipos básicos de funções de ativação.

3.4 Funções de Ativação

Conforme foi apresentado anteriormente, a operação básica de um neurônio artificial envolve a soma ponderada de sinais de entrada que são avaliados por uma função de ativação. De forma geral, a saída, y , de um neurônio é dada por:

$$y = f(\text{net}), \text{ onde } \text{net} = \sum_{i=1}^n x_i \cdot w_i \quad ,$$

onde f é a função de ativação e net é a soma dos produtos entre a entrada x_i e o peso w_i . Na literatura, é possível encontrar diversos tipos de funções de ativação, tais como: linear, rampa, degrau e sigmóide, entre outras (BRAGA, CARVALHO, LUDERMIR, 1998).

A função de ativação do tipo linear, ilustrada na Figura 3.3, é definida pela equação:

$$y = \alpha \times \text{net},$$

onde α é um número real.

No entanto, a função linear pode ser restringida para gerar apenas valores constantes, em uma determinada faixa de valores $[-\theta, +\theta]$. Nesta situação, a função

linear se transforma em uma função de ativação do tipo rampa definida pela equação:

$$y = \begin{cases} -\theta, & \text{se } \text{net} < -\theta \\ \text{net}, & \text{se } -\theta \leq \text{net} \leq +\theta \\ +\theta, & \text{se } \text{net} > +\theta \end{cases}$$

onde o valor máximo e mínimo da saída são $+\theta$ e $-\theta$, respectivamente. Esta função pode ser observada graficamente na Figura 3.4.




Figura 3.3: Função Linear




Figura 3.4: Função Rampa

A função de ativação do tipo degrau (*step*), ilustrada na Figura 3.5, produz uma saída $-\theta$ para os valores de *net* menores que zero, caso contrário a função retorna o valor $+\theta$. Conforme podemos observar pela equação a seguir.

$$y = -\theta, \text{ se } \text{net} \leq 0 \quad \text{e} \quad y = +\theta, \text{ se } \text{net} > 0$$

Finalmente, a função de ativação do tipo sigmóide, cujo gráfico tem a forma de S, como pode ser observado na Figura 3.6. A função sigmóide, também conhecida como *S-shape*, pode ser definida como uma função estritamente crescente que exibe o balanceamento adequado entre o comportamento linear e não-linear. Um exemplo de função sigmóide é a função logística representada pela equação:

$$y = \frac{1}{1 + e^{-\text{net}/T}},$$

onde T determina a suavidade da curva.




Figura 3.5: Função Degrau




Figura 3.6: Função Sigmóide

3.5 O que são Redes Neurais Artificiais?

Segundo Haykin (2001), uma rede neural artificial é um modelo de processamento paralelo distribuído formado por unidades de processamento simples (neurônios), que possuem a capacidade natural para armazenar conhecimento experimental e torná-lo disponível para uso futuro. Ela é projetada para emular a forma como o cérebro humano se comporta ao realizar uma tarefa particular, assemelhando-se a ele de duas formas:

- O conhecimento é adquirido pela rede através de um processo de aprendizagem e
- As intensidades das conexões entre os neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Até o início da década de 80, praticamente todas as aplicações que envolviam processamento de dados e informações adotavam a abordagem da “computação programada”, que consiste no desenvolvimento de um algoritmo para a resolução de um problema, o qual é codificado em uma linguagem de programação (BIGUS, 1996).

Em meados da década de 80 surgiu uma abordagem revolucionária para o processamento de dados e informações, conhecida como redes neurais artificiais¹⁶. Diferente da abordagem da “computação programada”, as redes neurais artificiais não necessitam definir algoritmos ou conjuntos de regras para analisar os dados, o

¹⁶ Como vimos na seção 3.1, as RNAs tiveram o início de suas pesquisas na década de 40, porém apenas em meados da década de 80, foi que ela se popularizou. Por isso o termo “abordagem revolucionária”.

que freqüentemente reduz de forma significativa o trabalho de desenvolvimento de programas para um dado problema (BIGUS, 1996).

Em geral, a rede neural artificial passa por um processo de aprendizado, a partir de casos conhecidos, adquirindo o conhecimento necessário para realizar adequadamente o processamento desejado dos dados fornecidos. Em outras palavras, as RNAs possuem a capacidade de extrair, automaticamente, as regras básicas desejadas a partir da análise dos dados, aprendendo por experiência e dispensando qualquer modelo adicional de captura de conhecimento (TRIPPI, TURBAN, 1996).

O processo de aprendizagem existente nas RNAs é uma das características definidas na tentativa de simular a desenvoltura com que o cérebro humano desempenha suas funções. Além da habilidade de aprender, as RNAs possuem outras características que tornam o seu comportamento semelhante ao de uma rede neural biológica, a saber (HAYKIN, 2001):

- Habilidade de tratar sistemas não-lineares - a não linearidade viabiliza a geração de mapeamentos complexos entre as variáveis de entradas e saída da rede, que normalmente podem ser achados no mundo real.
- Paralelismo – a seqüência de processamento das RNAs é realizada de forma paralela, como se cada neurônio na rede possuísse o seu próprio processador, aumentando a velocidade com que as informações são processadas.
- Tolerância a falhas - a informação se encontra distribuída por todos os elementos da rede, logo mesmo que parte da rede seja destruída, a informação contida nesta parte ainda estará presente no restante da rede, e poderá ser recuperada. Adicionalmente, por causa da capacidade de processamento paralelo das RNAs, a falha de alguns neurônios tendem a não causar efeitos significativos na performance geral do sistema.
- Tolerância a ruídos e generalização - a rede é capaz de generalizar o seu conhecimento a partir de exemplos anteriores, extraindo informações apresentadas implicitamente através de exemplos. Neste sentido, ela se

torna apta a lidar com ruídos e distorções, respondendo corretamente a novos padrões de informações.

Conforme podemos observar, a rede neural artificial possui características, tais como: aprender através de exemplos, capacidade de generalização e tolerância a falhas, que a tornam uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos.

Um fator essencial para se determinar que tipos de problemas podem ser resolvidos por uma rede neural é a sua arquitetura básica, isto é, a forma com que os neurônios estão conectados, o número de camadas da rede e o número de neurônios em cada camada. Na próxima seção, é realizada uma breve descrição das principais arquiteturas de redes neurais artificiais.

3.6 Principais Arquiteturas das Redes Neurais Artificiais

Os conjuntos de neurônios artificiais quando organizados e conectados de formas diferentes podem resultar em arquiteturas distintas de redes neurais, com características bastante diversas, algumas das quais serão discutidas nesta seção. No entanto, embora possam existir diferenças significativas entre estas arquiteturas, todas são chamadas, indistintamente, de redes neurais, devido ao fato de que o bloco básico de construção da arquitetura é o neurônio artificial (CICHOCKI, UNBEHAUEN, 1993).

A definição da arquitetura de uma RNA é um elemento essencial na sua concepção, uma vez que ela estabelece o tipo de problema que pode ser resolvido pela rede. Por exemplo, existem redes neurais cuja arquitetura as habilita a resolver problemas linearmente separáveis, em adição, existem aquelas que guardam o conhecimento anteriormente adquirido na sua estrutura, não sendo necessário se rerepresentar o conjunto de observações iniciais para aumentar a capacidade de discernimento da rede. Existem também aquelas que não requerem aprendizado supervisionado e as que estão habilitadas a lidar com estruturas não lineares de grande complexidade (ZURADA, 1995).

Os principais parâmetros que definem a arquitetura de uma RNA são: o número de camadas da rede, o número de neurônios em cada camada; o tipo de conexão entre os neurônios da rede e a sua conectividade (ASSEF, 1999).

Quanto ao número de camadas, uma rede pode conter (PAULA, 2000):

- Uma única camada - existe apenas um neurônio entre uma entrada e uma saída, ou seja, nesta rede há apenas a camada de saída que recebe os sinais de entrada diretamente ponderados pelos seus respectivos pesos, como ilustrado na Figura 3.7.

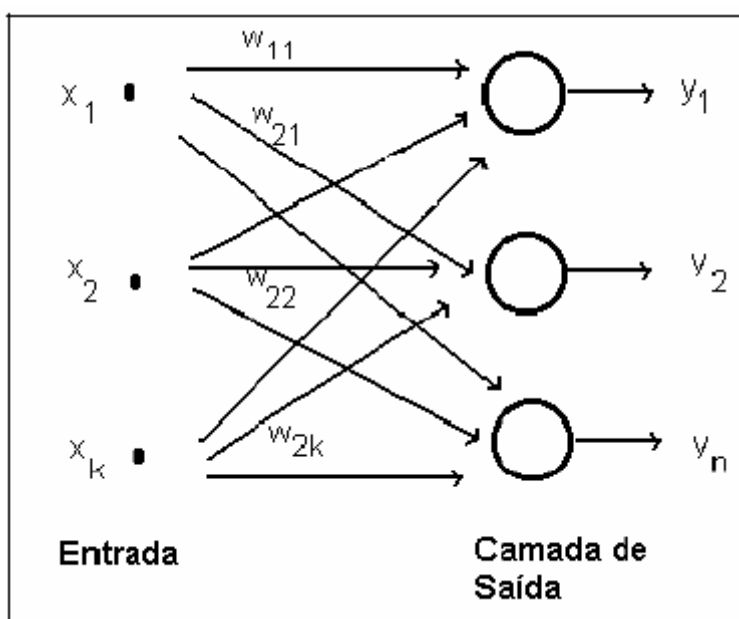


Figura 3.7: Rede com apenas uma camada

- Múltiplas camadas - são redes com uma ou mais camadas entre as entradas e a camada de saída, conforme é ilustrado na Figura 3.8. Essas camadas de neurônios são chamadas de camadas intermediárias ou escondidas (*hidden*).

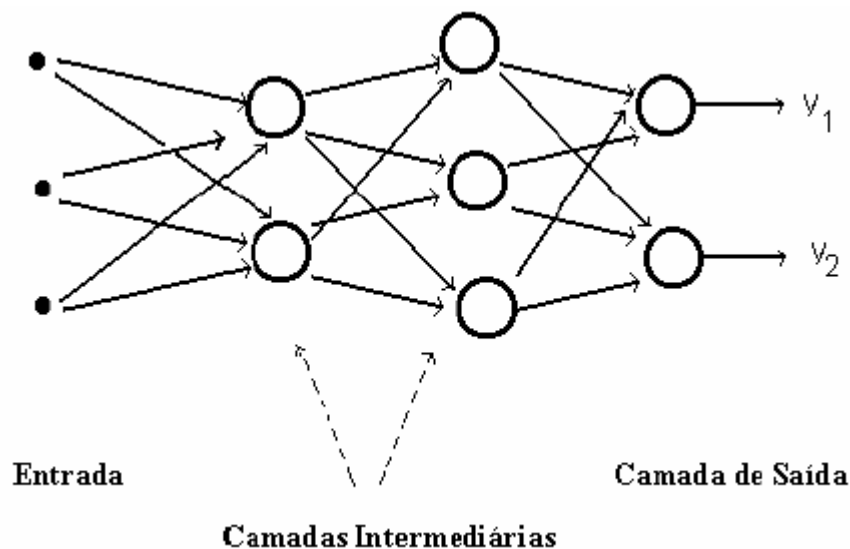


Figura 3.8: Rede com múltiplas camadas

Em relação à conexão entre os neurônios, as redes podem ser (DINIZ, 1997):

- *Feedforward* ou acíclica - a saída de um neurônio na i -ésima camada da rede, não pode ser utilizada como entrada de neurônios existentes em camadas de índice menor ou igual a i , ou seja, a informação flui somente da entrada para a saída. Em adição, não existem, nesse tipo de rede, conexões entre neurônios de uma mesma camada. As redes apresentadas nas Figuras 3.7 e 3.8 são do tipo *feedforward*.
- *Feedback* ou cíclica – a saída de um neurônio na i -ésima camada da rede é usada como entrada para neurônios em camadas de índice menor ou igual a i , ou seja, a informação processada por um neurônio pode ser utilizada por ele mesmo posteriormente (*feedback*). Ver Figura 3.9.




Figura 3.9: Rede cíclica

- Em termos de conectividade, as redes são classificadas em (ASSEF, 1999):
- Completamente conectadas – todos os neurônios da rede estão interconectados; e
- Fracamente conectadas – nem todos os neurônios da rede estão conectados entre si.

As Figuras 3.7 e 3.10 apresentam, respectivamente, exemplos de redes completamente conectadas e fracamente conectadas.




Figura 3.10: Rede fracamente conectada

Uma das propriedades mais importantes das redes neurais é a habilidade de aprender através de exemplos e com isso melhorar seu desempenho. Em princípio, quanto maior o número de exemplos distintos, maior o aprendizado. Isso é feito através de um processo iterativo, no qual os pesos das conexões são ajustados de acordo com os exemplos analisados pela rede. O aprendizado ocorre quando a rede neural atinge uma solução satisfatória para uma determinada classe de problemas (RIBEIRO, 2003). A seção que se segue descreve possíveis formas de aprendizado de uma rede neural artificial.

3.7 Aprendizado das Redes Neurais

De todas as propriedades das redes neurais artificiais, a que melhor captura o comportamento humano é a habilidade de aprender, ou seja, a habilidade em extrair informações relevantes baseadas nos dados apresentados, criando assim, uma representação própria para o problema (BOCANEGRA, 2002).

Neste sentido, a habilidade de aprender permite que a rede neural artificial possa ser treinada, através de exemplos, para realizar uma determinada tarefa, não sendo necessário especificar previamente os detalhes do problema a ser solucionado.

A etapa de aprendizagem consiste em um processo iterativo de ajuste dos pesos das conexões entre os neurônios (HRYCEJ, 1992). Estes pesos, ao final do processo, guardam o conhecimento que a rede adquiriu do ambiente em que está processando (RIBEIRO, 2003).

Ao longo do tempo, diversos métodos de treinamento para redes neurais foram propostos. Estes métodos podem ser subdivididos em dois grandes grupos: aprendizado supervisionado e aprendizado não-supervisionado (KROSE, SMAGT, 1996).

Em um aprendizado supervisionado, a RNA é treinada com auxílio de um supervisor. Para tanto, a rede deverá receber, durante o treinamento, pares de entrada e saída, ou seja, para cada entrada é apresentada a saída desejada. Quando uma entrada for apresentada à rede, é verificado se a saída estimada, gerada através dos cálculos efetuados a partir dos pesos das conexões na rede, confere com a saída desejada para aquela entrada. Caso seja diferente, a rede ajusta os pesos de forma a armazenar o conhecimento desejado. Esta interatividade do treino é repetida com todo conjunto de treinamento até que a taxa de acerto esteja dentro de uma faixa considerada satisfatória (DRAXLER, MEISL, THEINER, 2002).

Neste sentido, o aprendizado supervisionado é utilizado quando há um banco de dados com exemplos que contêm as descrições de problemas e suas respostas. Com base nestas informações, a rede neural artificial pode aprender as relações que existem entre as entradas e a saída. O aprendizado supervisionado é o paradigma de treinamento mais utilizado para desenvolver aplicações de RNAs para classificação (BIGUS, 1996).

Um outro tipo de aprendizado é o aprendizado não-supervisionado. Este tipo de aprendizado também é conhecido como aprendizado auto-supervisionado, por não requerer a apresentação das saídas desejadas na sua etapa de aprendizagem

e, conseqüentemente, não necessitando de um supervisor (DRAXLER, MEISL, THEINER, 2002).

No aprendizado não-supervisionado, a rede possui a habilidade de formar representações internas para codificar características da entrada e criar novas categorias automaticamente, segundo padrões, regularidades e correlações existentes entre os dados de entrada. Em outras palavras, para uma entrada fornecida à rede, será produzida uma resposta indicando a categoria a qual a entrada pertence. Se o padrão de entrada não corresponde às categorias existentes, uma nova categoria é gerada (ZURADA, 1995).

Em geral, o aprendizado não supervisionado é aplicado na resolução de problemas de categorização, com grandes quantidades de dados, onde as entradas são conhecidas e não se sabe as respostas desejadas correspondentes a estas entradas. O aprendizado é realizado com a categorização das entradas que possuem características similares (JAIN, MAO, MOHIUDDIN, 1996).

No que diz respeito aos algoritmos de treinamento utilizados, existe uma grande variedade, tanto para o treinamento supervisionado, como para o não supervisionado. Entre esses, um dos mais difundidos é o algoritmo do tipo supervisionado, conhecido por *back-propagation* (retro-propagação) (KORDING e KONING, 2001). Este algoritmo é utilizado neste trabalho para o treinamento de redes do tipo perceptron multi-camadas. Este tipo de rede consiste da derivação da rede perceptron de uma única camada proposta, em 1958, por Frank Rosenblatt, e é apresentada seção seguinte.

3.8 Redes Perceptron

O modelo proposto por Frank Rosenblatt, em 1958, conhecido como perceptron, era composto por uma estrutura de rede, tendo como unidades básicas, os neurônios artificiais propostos por McCulloch e Pitts. Este foi o primeiro modelo de redes neurais artificiais capaz de ajustar os pesos de suas conexões, de acordo com as entradas apresentadas à rede e suas respectivas respostas esperadas. Em outras palavras, a rede perceptron era capaz de aprender (ZURADA, 1995).

O objetivo da rede perceptron é separar as entradas do vetor $X = \{x_1, x_2, \dots, x_m\}$, onde $x_{i \in [1, m]} \in \{0, 1\}$, em uma das duas classes C_1 ou C_2 , através de um aprendizado supervisionado (HAYKIN, 2001).

A função de ativação utilizada no processamento da rede perceptron é a função degrau, permitindo que a saída da rede, tanto a estimada quanto a desejada, tenha uma representação binária 0 ou 1 (PERANTONIS, VIRVILIS, 2000). Ver Figura 3.11.

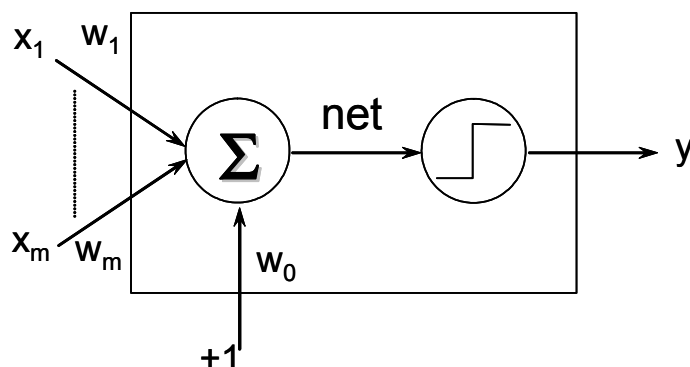


Figura 3.11: Arquitetura básica da rede perceptron

A função degrau do perceptron é definida por:

$$y = 0, \text{ se } net < \theta \quad \text{e} \quad y = 1, \text{ se } net \geq \theta,$$

onde θ é o limiar de excitação. Em vista disto, segundo Braga *et al.* (1998), a fronteira de decisão que determina se uma entrada x_i pertence à classe C_1 ou C_2 , pode ser representada por:

$$net = \theta, \text{ onde } net = \sum_{i=1}^m x_i w_i, \text{ ou seja, } \sum_{i=1}^m x_i w_i = \theta \text{ ou } \sum_{i=1}^m x_i w_i - \theta = 0,$$

que é equivalente a se adicionar uma entrada com valor fixo $x_0 = 1$ que está permanentemente relacionada a um peso $w_0 = -\theta$. A função de ativação pode, então, ser reescrita da seguinte forma:

$$y = 0, \text{ se } net < 0 \quad \text{e} \quad y = 1, \text{ se } net \geq 0$$

E a fronteira de decisão passa a ser expressa por:

$$\sum_{i=0}^M x_i \cdot w_i = 0, \text{ onde } x_0 = 1 \text{ e } w_0 = -\theta,$$

definindo, assim, um hiperplano que passa em θ .

Neste sentido, a regra de decisão para a classificação resume-se em atribuir as entradas x_1, x_2, \dots, x_m à classe C_1 , se a saída do perceptron y for 0, e à classe C_2 , se ela for 1, obtendo um hiperplano separador. Na Figura 3.12, está ilustrado um problema de classificação bidimensional, onde a reta corresponde ao hiperplano separador, definido pela equação:

$$w_1 \cdot x_1 + w_2 \cdot x_2 + b = 0, \text{ onde } b = -\theta$$

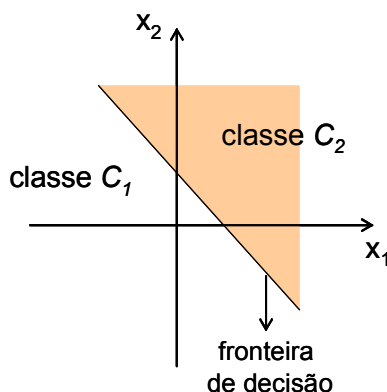


Figura 3.12: Fronteira de decisão da rede perceptron

Para melhor compreender o comportamento da rede perceptron, será apresentada a sua regra de aprendizado, que permite a adaptação dos seus pesos de forma a obter a definição do hiperplano separador das classes C_1 e C_2 .

A fase de aprendizado do perceptron é feita através da aprendizagem por correção de erro, onde é realizado o ajuste dos pesos sinápticos $w_i(t)$ do neurônio excitado pela entrada $x_i(t)$ do vetor de entradas $X(t)$, na iteração t (HAYKIN, 2001). A saída estimada do neurônio é representada por $y(t)$. Esta saída é comparada com a resposta desejada $d(t)$. Conseqüentemente, é produzido um sinal de erro $e(t)$:

$$e(t) = d(t) - y(t)$$

Uma vez obtido o sinal de erro $e(t)$, descobre-se o ajuste $\Delta w_i(t)$ aplicado ao peso sináptico w_i no tempo t :

$$\Delta w_i(t) = \eta e(t) x_i(t), \text{ onde } \eta = \text{taxa de aprendizado}$$

Conseqüentemente, se a entrada $x_i(t)$ for igual a 1, o peso da conexão é ajustado, mas se for 0, não há influência sobre a saída, logo não há necessidade de ajustamento (ESTEBON, 1997).

Assim, o valor do incremento ΔW é aplicado ao vetor de pesos W de forma que o seu valor atualizado, $W(t+1) = W(t) + \Delta W$, na iteração $t+1$, esteja mais próximo da solução desejada do que $W(t)$. A equação de atualização dos pesos sinápticos de uma rede perceptron é expressa como (RIBEIRO, 2003):

$$W(t+1) = W(t) + \eta \cdot e(t) \cdot X(t)$$

Os ajustes corretivos são projetados para aproximar passo a passo o valor de saída $y(t)$ da resposta desejada $d(t)$. Estes ajustes continuam até o sistema atingir um erro aceitável.

As redes do tipo perceptron têm apenas uma camada de processamento, ou seja, são classificadas como redes de camada única. Conseqüentemente, elas possuem a limitação de apenas solucionarem problemas linearmente separáveis. Em outras palavras, as entradas a serem classificadas devem estar suficientemente separadas entre si para assegurar que a superfície de decisão consista de um hiperplano (CICHOCKI, UNBEHAUEN, 1993).

Esta limitação foi superada em modelos de redes que surgiram, a partir dos anos 80, com o desenvolvimento de técnicas de aprendizado como, por exemplo, o *back-propagation*, que será visto na seção seguinte.

3.9 Redes MultiLayer Perceptron (MLP)

As arquiteturas do tipo *perceptron* de múltiplas camadas (*MultiLayer Perceptron* - MLP) constituem os modelos neurais artificiais mais utilizados e conhecidos atualmente (BOCANEGRA, 2002). Esta arquitetura é composta por:

- Uma camada de entrada formada por neurônios sensoriais: onde os padrões são apresentados à rede;
- Uma ou mais camadas intermediárias (ou escondidas) de neurônios: onde é realizada a maior parte do processamento. São as principais responsáveis por extrair as características dos padrões fornecidos à rede;
- Uma camada de saída: onde o resultado final é concluído e apresentado.

Veja Figura 3.13.




Figura 3.13: Rede MLP com duas camadas escondidas

Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída. Esta arquitetura representa uma generalização do perceptron apresentado na seção anterior.

As redes do tipo MLP, por possuírem mais de uma camada de processamento, são capazes de solucionar problemas linearmente não separáveis, sendo esta uma limitação das redes perceptron de uma única camada (BRAGA, CARVALHO, LUDERMIR, 1998).

O treinamento das redes MLP é realizado, através do algoritmo de aprendizagem supervisionada, conhecido como retro-propagação do erro (*error back-propagation*). Adequado para a resolução de problemas de mapeamento complexo, este algoritmo tem sido utilizado em vários tipos de aplicação incluindo classificação, aproximação de funções e previsões (ZURADA, 1995). Sua definição será descrita em mais detalhes na próxima subseção.

3.9.1 Algoritmo Back-Propagation

Popularizado em 1986, por Rumelhart, Hinton e Williams, o algoritmo *error back-propagation*, ou simplesmente *back-propagation*, procura minimizar o erro obtido pela rede, ajustando os pesos das conexões para que estes correspondam às coordenadas dos pontos mais baixos da superfície de erro (Figura 3.14). Para isto, o algoritmo utiliza o método do gradiente¹⁷ descendente que permite à rede caminhar, pela superfície de erro, na direção de decrescimento do erro obtido (GERMAN, GAHEGAN, 1996). Mas, para que este método possa ser aplicado, a função de ativação precisa ser contínua e diferenciável (HAYKIN, 2001).

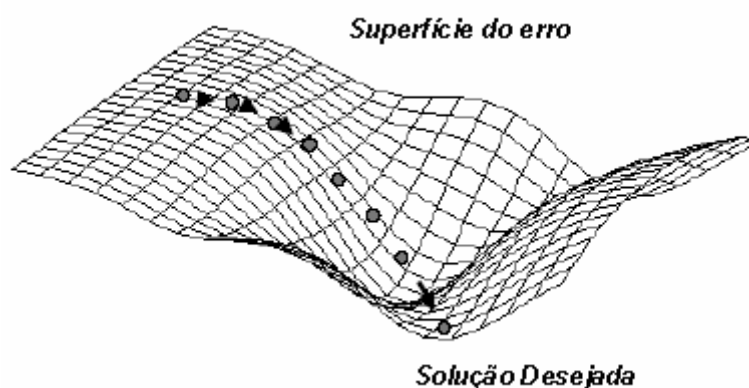


Figura 3.14: Superfície de erro de uma rede MLP

¹⁷ O gradiente de uma função está na direção e sentido em que a função tem taxa de variação máxima.

Uma das principais vantagens deste algoritmo é permitir que o erro calculado na saída da rede seja retro-propagado para os neurônios das camadas escondidas. Este ajuste é realizado através da seguinte fórmula geral:

$$w_{ji}(t+1) = \eta \times \delta_j(t) \times x_j(t),$$

onde $w_{ji}(t+1)$ é o peso da conexão sináptica do neurônio i ao neurônio j , na iteração $t+1$, η é o parâmetro de aprendizagem, $\delta_j(t)$ é o gradiente local e $x_j(t)$ é o sinal de entrada do neurônio j (ZURADA, 1995; HAYKIN, 2001).

Quando o neurônio j está localizado na camada de saída da rede, ele possui uma resposta desejada particular, d_j . Assim, o gradiente local $\delta_j(t)$ será igual ao produto da derivada $f'_j(\text{net}_j(t))$ pelo sinal de erro e_j , ambos associados ao neurônio j , ou seja,

$$\delta_j(t) = e_j(t) \cdot f'_j(\text{net}_j(t)),$$

onde e_j corresponde a diferença entre a saída desejada d_j , e a saída estimada y_j , no neurônio j ; e

$$\text{net}_j = \sum_{i=1}^n x_i \cdot w_{ji}$$

Ver Figura 3.15.

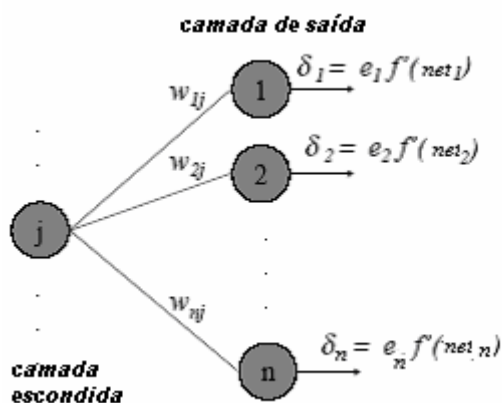


Figura 3.15: Ajuste dos pesos dos neurônios na camada de saída

Se o neurônio j estiver em uma camada escondida, $\delta_j(t)$ será igual ao produto da derivada associada $f'_j(\text{net}_j(t))$ pela soma ponderada dos δ s calculados para os neurônios k na próxima camada escondida ou camada de saída que estão conectados ao neurônio j :

$$\delta_j(t) = f'_j(\text{net}_j(t)) \cdot \sum_k \delta_k(t) w_{kj} \quad ,$$

Neste sentido, o erro calculado na saída da rede é retro-propagado para os neurônios das camadas escondidas.

Na aplicação do algoritmo de *back-propagation*, é possível distinguir duas fases: a de propagação do sinal de entrada (*feedforward*) e a de retro-propagação do erro (*back-propagation*), como ilustrado na Figura 3.16.




Figura 3.16: Fluxo de processamento do algoritmo *back-propagation*

Na fase propagação, o vetor de entrada $X = \{x_1, x_2, \dots, x_m\}$ é aplicado como estímulo aos neurônios da primeira camada da rede, e a partir destes valores, é calculado o valor de net_j , baseado nos pesos das conexões, w_{ij} , associados ao neurônio j :

$$\text{net}_j = \sum_{i=1}^m x_i \cdot w_{ij}$$

Posteriormente, a saída do neurônio é determinada pela função de ativação da camada, aplicada sobre o netj do neurônio. Esse processamento é repetido em cada uma das outras camadas escondidas, até que, finalmente, um conjunto de saídas é produzido como resposta da rede. Para cada saída deste conjunto, um sinal de erro é calculado, comparando a saída estimada com a saída desejada correspondente.

Por outro lado, na fase de retro-propagação, o sinal de erro calculado, na etapa anterior, é retro-propagado da saída para cada neurônio da camada escondida anterior que contribui diretamente para a formação da saída. Os sinais de erro são retro-propagados para a esquerda através da rede, camada por camada, e recursivamente calculado o gradiente local δ de cada neurônio. Este processo recursivo permite que os pesos sinápticos sejam modificados de acordo com a fórmula geral de ajuste dos pesos, apresentada anteriormente. Note que para a apresentação de cada exemplo de treinamento, a entrada está fixa, durante todo o ciclo, englobando o passo de propagação seguido pelo passo de retro-propagação.

O treinamento continua até que uma condição de parada aconteça. Existem duas condições principais para terminar um treinamento: número de passos, ou iterações, t ou erro mínimo. O usuário irá escolher com quantos passos irá treinar a rede ou qual o erro quadrático médio que ele deseja. Caso o erro seja obtido antes de terminar o número de passos imposto, o treinamento termina. Caso contrário, a rede só irá parar, quando for atingido o número de passos desejado.

3.10 Exemplos de Aplicações e uso de Redes Neurais

Atualmente, uma grande atenção tem sido dada às redes neurais artificiais, por estas possuírem uma variedade crescente de aplicações, como o reconhecimento de padrões, otimização, interpretações de imagens, previsões em sistemas complexos, etc. Nesta seção apresentamos algumas aplicações de RNAs que podem ser encontradas no mercado.

As redes neurais artificiais vêm sendo utilizadas intensamente na área de reconhecimento de padrões. Como por exemplo, na área médica, onde elas estão se tornando uma poderosa ferramenta tanto para diagnose médica, quanto para a

prevenção de um número crescente de diferentes enfermidades (DYBOWSKI, GANT, 2001).

No mundo dos negócios, as redes neurais se tornaram um importante instrumento de previsão. A habilidade para antecipar de forma apurada o futuro próximo, é fundamental para diversos processos de tomada de decisão, a saber: compra de ativos, formulação de estratégias, reposição de insumos etc. (SMITH, GUPTA, 2002). Por exemplo, as previsões fornecidas pela rede tendo como base o histórico de transações realizadas na BOVESPA permite que o investidor tome decisões com uma maior probabilidade de ser bem sucedido (ZHANG, 2003).

Outra aplicação baseada em redes neurais comumente encontrada na literatura é a interpretação de imagens. Um exemplo de aplicação nesta área é o reconhecimento de caracteres manuscritos (BISHOP, 1995). Ao utilizar um método de extração de características, sobre a imagem correspondente ao caractere manuscrito, é possível, através das redes neurais, interpretar esta imagem e identificar qual caractere ela está representando (SILVA, 2002).

Uma outra área onde a aplicação de redes neurais tem se destacado é a de processamento de texto. A tecnologia de redes neurais está sendo utilizada, de forma significativa, para o processamento de texto visando à resolução de problemas de reconhecimento de padrão (SELAMAT, OMATU, 2004).

Esta dissertação de mestrado é um exemplo de aplicação de processamento de texto baseada em rede neurais. Nele é proposto um sistema de resposta automática que utiliza uma rede MLP treinada, a partir do algoritmo *back-propagation* e um banco de respostas do domínio de aplicação, isto é, do Desafio SEBRAE. No próximo capítulo, serão apresentados, em mais detalhes, como foi o processo de desenvolvimento desta aplicação.

CAPÍTULO 4. MÉTODOS E FERRAMENTAS DE PESQUISA

Neste capítulo apresentamos os métodos e ferramentas utilizadas no desenvolvimento do sistema de resposta automática para o Desafio SEBRAE.

Mais especificamente são descritos a fase de obtenção dos dados pelo Desafio SEBRAE, os processos de manipulações de dados envolvendo tanto as respostas como as mensagens e, ao final, o treinamento da rede neural através dos dados transformados nas etapas anteriores.

O fato das dúvidas, sugestões e reclamações serem enviadas ao sistema de *help desk* em linguagem natural faz com que elas tenham que ser transformadas antes de poderem ser apresentadas ao modelo quantitativo sobre o qual o sistema de resposta automática está baseado.

Em adição, foram realizadas manipulações adicionais visando à diminuição da complexidade deste modelo quantitativo, a saber: o agrupamento das respostas com assuntos em comum e a divisão das mensagens com múltiplos assuntos envolvidos.

No entanto, é importante notar que o agrupamento das respostas e a divisão das mensagens nem sempre farão parte do processo de transformação do texto contido nas mensagens enviadas a um sistema de resposta automática.

Conforme veremos nas seções 3.2 e 3.3, isso dependerá do ambiente de comunicação entre o usuário e o *help desk* e da padronização das respostas enviadas por esta central de atendimento.

4.1 Obtenção dos Dados

A base de conhecimento utilizada para a construção do sistema de resposta automática objeto desta dissertação foi gentilmente fornecida pelo Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE).

Esta base contém cerca de 1.500 mensagens com dúvidas, sugestões e reclamações enviadas ao sistema de *help desk* do Desafio SEBRAE pelas equipes participantes do desafio, durante a realização do jogo no ano de 2004.

Em adição, o SEBRAE forneceu para cada uma destas mensagens a resposta enviada pelo operador de *telemarketing* aos participantes do jogo. Ver Figura 4.1.

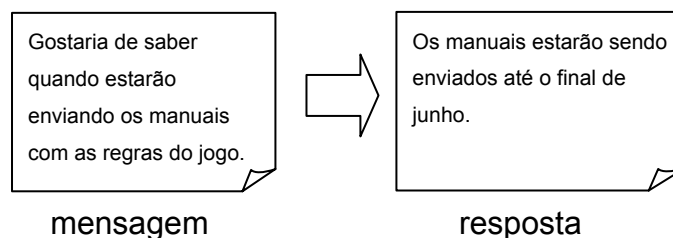


Figura 4.1: Mensagem com sua resposta personalizada

4.2 Manipulação das Mensagens

A forma de comunicação entre os participantes do jogo e o sistema de *help desk* do Desafio SEBRAE é realizada através do envio de mensagens via um sistema de e-mail desenvolvido pela organização (FERREIRA, 2004).

Conseqüentemente, não há limitações sobre o tamanho destas mensagens e o seu escopo, permitindo que elas contenham múltiplas perguntas associadas a diversos temas e, por conseguinte, múltiplas respostas. Como por exemplo, na mensagem apresentada na Figura 4.2:

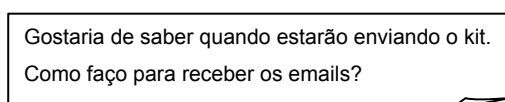


Figura 4.2: Mensagem com múltiplos temas associados

Visando uma diminuição na complexidade do modelo quantitativo proposto neste trabalho, optamos em dividir as mensagens, de forma que cada uma contivesse apenas uma pergunta.

Dentre as 1.531 mensagens fornecidas pelo desafio, existiam 77 mensagens com múltiplas perguntas. A partir da divisão destas mensagens, foi obtido um total de 1.596 mensagens, como pode ser visto na Figura 4.3.

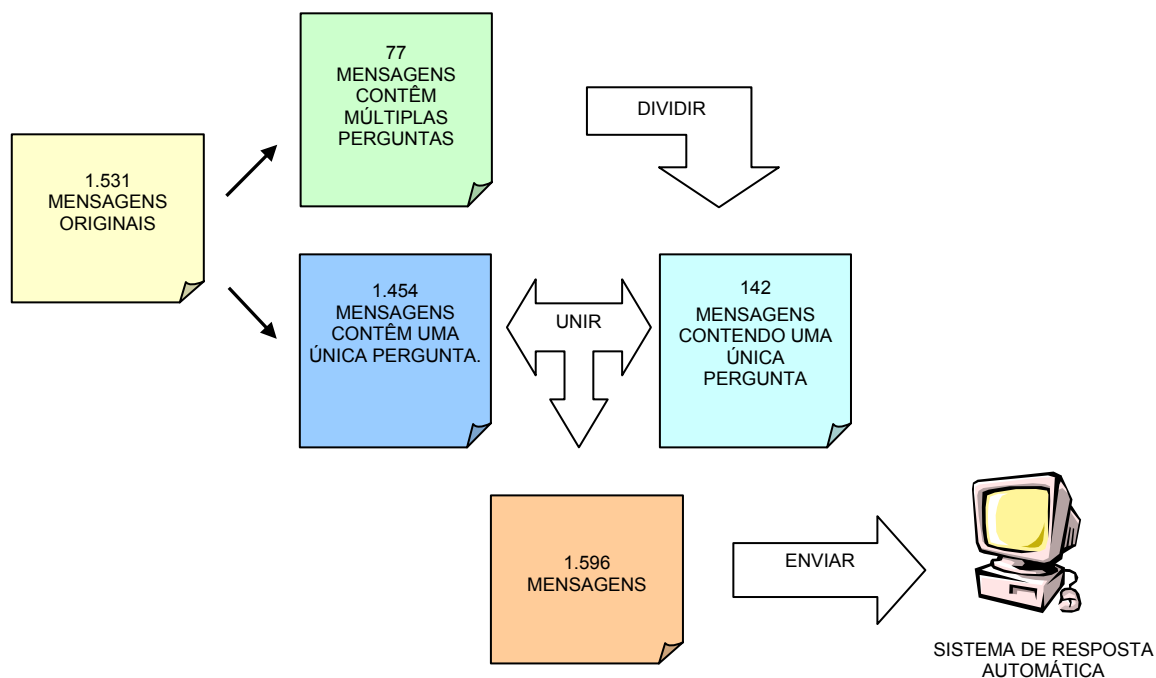


Figura 4.3: Processo de manipulação das mensagens

Note que este processo de manipulação das mensagens não seria necessário se o ambiente de comunicação dos participantes com o *help desk* possuísse uma orientação que induzisse o participante a enviar mensagens contendo uma única pergunta por vez. Neste sentido, no capítulo 6, serão apresentadas algumas sugestões para resolver este problema.

4.3 Manipulação das Respostas

Ao realizar um exame detalhado sobre as respostas enviadas aos participantes do desafio, observou-se que muitas se relacionavam a um mesmo tema ou assunto.

Com o objetivo de diminuir a complexidade de nosso modelo quantitativo, optamos por agrupar as respostas com assuntos em comum. Este agrupamento

resultou em uma redução de um grupo de 141 respostas para um conjunto de 24 respostas, como pode ser visto na Figura 4.4.

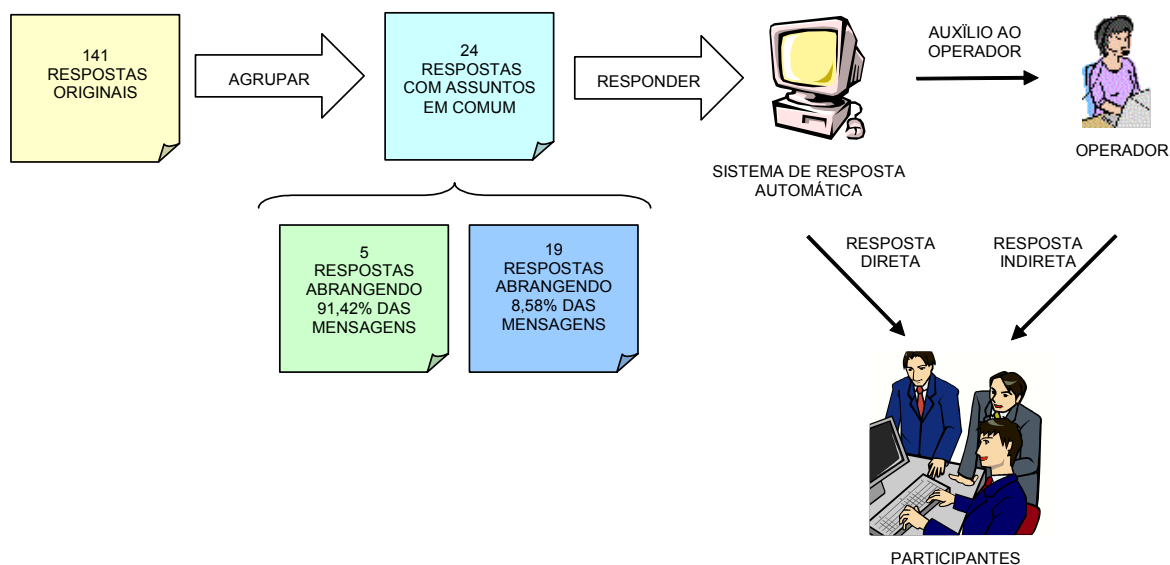


Figura 4.4: Processo de manipulação das respostas

Entre as 24 respostas, observou-se que um número relativamente pequeno, 5 respostas, abrangia um número relativamente grande de mensagens, 91,42% para ser exato.

Como dificilmente um sistema de resposta automática se propõe a responder todas as perguntas que lhe são apresentadas, mesmo porque sempre existem perguntas que exigem respostas personalizadas (ver Figura 4.5), optamos por desenvolver o sistema de resposta em torno das respostas que concentram a maior parte das perguntas, enviando as demais perguntas para serem respondidas pelo operador.

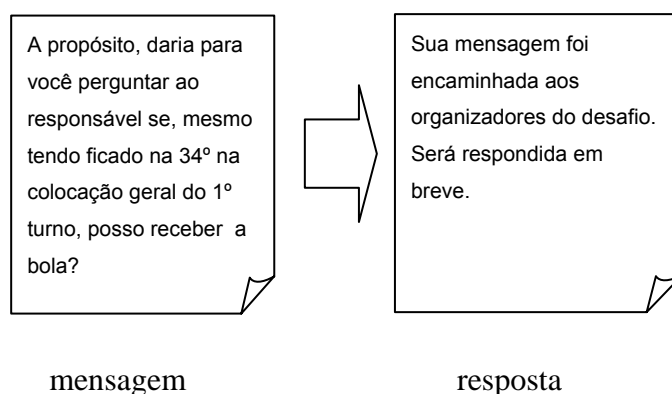


Figura 4.5: Mensagem e sua Resposta

As cinco respostas escolhidas para servirem de base para o desenvolvimento do sistema de resposta automática estão apresentadas no Anexo I.

Portanto, quando uma resposta é apresentada ao sistema de resposta automática desenvolvido no escopo desta tese, duas alternativas de respostas diferentes se apresentam, a saber:

- O sistema responde diretamente ao usuário, utilizando uma das cinco respostas padrões, ou
- Solicita que o operador forneça uma resposta adequada a pergunta, ver Figura 4.4.

4.4 Preparação dos Dados

Esta etapa concentra a maior parte das transformações ocorridas sobre os dados contidos nas mensagens fornecidas pelo SEBRAE. O objetivo principal desta etapa é preparar os dados armazenados no banco de dados para que possam ser apresentados ao modelo quantitativo.

Na Figura 4.6 são ilustradas as transformações necessárias à preparação dos dados e que serão objeto de estudo nas próximas subseções, a saber:

- Tokenização;

- Tradução de idiomas e siglas;
- Transcrição fonológica;
- Redução dos verbos aos seus respectivos infinitivos;
- Retirada das *stop words* e
- Escolha das palavras mais relevantes.

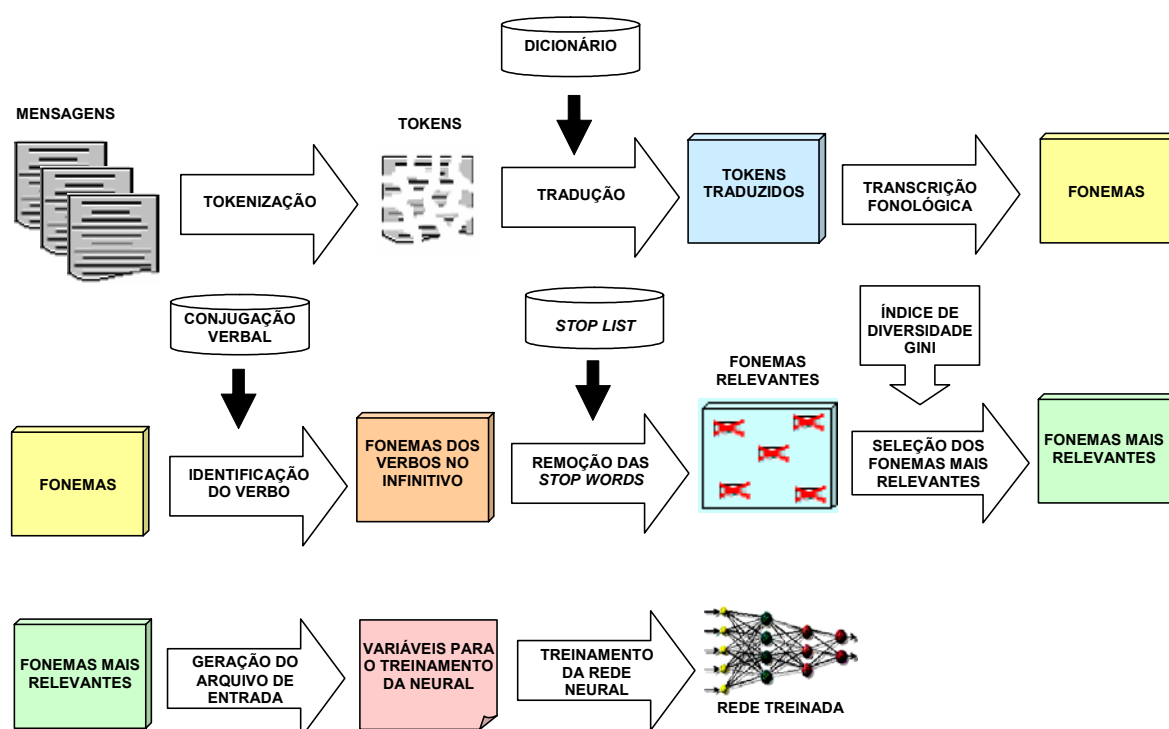


Figura 4.6: Arquitetura do sistema de resposta automática

4.4.1 Tokenização

O processo de tokenização consiste na identificação de *tokens*, ou seja, na separação das diferentes palavras que fazem parte de cada mensagem enviada pela equipe participante do desafio.

Para efeito deste trabalho de dissertação, uma palavra, ou *token*, é uma seqüência de caracteres alfanuméricos sem espaços em branco, da qual são retirados os sinais de pontuação (RODRIGUES *et.al*, 2004).

A Figura 4.7 ilustra o processo de tokenização, onde a partir de um determinado texto, se obtêm as palavras em separado.

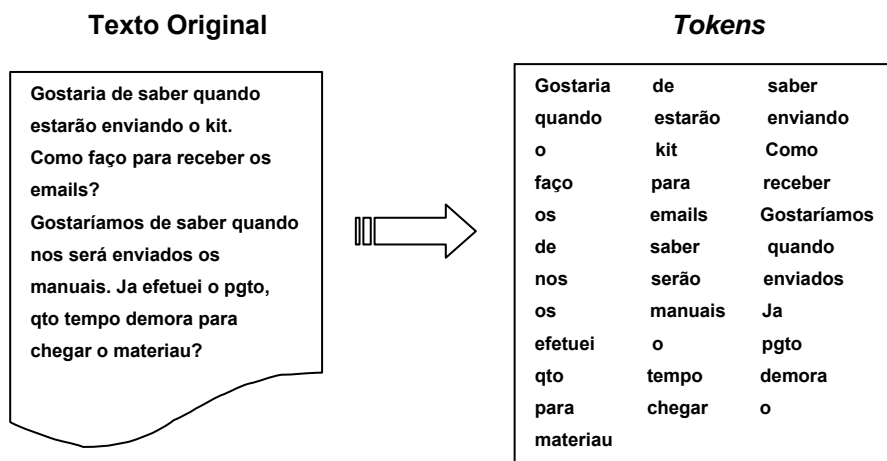


Figura 4.7: Processo de tokenização

Na etapa de tokenização, foi implementado um algoritmo com o objetivo de armazenar, em uma estrutura de dados do tipo tabela, os *tokens* existentes nas mensagens.

A tokenização é uma das principais fases de nosso trabalho, uma vez que os *tokens* são utilizados pelas demais etapas do processo de transformação dos dados. Os *tokens* resultantes deste processo estão em uma forma bruta e precisam ainda ser lapidados para que possam ser apresentados ao modelo quantitativo.

Com essa idéia em mente, estes *tokens* passarão por algumas transformações, tais como: tradução, transcrição fonológica, redução dos verbos aos seus respectivos infinitivos, remoção das *stop words* e seleção das palavras mais relevantes.

4.4.2 Tradução

Durante o processo de tokenização das mensagens fornecidas pelo SEBRAE, foram encontrados alguns *tokens* pertencentes à língua inglesa, outros representados como siglas ou abreviações de palavras.

Com o intuito de evitar que diversas palavras ou conjunto de palavras tenham o mesmo significado e, por conseguinte, dificultando a construção do modelo quantitativo, foi construído um dicionário, especificamente com:

- Palavras estrangeiras, para a tradução destas do inglês para o português;
- Siglas e abreviações, para a tradução destas a sua forma por extenso.

O dicionário construído tem por objetivo armazenar palavras estrangeiras, siglas ou abreviações existentes nas mensagens e a tradução de cada uma delas. A unidade de armazenamento do dicionário é constituída por uma estrutura de dados do tipo tabela indexada (SEVERANCE, 1974), onde o índice é a palavra estrangeira, sigla ou abreviação e o resultado da busca é a sua tradução.

O algoritmo de tradução resume-se em tentar localizar na tabela os *tokens* resultantes do processo de tokenização, substituindo-os por suas respectivas traduções caso existam. Ver Figura 4.8.

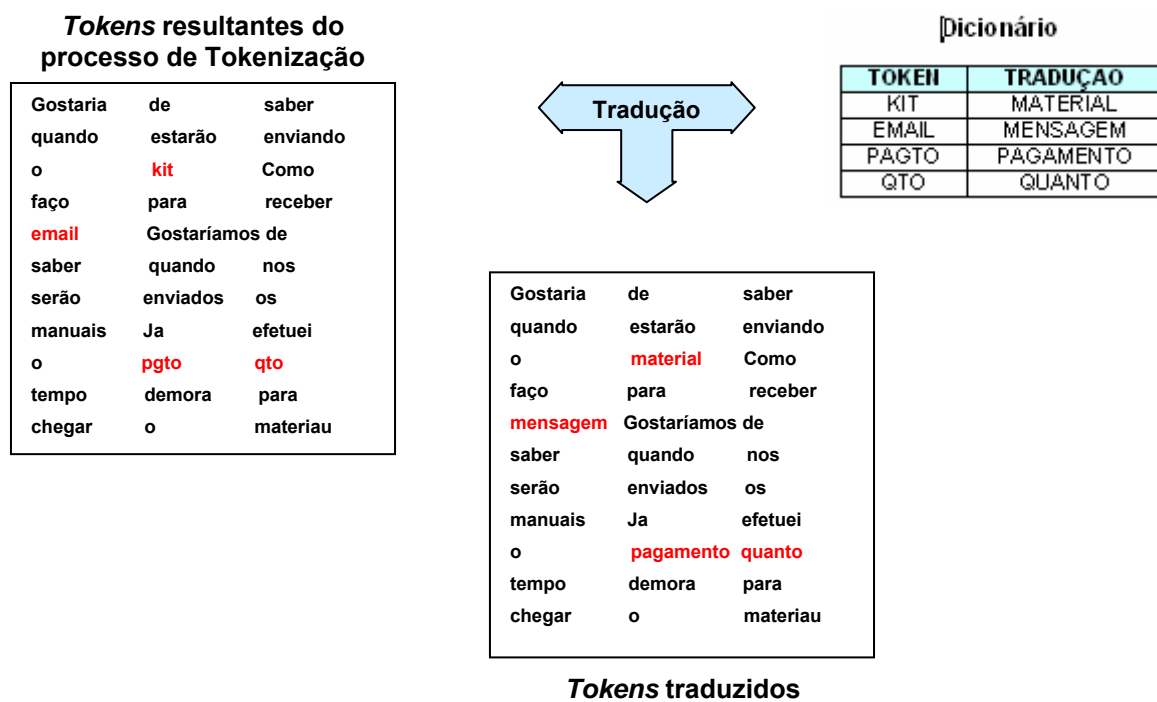


Figura 4.8: Processo de tradução

4.4.3 Transcrição Fonológica

Analisando os *tokens* extraídos no processo de tokenização, verificou-se que existe uma quantidade significativa de palavras escritas erroneamente segundo as normas cultas da língua portuguesa brasileira. Como opção para solucionar este tipo de problema foi implementado um processo de transcrição fonológica dos *tokens*.

Neste trabalho, a conversão de texto em fonemas é realizada através de um conjunto de regras de transcrição de letras para fonemas que permite efetuar a transcrição fonológica das palavras com base nas letras que a constituem. Estas regras baseiam-se nas regras de conversão definidas no livro “Princípios do Sistema Alfabético: do Português do Brasil” (CABRAL, 2003).

A opção em transcrever o texto em fonemas¹⁸ confere ao modelo uma maior robustez na interpretação das palavras com maiores erros de grafia. Uma vez que, embora a palavra tenha sido escrita de forma errada, ela poderá ser interpretada da

¹⁸ Os fonemas são as unidades mais simples de uma língua, aos quais correspondem os sons elementares que entram na constituição das sílabas e dos vocábulos.

mesma forma que a sua representação correta, no caso de ambos possuírem uma mesma transcrição fonológica.

Por exemplo, as palavras *kasa* e *casa* possuem a mesma transcrição fonológica, ou seja, ambos são representados pelos fonemas /kaza/¹⁹. Na Figura 4.9 são ilustrados exemplos de transcrição fonológica aplicados neste trabalho.

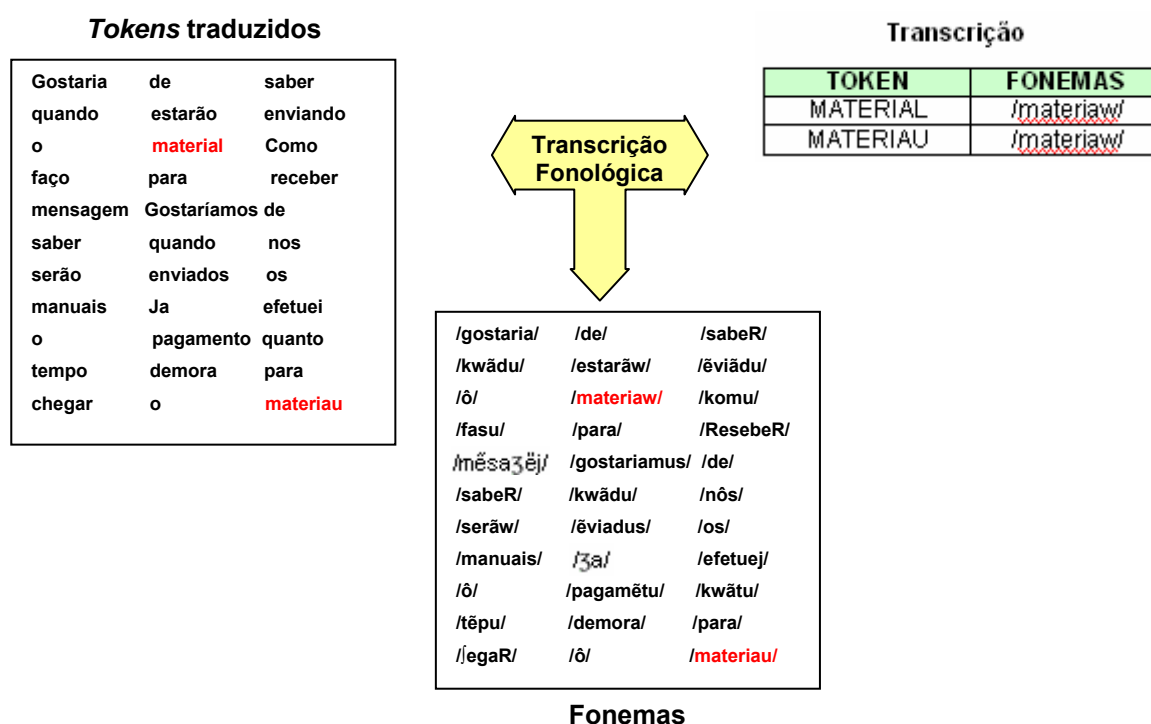


Figura 4.9: Transcrição fonológica

4.4.4 Redução dos verbos aos seus respectivos Infinitivos

Ao analisar as mensagens cedidas pelo SEBRAE foi observado que alguns *tokens* são simplesmente conjugações verbais de um mesmo verbo. Por exemplo, os *tokens* *enviou* e *enviaram* são conjugações verbais do verbo *enviar*.

Embora a redução das conjugações verbais aos seus respectivos infinitivos apresente uma perda de informação, ou seja, deixa-se de saber com precisão

¹⁹ Os fonemas são normalmente representados entre barras oblíquas (/ /) para distingui-los dos sons realmente produzidos.

quando a ação definida pelo verbo foi executada, ela diminui a complexidade do modelo a ser desenvolvido, que requer o uso de uma quantidade menor de palavras.

Nos experimentos relatados no Capítulo 5, os efeitos da perda de informação, propiciada pela redução das conjugações aos seus respectivos infinitivos, sobre a precisão do modelo desenvolvido se revelaram ser muito pequenas.

A Figura 4.10 ilustra o processo de redução das conjugações aos seus respectivos infinitivos utilizado no escopo deste trabalho. Note que como nesta fase, a etapa de transcrição fonológica já foi realizada, os verbos no infinitivo, correspondentes as *tokens* verbais, também foram convertidos em fonemas permitindo uma redução mais adequada.

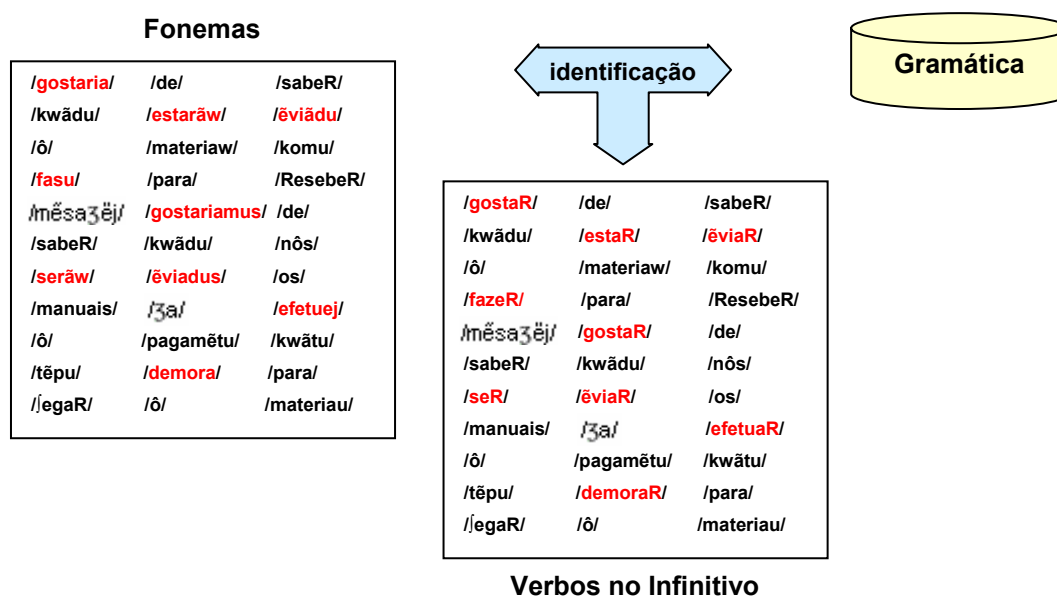


Figura 4.10: Processo de redução dos verbos aos seus infinitivos

4.4.5 Retirada das *Stop Words*

Nas mensagens enviadas pelos participantes do desafio, observou-se que existem muitos *tokens* que não possuem nenhum poder de discriminação. Em outras palavras, eles não influenciam na identificação da resposta associada à mensagem e, conseqüentemente, torna-se uma característica de pouca importância. Assim,

esta etapa concentra-se no processo de retirada destas palavras que não possuem relevância significativa no texto – as chamadas *stop words*.

A lista de palavras irrelevantes é fortemente dependente da língua e do contexto em que ela é utilizada. Tipicamente, palavras como “a”, “de”, “desde”, etc. são exemplos de *stop words* que são empregadas, freqüentemente, na língua portuguesa. Observe que estas palavras transmitem pouca ou nenhuma informação sobre o conteúdo do documento, elas funcionam simplesmente como conectivos entre palavras de maior peso semântico, tais como: substantivos e verbos.

A lista de *stop words* para língua portuguesa que utilizamos no escopo desta tese foi compilada pelo Institut Interfacultaire d'Informatique da Universidade de Neuchatel, na França (STOPWORD, 2002). No entanto, como nesta etapa os *tokens* já foram convertidos em fonemas, estas *stop words* também sofreram o processo de transcrição fonológica para possibilitar a comparação entre os fonemas das mensagens do desafio e as *stop words* compiladas pelo Institut Interfacultaire d'Informatique.

A remoção de *stop words* foi realizada de modo automático. Primeiramente, criou-se uma estrutura de dados do tipo lista, denominada *stop list*, na qual foram definidas todas as palavras que poderiam ser removidas das mensagens. Posteriormente, aplicou-se um algoritmo cujo objetivo foi realizar uma pesquisa sobre os grupos de fonemas e remover aqueles que fossem iguais a alguma representação presente na *stop list*.

Com a retirada das *stop words*, as palavras restantes são consideradas filtradas e, assim, restam apenas os grupos de fonemas relevantes. A Figura 4.11 ilustra um exemplo de remoção das *stop words*.

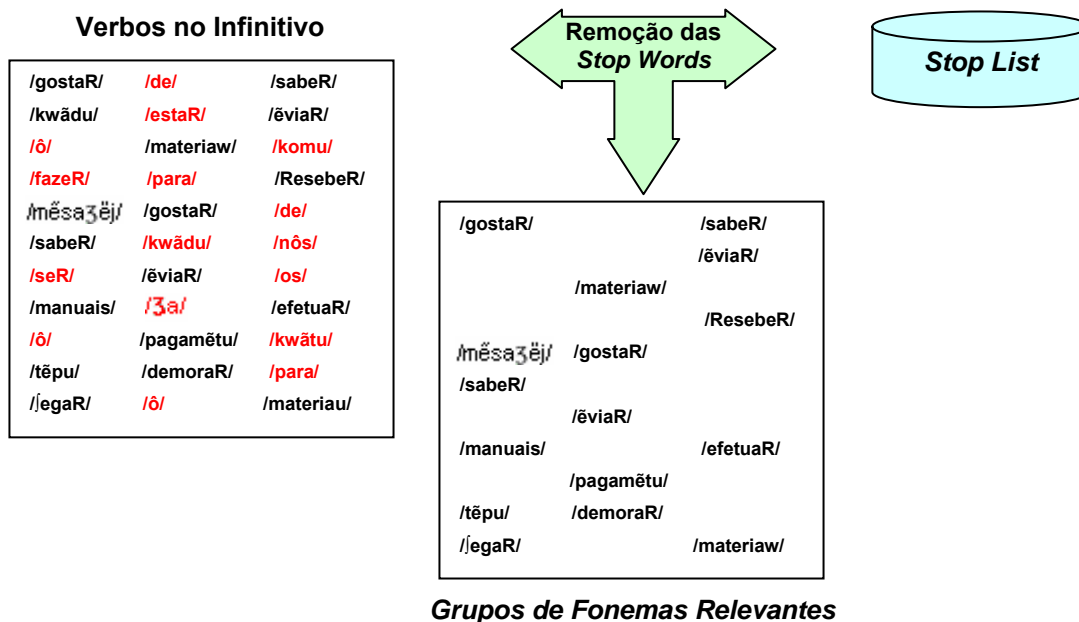


Figura 4.11: Exemplo de remoção das *stop words*

4.4.6 Seleção das Palavras mais Relevantes

Embora o processo de retirada das *stop words*, definidos pelo Institut Interfacultaire d'Informatique da Universidade de Neuchatel, tenha removido alguns fonemas associados aos *tokens* não relevantes, dentro deste grupo, ainda existem *tokens* com diferentes capacidades de discriminação, ou seja, capacidades distintas de identificar que resposta está associada a um conjunto de mensagens.

Por exemplo, considere que existam em nossa base de conhecimento as perguntas apresentadas no Exemplo 4.1:

Nº	Mensagem	Resposta
1	Gostaria de saber quando estarão enviando o material?	1
2	Gostaríamos de saber quando começará o aquecimento	2
3	Gostaríamos de saber quando nos será enviados os manuais.	1
4	Não recebemos nenhum material do aquecimento, ele já está acontecendo? Gostaríamos de participar.	2
5	Ainda não recebemos o material.	1

Exemplo 4.1: Base de conhecimento utilizada na extração dos fonemas relevantes

Suponha que cada uma destas perguntas já tenha passado pelos processos de tokenização, tradução, transcrição fonológica, redução dos verbos, aos seus respectivos infinitivos, e retirada das *stop words*. Portanto, obtendo como resultado os grupos de fonemas relevantes, com capacidades de discriminação distintas, apresentados na Tabela 4.1.

/gostaR/	/pagamêtu/
/materiaw/	/jegaR/
/efetuaR/	/êviaR/
/demoraR/	/komesaR/
/sabeR/	/manuais/
/ResebeR/	/têpu/
/sabeR/	/akesimêtu/
/akôteseR/	/partisipaR/

Tabela 4.1: Grupos de fonemas relevantes

É importante notar que embora este exemplo talvez não necessite da remoção das palavras mais relevantes por conter apenas 16 grupos de fonemas, esta remoção é essencial quando trabalhamos com uma base de conhecimento que possui cerca de 1.500 mensagens.

Se utilizássemos como nós em uma rede neural todos os grupos de fonemas relevantes destas 1.500 mensagens, isto poderia aumentar significativamente a complexidade do nosso modelo quantitativo, uma vez que, em geral, o número de conexões de uma rede neural aumenta exponencialmente à medida que o número de entradas (*inputs*) cresce (HAYKIN, 2001).

Por exemplo, em uma rede neural totalmente conectada, todas as entradas estão conectadas com todos os neurônios da camada seguinte. Se o número de entradas aumenta, isso acaba por aumentar também o número de conexões destas entradas com os neurônios da camada seguinte.

Supondo então que em uma rede neural, o número de neurônios na primeira camada seja igual ao número de entradas e as entradas estejam conectadas a todos os neurônios, o número de conexões cresce de acordo com o quadrado das entradas. Ver Exemplo 4.2.

Entradas	Conexões
2	$2^2 = 4$
3	$3^2 = 9$
4	$4^2 = 16$
⋮	⋮
50	$50^2 = 2.500$

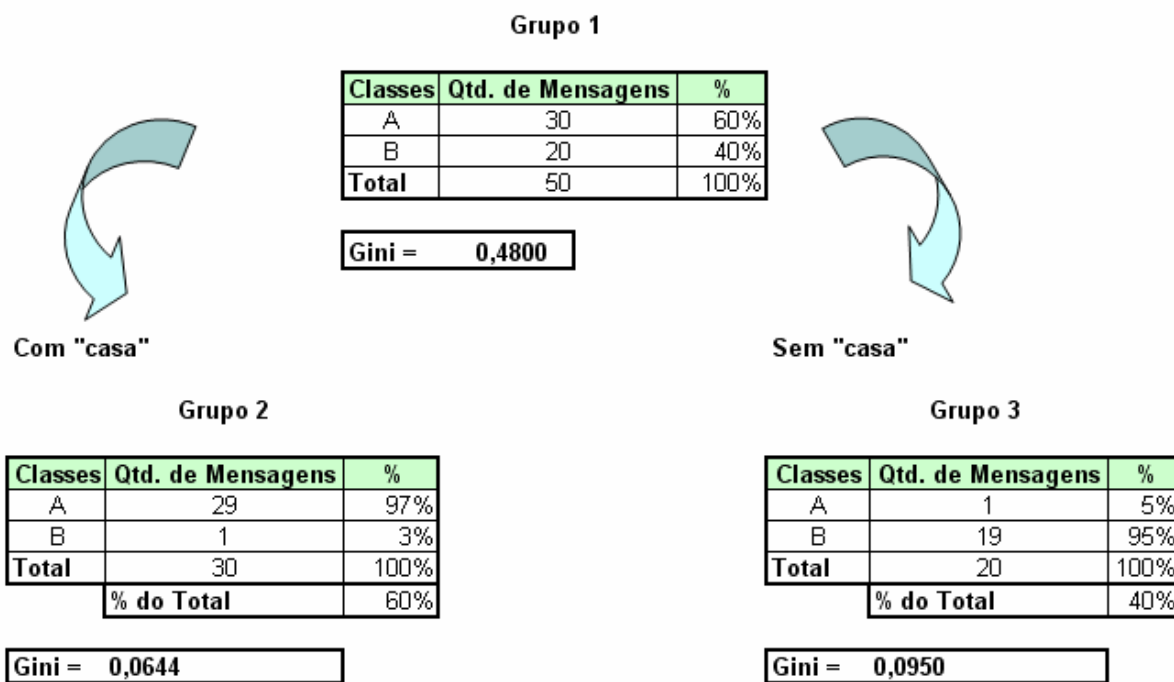
Exemplo 4.2: Conexões na rede neural de acordo com o número de entradas

Então, visando diminuir a complexidade de nossa rede neural, resolvemos selecionar um subgrupo de entradas a partir dos grupos de fonemas resultantes do processo de retirada das *stop words*.

Essa seleção foi realizada escolhendo os grupos de fonemas com maior capacidade de discriminação, em relação a uma determinada resposta. Em outras palavras, se o grupo de fonemas “/materiaw/” possuir um alto poder de discriminação para a *resposta 3*, então as mensagens que possuem este grupo de fonemas terão uma grande probabilidade de estarem relacionadas a *resposta 3*. Uma das formas de realizar este tipo de seleção é através do índice de diversidade Gini.

O índice Gini, proposto inicialmente em 1.914 por Corrado Gini, é uma medida de diversidade que indica, em relação a um conjunto de classes específicas, o grau de homogeneidade de um dado conjunto de objetos pertencentes a estas classes (BREIMAN *et.al.* 1984).

Por exemplo, suponha que em um conjunto de mensagens, chamado *grupo 1*, existem 30 mensagens pertencentes à *classe A* e 20 mensagens pertencentes à *classe B*, conforme ilustrado no Exemplo 4.3.



Exemplo 4.3: Indicação do grau de homogeneidade em um conjunto de objetos

Estas mensagens são compostas por diversas palavras, como por hipótese a palavra “casa”, que possui uma certa capacidade de discriminação.

Ao utilizarmos a palavra “casa” para separar as mensagens existentes no *grupo 1*, em dois subgrupos, percebemos que dentre as mensagens que possuem esta palavra, 97% está associada a *classe A* e apenas 3% a *classe B*.

Então, podemos notar que a palavra “casa” possui uma grande capacidade de discriminação em relação às mensagens existentes no *grupo 1* e pertencentes a *classe A*, pois foi capaz de dividir o *grupo 1* em dois grupos, que em média, são mais homogêneos do que ele.

Isto pode ser verificado, comparando o índice de diversidade Gini do *grupo 1* com os calculados para os *grupos 2* e *3*. Pelo fato dos *grupos 2* e *3* serem mais homogêneos do que o *grupo 1*, eles possuem índices de diversidade Gini menores do que este grupo. Portanto, nota-se que através do índice Gini é possível verificar quão homogêneo é um conjunto de objetos pertencentes às *classes A* e *B*.

No caso de existirem apenas duas classes de objetos, o índice Gini varia entre zero e 0.5, assumindo o menor valor possível na situação ideal, isto é, quando

apenas uma classe está presente no conjunto de objetos que se deseja avaliar e o maior valor na situação mais indesejável, quando as duas classes estão presentes no conjunto de objetos na mesma proporção (MATOS, 2003).

O índice Gini é calculado da seguinte forma, para um conjunto de objetos contendo n classes diferentes:

$$I(C) = 1 - \sum_{j=1}^n p_j^2,$$

onde p_j é a probabilidade de ocorrência dos elementos da classe de objetos j em C .

Observando as perguntas existentes no Exemplo 4.4, podemos verificar a existência de duas classes:

- Classe 1: mensagens cuja resposta é 1;
- Classe 2: mensagens cuja resposta é não 1.

Nº	Mensagem	Resposta
1	Quando estarão enviando o material ?	1
2	O material ainda não chegou pra mim, vai demorar pra vir?	1
3	Até o momento não recebemos o material	1
4	Informamos a equipe Desafio SEBRAE, que estamos no aguardo do material .	1
5	Gostaríamos de saber em quanto tempo estaremos recebendo o material , e se é um só para todos ou um para cada membro da equipe.	1
6	Meu nome é Diogo Costa da equipe 1 e ainda não recebi o meu material , apesar de todos os outros componentes do grupo terem recebido. Gostaria de saber quais os procedimentos a serem tomados. Obrigado.	1
7	Um dos integrantes da minha equipe ainda não recebeu o material . Gostaria de saber como proceder.	1
8	Fiz o pagamento através de boleto bancário e ainda não recebi o material , gostaria de saber o motivo.	1
9	Infelizmente ocorreu erro na execução do software, de modo que após a sua completa instalação, a tela do computador fica toda preta, e nada acontece. No aguardo da ajuda necessária, agradecemos.	4

Nº	Mensagem	Resposta
10	Gostaríamos de saber se é possível instalar o programa em outra máquina, pois temos problemas de áudio com a máquina atual, dificultando o entendimento do programa.	3
11	Gostaríamos de saber quando começará o aquecimento	2
12	Não recebemos nenhum material do aquecimento, ele já está acontecendo? Gostaríamos de participar	2

Exemplo 4.4: Perguntas contidas na base de conhecimento

Analisando a Tabela 4.2 e utilizando as mensagens do Exemplo 4.4, vimos que a probabilidade de uma mensagem ser da *classe 1* é de 67% e a probabilidade de ser da *classe 2* é de 33%, logo o índice Gini é:

$$I(C) = 1 - (0,33^2 + 0,67^2) = 0,44$$

Classes	Quantidade	%
1	8	67%
2	4	33%
Total	12	100%

Tabela 4.2: Cálculo do índice Gini

Para que o índice Gini possa nos auxiliar na escolha dos grupos de fonemas que irão ser utilizados na construção do modelo quantitativo, precisamos definir uma métrica de diminuição de diversidade. Neste sentido adotamos a mesma métrica $\Delta i(C)$ utilizada por *Breiman et al.* (1984), isto é:

$$\Delta i(C) = p_C * i(C) - p_E * i(C_E) - p_D * i(C_D),$$

onde:

- C é um conjunto de valores;
- C_E é um subconjunto do ramo esquerdo;

- C_D é um subconjunto do ramo direito;
- p_C é a proporção de elementos em C ;
- p_E é a proporção de elementos em C_E ;
- p_D é a proporção de elementos em C_D .

Neste sentido, cada grupo de fonemas que representam um *token* irá dividir o conjunto de elementos C em dois subconjuntos, o da esquerda C_E e o da direita C_D , e a partir destes subconjuntos é possível calcular o valor de diminuição da diversidade $\Delta i(C)$.

Por exemplo, utilizando as mensagens do Exemplo 4.4 e analisando a Figura 4.12, é possível verificar que a transcrição fonológica (ou grupo de fonemas) “/sabeR/” divide o conjunto de mensagens C em dois subconjuntos: C_E definido como o subconjunto das mensagens que possuem a transcrição fonológica “/sabeR/” e C_D caracterizado como o subconjunto das mensagens que não possuem esta transcrição fonológica.

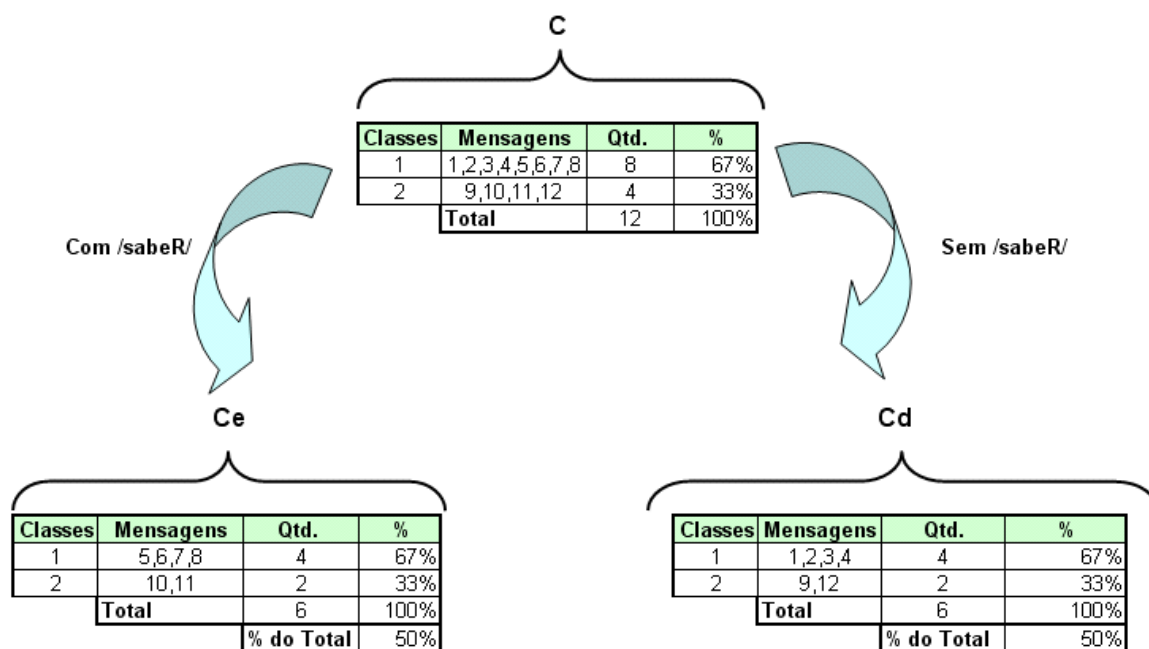


Figura 4.12: Separação de duas classes por um grupo de fonemas

Uma vez separados os subconjuntos C_E e C_D , são verificadas, em cada um deles, as probabilidades de ocorrência dos elementos da *classe 1* e da *classe 2*. Posteriormente, são calculados o valor do índice Gini para cada subconjunto e, finalmente, é determinado o valor de diminuição de diversidade $\Delta i(C)$, como pode ser visto na Figura 4.13.

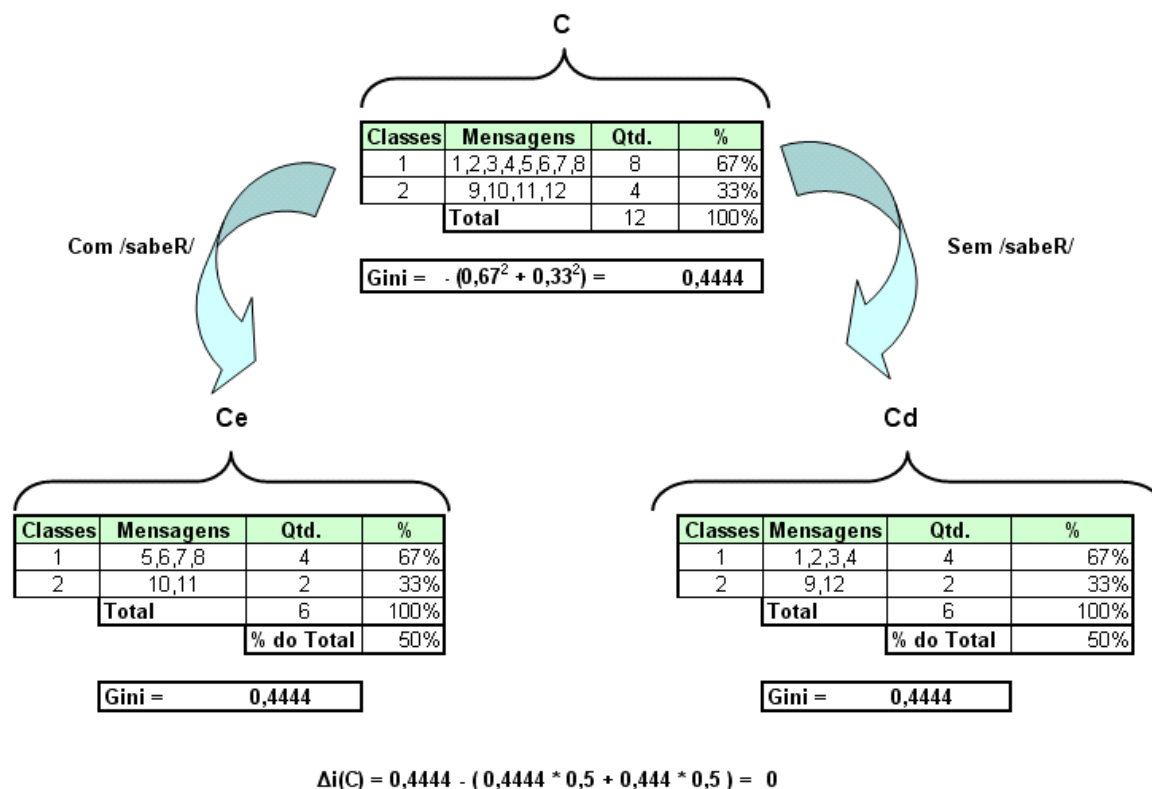


Figura 4.13: Valor de diminuição da diversidade para a transcrição '/sabeR/'

No exemplo anterior, foi calculado o valor de diminuição de diversidade associada à *resposta 1* para a transcrição “/sabeR/”. O mesmo processo realizado para esta transcrição deve ser feito para todos os outros grupos de fonemas relevantes existentes nas mensagens associadas à *resposta 1*. Como por exemplo, o grupo de fonemas “/materiaw/”, ilustrado na Figura 4.14.

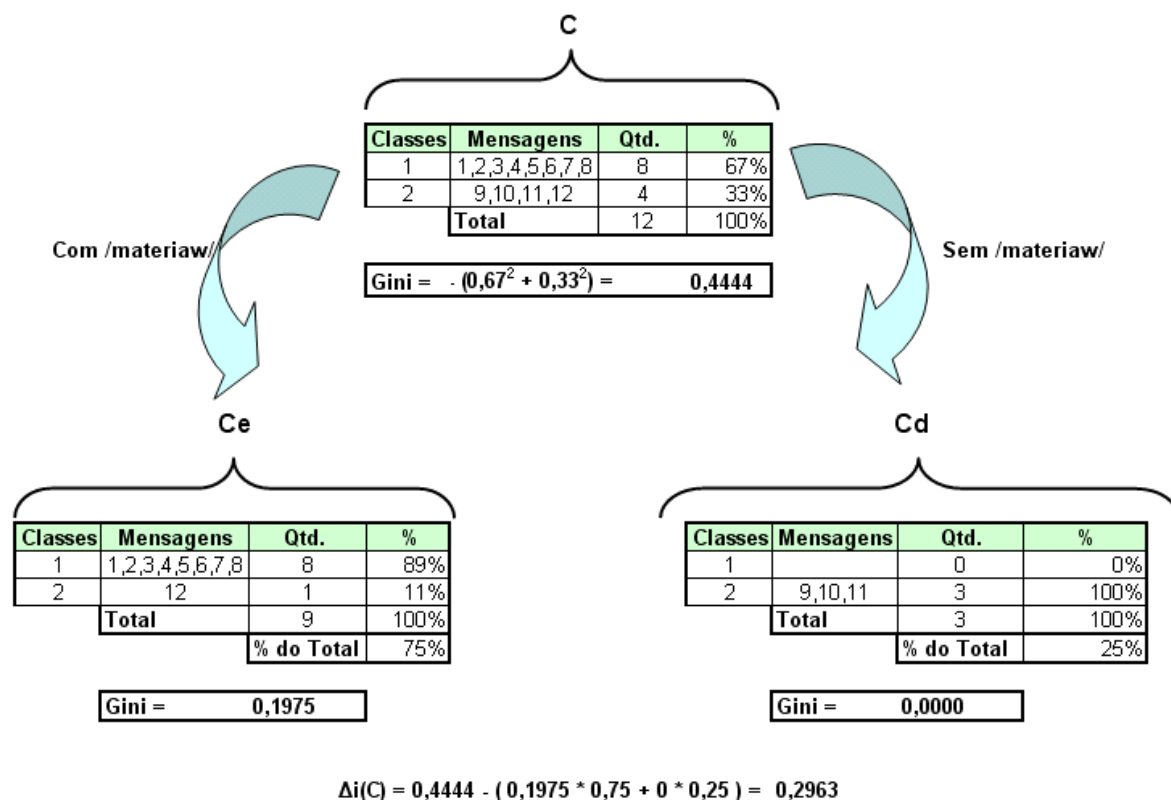


Figura 4.14: Valor de diminuição da diversidade para a transcrição /materiaw/

Como pode ser observado nas Figuras 4.13 e 4.14, a transcrição fonológica “/materiaw/” possui, em relação a *classe 1*, um valor de diminuição de diversidade maior ($\Delta i(C) = 0,2963$) do que a transcrição “/sabeR/”, onde o seu $\Delta i(C)$ é igual a zero.

Isso significa que a transcrição “/materiaw/” tem um poder de discriminação maior sobre as mensagens da *classe 1* do que a transcrição “/sabeR/”.

Uma vez calculadas todas os valores de diminuição de diversidade relacionadas a *resposta 1*, é possível então selecionar um determinado número de palavras que possuem o maior valor $\Delta i(C)$, ou seja, são selecionados os grupos de fonemas com o maior poder de separação entre a classe das mensagens de *resposta 1* e a classes das mensagens de *resposta não 1*. Este processo é realizado com todas as respostas existentes na base de conhecimento fornecida pelos organizadores do Desafio SEBRAE.

A combinação destes grupos de fonemas com o maior poder de discriminação constitui o conjunto dos grupos de fonemas relevantes necessários para a construção do modelo quantitativo. A escolha de quantos grupos seriam selecionados para cada resposta foi realizada de acordo com os experimentos relatados no Capítulo 5.

4.4.7 Codificação

Depois de selecionar os grupos de fonemas mais importantes para o modelo quantitativo é necessário representá-los de forma que possam ser interpretados pela rede neural, possibilitando que ela entenda quais são os grupos de fonemas relevantes que compõem cada mensagem.

O processo de codificação resume-se em transformar cada grupo de fonemas relevantes em uma variável de entrada da rede, cujo valor é definido como sendo 1, se o grupo estiver presente na mensagem, e 0, caso contrário.

No Exemplo 4.5, é apresentado um exemplo da codificação dos fonemas relevantes. Neste exemplo, foram selecionados os grupos de fonemas “/materiaw/” e “/akesimêtu/”, a partir das três mensagens apresentadas na tabela abaixo.

Mensagem	Variáveis de Entrada		Variável de Saída
	/materiaw/	/akesimêtu/	Resposta
Gostaria de saber quando estarão enviando o material?	1	0	1
Gostaríamos de saber quando começará o aquecimento	0	1	2
Ainda não recebemos o material	1	0	1

Exemplo 4.5: Codificação dos grupos de fonemas relevantes

Como o objetivo deste trabalho é classificar as mensagens enviadas pelos participantes de Desafio SEBRAE, ou seja, prever qual resposta estaria associada a uma mensagem, foi utilizado o treinamento supervisionado. Neste sentido, é necessário, além das variáveis de entrada, as variáveis de saída que, neste caso, são as respostas a cada mensagem.

Uma vez formado a bases de dados com as variáveis de entrada, fonemas, e a variável de saída, respostas, a etapa de manipulação dos dados está finalizada passando para a etapa de treinamento.

4.5 Especificação da Rede Neural

O modelo de redes neurais adotado, para avaliar a capacidade de discriminação da técnica proposta de extração de características, foi o MLP, treinado com o algoritmo de retro-propagação do erro (*error back-propagation*).

Em todos os nossos experimentos foi criada uma rede neural totalmente conectada com uma arquitetura possuindo:

- Uma entrada formada pelos fonemas escolhidos na etapa de seleção das palavras mais relevantes;
- Uma única camada escondida de neurônios e
- Uma camada de saída formada por 6 variáveis que correspondem a cada uma das possíveis respostas fornecidas pelo modelo.

Como o problema em questão é de classificação de padrões, segundo Maren *et.al.* (*apud* SILVA, 2002) a utilização de apenas uma camada escondida é considerada suficiente.

Para a escolha do número de neurônios na camada escondida, utilizamos como ponto inicial a heurística defendida por Maren *et.al.* (*apud* Silva, 2002), ou seja, a média geométrica²⁰ entre o número de entradas e de saídas da rede. Em outras palavras, o número de neurônios da camada escondida era, a fim de obter um melhor resultado, em torno do valor desta média geométrica.

Além disto, a ferramenta estatística escolhida permite tanto a construção da rede neural como o seu treinamento. Para realizar o treinamento da rede neural, os dados resultantes do processo de manipulação da seção 4.4 foram divididos em

²⁰ A média geométrica entre x e y, é definida como a raiz quadrada do produto de x por y ($\sqrt{x.y}$).

dois subconjuntos distintos: treinamento e teste, para ser mais exato, utilizamos para o treinamento 70% das 1.596 mensagens disponibilizadas pelos organizadores do desafio e 30% para a avaliação deste treinamento.

4.6 Ferramentas Utilizadas

Neste trabalho, foram utilizadas algumas ferramentas para auxiliar o processamento de cada uma das etapas descritas neste capítulo e, por conseguinte, promover o desenvolvimento do modelo quantitativo proposto.

As ferramentas empregadas foram basicamente voltadas para o armazenamento e manipulação das informações, como mensagens e respostas, fornecidas pelos organizadores do Desafio SEBRAE.

Nas etapas de armazenamento foi utilizada a ferramenta Microsoft Access 2002, onde por meio do uso das tabelas e índices, os dados puderam ser armazenados e gerenciados de forma a prover consultas otimizadas.

As etapas de manipulação foram realizadas através dos módulos implementados na linguagem Visual Basic For Application (VBA) no Microsoft Access 2002 apoiada pela linguagem de consulta SQL.

Ao final, para a fases de construção e treinamento da rede neural foi utilizada a ferramenta PRW, desenvolvida pela empresa Unica (<http://www.unica.com/>). Com o objetivo de realizar estas duas etapas, foi necessário exportar os dados armazenados no Access para uma planilha da aplicação Microsoft Excel 2002 e, posteriormente, importá-los para a ferramenta PRW.

Em resumo, são apresentadas, na Tabela 4.3, as ferramentas utilizadas em cada etapa de nosso processo de construção do modelo quantitativo e a descrição de como foi empregada cada ferramenta.

Etapa	Descrição	Ferramenta
Obtenção dos dados	Armazenamento	Microsoft Access 2002
Manipulação das mensagens		
Manipulação das respostas		
Tokenização	Manipulação	Microsoft Access 2002 + Módulo em VBA + Linguagem de consulta SQL
Tradução		
Transcrição fonológica		
Redução dos verbos		
Retirada das <i>Stop Words</i>		
Seleção das palavras relevantes		
Codificação		
Treinamento da rede neural	Manipulação + Treinamento	Microsoft Access 2002 + Microsoft Excel 2002 + PRW

Tabela 4.3: Ferramentas utilizadas na construção do modelo quantitativo

CAPÍTULO 5. ANÁLISE DOS RESULTADOS

Neste capítulo, são apresentados os resultados obtidos pelo sistema de resposta automática via *web* proposto neste trabalho.

Para que possamos avaliar de forma clara o sistema proposto no escopo desta dissertação, é necessário levarmos em consideração que se trata de um sistema híbrido, onde um modelo matemático e os operadores de *telemarketing* atuam em conjunto para que a resposta adequada a uma pergunta formulada por um participante do desafio seja disponibilizada o mais rápido possível.

Neste sentido existem duas questões que precisam ser consideradas. A primeira diz respeito ao subconjunto de perguntas que o modelo matemático se propõe a responder. A segunda diz respeito às mensagens que os operadores de *telemarketing* são solicitados a responderem.

No primeiro caso, o modelo desenvolvido se propõe a fornecer respostas que tenham uma probabilidade alta de estarem corretas, sendo as demais passadas para o operador, que se encarrega de respondê-las. No segundo caso, assumimos, no escopo desta tese, que o operador sempre fornecerá uma resposta correta.

Existem, portanto, três perspectivas importantes para avaliação do sistema de resposta automática, a saber:

- A perspectiva do participante do Desafio SEBRAE – que deseja receber a resposta correta a suas perguntas no menor tempo possível.

Observe que, do ponto de vista do participante do desafio, não importa se a resposta fornecida a uma pergunta foi elaborada pelo modelo ou pelo operador, desde que esteja correta.

- A perspectiva do gestor do Desafio SEBRAE – que deseja utilizar o menor número de operadores possíveis, mantendo um elevado padrão de acerto (qualidade) nas respostas que são fornecidas aos participantes do desafio.

Diante desta perspectiva, uma taxa de erro maior pode ser tolerada desde que compensada pela redução de custo propiciada pela diminuição do número de operadores e pelo aumento da velocidade das respostas fornecidas.

- A perspectiva do desenvolvedor do modelo matemático – que deseja avaliar a precisão do modelo diante das respostas que ele se propõe a responder.

Neste caso os fatos relevantes são o percentual de respostas que o modelo se propõe a responder e a taxa de acerto destas respostas.

No decorrer do processo de avaliação do sistema de resposta automática desenvolvido no escopo desta dissertação estaremos sempre utilizando o ponto de vista do participante do Desafio SEBRAE, que é para quem, em última instância, o sistema foi desenvolvido.

Entretanto, onde for relevante, discutiremos o impacto dos erros e acertos propiciados pelo sistema tanto diante da perspectiva do gestor do desafio, quanto do desenvolvedor.

5.1 Melhor Resultado

Quando realizamos todas as etapas do processo de preparação dos dados, descritas no Capítulo 4, obtivemos uma taxa de acerto de 94,2% sobre as 479 mensagens utilizadas na avaliação do sistema de resposta automática, como pode ser visto na Tabela 5.1.

Respostas	Nº	%
Corretas	451	94,2
Erradas	28	5,8
Total	479	100,0

Tabela 5.1: Melhor resultado obtido no sistema de resposta automática

Neste caso, uma resposta fornecida pela rede foi considerada correta quando ela concordava com a resposta contida na base de conhecimento disponibilizada pelos organizadores do Desafio SEBRAE.

A taxa de acerto de 94% foi alcançada utilizando uma rede neural MLP composta por 50 variáveis de entrada, 6 variáveis de saída e uma camada escondida com 19 neurônios, cuja função resultante deste treinamento está localizada no Anexo II.

As palavras que deram origem aos fonemas utilizados na construção da rede neural estão relacionadas no Anexo III.

5.2 Processo de Seleção do Melhor Modelo

A fim de selecionar uma quantidade mínima de fonemas relevantes que proporcionam a construção de um modelo com um alto grau de precisão na classificação das mensagens enviadas ao desafio, foram realizados 5 experimentos, onde em cada um deles foi alterada a quantidade de fonemas relevantes selecionados para cada resposta, vide Tabela 5.2.

Experimento	Nº de Fonemas por Resposta	Total de Fonemas
1	5	23
2	8	33
3	10	38
4	12	44
5	15	50

Tabela 5.2: Número de fonemas relevantes selecionados por experimento

Note que algumas respostas estão associadas a um mesmo fonema relevante, e, por conseguinte, o número total de fonemas não é o resultado da multiplicação do número de respostas pelo número de fonemas selecionados para cada resposta.

Por exemplo, no experimento 1 foram escolhidos para cada resposta os 5 primeiros fonemas com maior poder de discriminação, obtendo uma quantidade total de 23 fonemas relevantes.

Ao analisarmos os resultados obtidos nos experimentos realizados, sob a perspectiva do participante do desafio, vide Tabela 5.3, verificamos que a diferença entre a pior e a melhor taxa de acerto, mais exatamente, a diferença entre a taxa de acerto do experimento 1 com o experimento 5, foi de 1,5%.

Respostas	Experimentos (Perspectiva do Participante do Desafio)									
	1		2		3		4		5	
	Nº	%	Nº	%	Nº	%	Nº	%	Nº	%
Corretas	444	92,70	449	93,7	446	93,10	451	94,2	451	94,2
Erradas	35	7,30	30	6,30	33	6,90	28	5,8	28	5,8
Total	479	100,0	479	100,0	479	100,0	479	100,0	479	100,0

Tabela 5.3: Resultados obtidos sob a perspectiva do participante

No entanto, sob a perspectiva do desenvolvedor do modelo matemático, vide Tabela 5.4, das mensagens 479 mensagens enviadas ao sistema, o modelo do experimento 1 se propôs a responder 475 mensagens onde 87,8% delas foram respondidas corretamente. Já no experimento 5, o modelo se encarregou de responder 477 mensagens das quais 92,5% foram respondidas de forma correta.

Respostas	Experimentos (Perspectiva do Desenvolvedor do Modelo Matemático)									
	1		2		3		4		5	
	Nº	%	Nº	%	Nº	%	Nº	%	Nº	%
Corretas	417	87,8	430	90,5	430	90,3	437	91,8	441	92,5
Erradas	58	12,2	45	9,5	46	9,7	39	8,2	36	7,5
Respondidas pelo Modelo	475	100,0	475	100,0	476	100,0	476	100,0	477	100,0

Tabela 5.4: Perspectiva do desenvolvedor do modelo matemático

Assim, apesar de haver apenas uma pequena diferença entre as taxas de acerto dos experimentos 1 e 5, sob o ponto de vista do participante do desafio, ao analisarmos estes experimentos sob a perspectiva do desenvolvedor do modelo, verificamos que no experimento 5 o número de mensagens respondidas pelo modelo foi maior do que as respondidas no experimento 1.

Note que o mesmo ocorre entre os experimentos 4 e 5, que possuem taxas de acertos semelhantes, sob a perspectiva do participante. Porém, sob o ponto de vista do desenvolvedor do modelo matemático e do gestor do desafio, o experimento 5 possui taxas de acertos superiores aos obtidos no experimento 4, vide Tabelas 5.4 e 5.5, respectivamente.

Respostas	Experimentos (Perspectiva do Gestor do Desafio)										
	1		2		3		4		5		
	Nº	%	Nº	%	Nº	%	Nº	%	Nº	%	
Enviadas ao Operador	47	9,8	37	7,7	41	8,6	37	7,7	30	6,3	
Respondidas pelo Sistema	432	90,2	442	92,3	438	91,4	442	92,3	449	93,7	
Total	479	100,0	479	100,0	479	100,0	479	100,0	479	100,0	
Respondidas pelo Sistema	Total	432	100,0	442	100,0	438	100,0	442	100,0	449	100,0
	Corretas	397	91,9	412	93,2	405	92,5	414	93,7	421	93,8
	Erradas	35	8,1	30	6,8	33	7,5	28	6,3	28	6,2

Tabela 5.5: Perspectiva do gestor do desafio

Comparando novamente os resultados dos experimentos 1 e 5, mas agora sob a perspectiva do gestor do desafio, verificamos que no experimento 5, o operador foi encarregado de responder 6,3% das mensagens enviadas ao sistema. Já no experimento 1, o operador foi solicitado a responder 9,8% das mensagens. Aumentando assim, o custo do gestor do desafio sob o ponto de vista financeiro para manter a qualidade do serviço. Vide Tabela 5.5.

Ao realizar experimentos com mais de 15 fonemas relevantes associados a cada resposta concluímos que a precisão do modelo permanecia sem grandes variações, apesar da complexidade da rede MLP aumentar. Por isso, o último experimento relatado neste trabalho é o que utilizou para cada resposta os 15 primeiros fonemas relevantes com o maior poder de discriminação.

Por exemplo, sob o ponto de vista do desenvolvedor do modelo matemático, ao realizar um experimento com 15 fonemas relevantes associados a cada resposta, somando um total de 50 fonemas, obtemos uma taxa de acerto de 92,5%. Vide Tabela 5.6.

Respostas	Experimentos (Perspectiva do Desenvolvedor do Modelo Matemático)			
	Com 50 fonemas		Com 56 fonemas	
	Nº	%	Nº	%
Corretas	441	92,5	437	92,4
Erradas	36	7,5	36	7,6
Respondidas pelo Modelo	477	100,0	473	100,0

Tabela 5.6: Perspectiva do desenvolvedor do modelo por número de fonemas

Já quando realizamos o experimento com 17 fonemas relevantes relacionados com cada resposta, mais exatamente 56 fonemas, obtivemos uma taxa de acerto de 92,4%.

5.3 Variações no processo de construção do modelo quantitativo

Com o intuito de verificar a contribuição das diversas etapas de preparação dos dados para o modelo desenvolvido para o sistema de resposta automática, realizamos, nesta seção, variações no processo de preparação dos dados, através da remoção de etapas específicas, a saber:

- Tradução;
- Transcrição fonológica;
- Redução dos verbos aos seus respectivos infinitivos.

A remoção de cada uma destas etapas específicas constitui um experimento. Neste sentido, a análise sobre a contribuição de cada etapa para o modelo é realizada comparando os resultados de cada um dos três experimentos com o experimento 5 da seção 5.2, onde foi obtido o melhor resultado sob a perspectiva do participante do desafio.

Para que fosse possível comparar o efeito da remoção de cada uma das etapas, a retirada de uma etapa específica de preparação dos dados foi seguida

pela re-seleção de palavras relevantes, mantendo-se, entretanto o mesmo número de variáveis de entrada e de neurônios da camada escondida.

5.3.1 Etapa de Tradução

Para efeito de análise, removemos a etapa de tradução de idiomas e siglas para verificar quão influente ela é na precisão do modelo quantitativo. A Tabela 5.7 ilustra, sob a perspectiva do participante do desafio, dois experimentos, a saber:

- o primeiro é o experimento 5 da seção 5.2, ou seja, aquele que contém a etapa de tradução e que nos forneceu o resultado mais preciso e
- o segundo contém uma rede neural equivalente ao do experimento 5 sem que a etapa de tradução de palavras tenha sido executada no processo de preparação dos dados.

Respostas	Experimentos (Perspectiva do Participante do Desafio)			
	Com Tradução		Sem Tradução	
	Nº	%	Nº	%
Corretas	451	94,2	448	93,5
Erradas	28	5,8	31	6,5
Total	479	100,0	479	100,0

Tabela 5.7: Tradução sob a perspectiva do participante

É possível observar através da Tabela 5.7 que ao removermos a etapa de tradução do processo de preparação dos dados, houve uma diminuição da taxa de acerto quando analisamos o sistema de resposta automática sob o ponto de vista do participante do desafio.

Além disso, podemos verificar que não somente esta taxa de acerto diminuiu sob o ponto de vista do participante, mas também ocorreu o aumento do número de mensagens encaminhadas ao operador, vide na Tabela 5.8.

Respostas		Experimentos (Perspectiva do Gestor do Desafio)			
		Com Tradução		Sem Tradução	
		Nº	%	Nº	%
Enviadas ao Operador		30	6,3	40	8,4
Respondidas pelo Sistema		449	93,7	439	91,6
Total		479	100,0	479	100,0
Respondidas pelo Sistema	Total	449	100,0	439	100,0
	Corretas	421	93,8	408	92,9
	Erradas	28	6,2	31	7,1

Tabela 5.8: Tradução sob a perspectiva do gestor do desafio

Uma vez que ao desenvolver o modelo com a etapa de tradução são encaminhadas ao operador apenas 6,3% das mensagens enquanto que com a remoção desta etapa, o operador passa a se encarregar de 8,4% das mensagens enviadas pelos participantes.

Já sob o ponto de vista do desenvolvedor do modelo matemático, verificamos uma diminuição de 1,3% (92,5% - 91,2%) no número de mensagens respondidas corretamente pelo modelo. Vide Tabela 5.9.

Respostas		Experimentos (Perspectiva do Desenvolvedor do Modelo Matemático)			
		Com Tradução		Sem Tradução	
		Nº	%	Nº	%
Corretas		441	92,5	434	91,2
Erradas		36	7,5	42	8,8
Respondidas pelo Modelo		477	100,0	476	100,0

Tabela 5.9: Tradução sob a perspectiva do desenvolvedor do modelo

Esta pequena diminuição da precisão pode ser explicada pela existência nas mensagens que fazem parte da base de conhecimento de uma pequena quantidade de palavras em idiomas estrangeiros e na forma de siglas. Em outras palavras, pelo fato de existir na nossa base de conhecimento apenas 74 palavras estrangeiras e siglas, a etapa de tradução não teve a importância que esperávamos que tivesse originalmente.

Entretanto, podemos supor que se nesta base de conhecimento houvesse um volume maior de palavras em outros idiomas ou sob forma de siglas, a etapa de tradução teria uma importância mais significativa no processo de preparação dos dados.

5.3.2 Etapa de Transcrição Fonológica

O principal objetivo da etapa de transcrição fonológica é remover pequenos erros gramaticais existentes nas mensagens enviadas ao desafio. Ao realizar um experimento sem esta etapa no processo de preparação dos dados, conseguimos os resultados disponibilizados na Tabela 5.10.

Respostas	Experimentos (Perspectiva do Participante do Desafio)			
	Com Transcrição		Sem Transcrição	
	Nº	%	Nº	%
Corretas	451	94,2	454	94,8
Erradas	28	5,8	25	5,2
Total	479	100,0	479	100,0

Tabela 5.10: Transcrição sob a perspectiva do participante

Analisando a Tabela 5.10, sob a perspectiva do participante do desafio, verificamos que removendo a etapa de transcrição fonológica, obtivemos uma taxa de precisão melhor do que quando utilizamos esta etapa.

No entanto, embora a taxa de acerto seja maior sob o ponto de vista do participante do desafio no experimento sem a etapa de transcrição, ao analisarmos os experimentos sob o ponto de vista do gestor do desafio, notamos que o operador de *telemarketing* do experimento sem a etapa de transcrição foi encarregado de responder 9,4% das mensagens enviadas ao sistema. Enquanto que no experimento construído com esta etapa, o operador respondeu apenas 6,3% das mensagens. Vide Tabela 5.11.

Respostas	Experimentos (Perspectiva do Gestor do Desafio)				
	Com Transcrição		Sem Transcrição		
	Nº	%	Nº	%	
Enviadas ao Operador	30	6,3	45	9,4	
Respondidas pelo Sistema	449	93,7	434	90,6	
Total	479	100,0	479	100,0	
Respondidas pelo Sistema	Total	449	100,0	434	100,0
	Corretas	421	93,8	409	94,2
	Erradas	28	6,2	25	5,8

Tabela 5.11: Transcrição sob a perspectiva do gestor do desafio

Se observarmos os experimentos sob a perspectiva do desenvolvedor do modelo matemático, verificamos que eles possuem taxas de acertos muito próximas. Vide Tabela 5.12.

Respostas	Experimentos (Perspectiva do Desenvolvedor do Modelo Matemático)			
	Com Transcrição		Sem Transcrição	
	Nº	%	Nº	%
Corretas	441	92,5	434	91,6
Erradas	36	7,5	40	8,4
Respondidas pelo Modelo	477	100,0	474	100,0

Tabela 5.12: Transcrição sob a perspectiva do desenvolvedor do modelo

O fato dos experimentos apresentados na Tabela 5.12 possuírem taxas de acertos próximas pode ser explicado analisando-se um dos pré-requisitos definidos pelos organizadores do Desafio SEBRAE para os candidatos que desejam participar do jogo, ou seja, para se inscrever no Desafio SEBRAE o estudante deve estar matriculado em alguma Instituição de Ensino Superior, credenciada pelo MEC.

Neste sentido, através deste pré-requisito podemos supor que os participantes do desafio possuem um bom nível cultural e, conseqüentemente, o número de erros nas mensagens enviadas pelos participantes é supostamente pequeno. Portanto, a etapa de transcrição fonológica é pouco utilizada no processo de preparação dos dados.

No entanto, se um dia os organizadores do Desafio SEBRAE não mais exigirem este pré-requisito dos candidatos, o número de erros pode aumentar significativamente e, por conseguinte, etapa de transcrição fonológica terá uma contribuição mais efetiva no processo de preparação dos dados.

5.3.3 Redução dos Verbos aos seus Infinitivos

Remover a etapa de redução dos verbos no infinitivo implica em manter todos os verbos nos seus tempos e conjugações verbais originais. Isso pode influenciar a classificação das mensagens uma vez que uma mesma pergunta pode ser escrita com um mesmo verbo, mas este expresso em um tempo ou em uma conjugação verbal diferente.

Na Tabela 5.13 estão representados, sob a perspectiva do participante do desafio, os resultados obtidos no experimento realizado sem a etapa de redução dos verbos.

Respostas	Experimentos (Perspectiva do Participante do Desafio)			
	Com Redução		Sem Redução	
	Nº	%	Nº	%
Corretas	451	94,2	451	94,2
Erradas	28	5,8	28	5,8
Total	479	100,0	479	100,0

Tabela 5.13: Redução dos verbos sob a perspectiva do participante

Embora, sob a perspectiva do participante do desafio, os experimentos parecem ser análogos pelo fato de suas taxas de acerto estarem muito próximas, ao analisarmos os experimentos sob o ponto de vista do gestor do desafio, verificamos que quando removemos a etapa de redução dos verbos, o operador passou a ficar encarregado de responder 3,9% (10,2% - 6,3%) a mais de mensagens do que no modelo construído com a etapa de redução. Vide Tabela 5.14.

Respostas	Experimentos (Perspectiva do Gestor do Desafio)				
	Com Redução		Sem Redução		
	Nº	%	Nº	%	
Enviadas ao Operador	30	6,3	49	10,2	
Respondidas pelo Sistema	449	93,7	430	89,8	
Total	479	100,0	479	100,0	
Respondidas pelo Sistema	Total	449	100,0	430	100,0
	Corretas	421	93,8	402	93,5
	Erradas	28	6,2	28	6,5

Tabela 5.14: Redução dos verbos sob a perspectiva do gestor do desafio

Se observarmos os experimentos sob a perspectiva do desenvolvedor do modelo matemático, vide Tabela 5.15, podemos verificar que, aparentemente, o poder de discriminação dos tempos verbais não foi tão relevante. Uma vez que a precisão do modelo não é significativamente afetada quando esta etapa foi utilizada

Respostas	Experimentos (Perspectiva do Desenvolvedor do Modelo Matemático)			
	Com Redução		Sem Redução	
	Nº	%	Nº	%
Corretas	441	92,5	431	92,8
Erradas	36	7,5	43	7,2
Respondidas pelo Modelo	477	100,0	474	100,0

Tabela 5.15: Redução dos verbos sob a perspectiva do desenvolvedor do modelo

Uma explicação para isto decorre do fato da maior parte dos verbos existentes nas perguntas estarem no futuro, como é visto nas mensagens apresentadas na Figura 5.1, retiradas da nossa base de conhecimento.

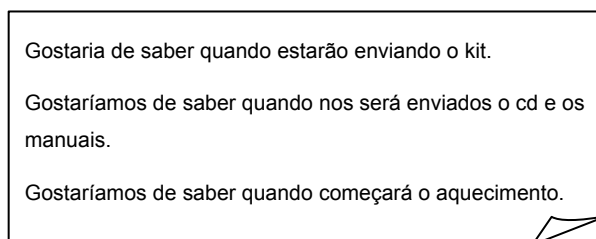


Figura 5.1: Perguntas contidas na base de conhecimento

5.3.4 Sumário

Nesta seção fizemos uma comparação entre os experimentos realizados sobre cada uma das etapas específicas do processo de preparação dos dados para avaliar qual seria o melhor experimento sob a perspectiva do participante do desafio, do gestor do desafio e do desenvolvedor do modelo matemático.

Sob a perspectiva do participante do desafio, verificamos que o experimento realizado sem a etapa de transcrição fonológica foi o que obteve o melhor resultado. Vide Tabela 5.16.

Respostas	Experimentos (Perspectiva do Participante do Desafio)							
	Todas as etapas		Sem Tradução		Sem Transcrição		Sem Redução	
	Nº	%	Nº	%	Nº	%	Nº	%
Corretas	451	94,2	448	93,5	454	94,8	451	94,2
Erradas	28	5,8	31	6,5	25	5,2	28	5,8
Total	479	100,0	479	100,0	479	100,0	479	100,0

Tabela 5.16: Análise geral sob a perspectiva do participante do desafio

Já sob o ponto de vista do gestor do desafio, assim como do desenvolvedor do modelo matemático, identificamos que o experimento com todas as etapas é o que propiciou o maior número de mensagens respondidas corretamente e também é o que necessitou do menor número de operadores para responder as mensagens enviadas pelos participantes. Vide Tabelas 5.17 e 5.18.

Respostas	Experimentos (Perspectiva do Gestor do Desafio)								
	Todas as etapas		Sem Tradução		Sem Transcrição		Sem Redução		
	Nº	%	Nº	%	Nº	%	Nº	%	
Enviadas ao Operador	30	6,3	40	8,4	45	9,4	49	10,2	
Respondidas pelo Sistema	449	93,7	439	91,6	434	90,6	430	89,8	
Total	479	100,0	479	100,0	479	100,0	479	100,0	
Respondidas pelo Sistema	Total	449	100,0	439	100,0	434	100,0	430	100,0
	Corretas	421	93,8	408	92,9	409	94,2	402	93,5
	Erradas	28	6,2	31	7,1	25	5,8	28	6,5

Tabela 5.17: Análise geral sob a perspectiva do gestor do desafio

Respostas	Experimentos (Perspectiva do Desenvolvedor do Modelo Matemático)							
	Todas as etapas		Sem Tradução		Sem Transcrição		Sem Redução	
	Nº	%	Nº	%	Nº	%	Nº	%
Corretas	441	92,5	434	91,2	434	91,6	431	92,8
Erradas	36	7,5	42	8,8	40	8,4	43	7,2
Respondidas pelo Modelo	477	100,0	476	100,0	474	100,0	474	100,0

Tabela 5.18: Análise geral sob a perspectiva do desenvolvedor do modelo

A escolha do sistema a ser utilizado no Desafio SEBRAE depende das prioridades a serem estabelecidas pelo gestor do desafio:

- Se a percepção de qualidade do participante vem em primeiro lugar, então o sistema que contém as etapas de tradução e redução dos verbos é a escolha mais adequada dado que forneceu a maior taxa de acerto.
- Por outro lado, se a prioridade para o gestor do desafio é fornecer o maior número de mensagens corretas ao menor custo, ou seja, encarregando o operador de *telemarketing* de responder um menor número de mensagens, então o sistema que contém todas as etapas específicas do processo de preparação dos dados é a escolha lógica, já que provê a maior taxa de acerto, com menor custo.
- Finalmente, do ponto de vista do desenvolvedor do sistema, a configuração que apresenta a maior taxa de acerto é aquela que contém todas as etapas específicas do processo de preparação dos dados. Esta visão coincide com a do gestor do Desafio SEBRAE.

CAPÍTULO 6. CONCLUSÕES E TRABALHOS FUTUROS

6.1 Discussão

Neste trabalho, propusemos a construção de sistemas de resposta automática baseados na tecnologia de redes neurais que sejam capazes de prover um menor tempo de resposta no atendimento à solicitação de informações, uma padronização das respostas, às custas de uma alta taxa de acerto nas respostas enviadas aos clientes. Abaixo, foram levantadas algumas questões chaves sobre o desenvolvimento destes sistemas e seus impactos no mundo dos negócios.

6.1.1 O que é um sistema de resposta automática?

Na medida em que o número de consumidores aumenta em todo o mundo, aumenta também o volume de solicitações de informações direcionadas às organizações que fornecem os produtos e serviços que estes consumidores desejam adquirir (ROSSI, MOTTA, 2003). A natureza destas solicitações é das mais diversas, variando desde a simples necessidade de suporte técnico até a aquisição de novos produtos e serviços, passando por localização de filiais, endereços da rede de assistência técnica autorizada, agendamento de visitas de representantes comerciais, envio de sugestões e reclamações, etc.

Quando uma determinada organização obtém a preferência de compra de um grande número de consumidores, seja pela qualidade de seus produtos ou por condições particulares do mercado (escassez, monopólio, inovação, moda, etc.), ela pode, facilmente, se deparar com uma situação em que seja incapaz de responder, em tempo hábil, a custos competitivos, todas as necessidades de informações de seus clientes.

Por exemplo, em junho de 2001, quando a população de São Paulo passou por um período de racionamento de energia elétrica, os sistemas de atendimento telefônico das principais distribuidoras de energia do Estado de São Paulo, isto é, Eletropaulo, Bandeirante, Elektro e CPFL (Companhia Paulista de Força e Luz), encontraram-se permanentemente congestionados, visto que os consumidores

necessitavam solicitar informações que variavam desde o método de cálculo das metas de consumo, até sugestões de como solicitar a revisão das metas e economizar energia elétrica (ESTADAO, 2001).

Outro exemplo importante aconteceu em 11 de setembro de 2001, quando o mundo assistiu estarecido aos atentados terroristas que atingiram as cidades de Nova Iorque e Washington, assim como as redondezas da cidade de Pittsburgh, nos Estados Unidos. Neste dia, o site da empresa americana CNN (*Cable News Network*) na Internet saiu do ar devido ao grande volume de solicitações de informações de seus clientes (GLOBO, 2001).

Para contornar o problema de excesso de solicitação de informações e manter um bom nível de relacionamento com seus clientes, as organizações têm recorrido a estratégias de toda ordem, tais como: instalação do serviço telefônico de atendimento ao cliente, expansão dos serviços de atendimento telefônico já existente, instalação de unidades de resposta automática para serviços telefônicos (URAs), catálogo de perguntas mais freqüentes, que pode ter sido impresso ou estar disponível para consulta virtual, terceirização, parcial ou total, do serviço de atendimento para empresas especializadas, criação de sites na Internet, etc.

Mais recentemente, a tecnologia de sistemas computadorizados de resposta tem se apresentado como uma alternativa atraente tanto para aumentar a velocidade e capacidade de atendimento das solicitações de informações de clientes e *prospects*²¹, quanto para reduzir os custos de serviços de atendimento ao cliente (SACs). Esta tecnologia permite a criação de sistemas computadorizados que são capazes de detectar a existência de solicitações de informações, identificar corretamente o seu conteúdo e prover, automaticamente, as respostas adequadas a cada solicitação (CHAMPION, 2003).

É importante mencionar que nem toda solicitação de informação irá recair sobre a base de conhecimento do sistema computadorizado. Em situações como estas, o sistema automatizado, em geral, direciona a solicitação de informação para um meio não automatizado, tal como: o operador de *telemarketing*, manual do

²¹ Clientes em potencial.

produto ou serviço, representante comercial mais próximo da empresa, serviço técnico autorizado, etc.

6.1.2 Por que utilizar um sistema de resposta automática via web?

Vivemos no limiar de uma era na qual um número cada vez maior de organizações utiliza a rede mundial de computadores, isto é, a Internet, para comercializar os produtos e serviços que oferecem à sociedade.

Neste sentido, a Internet pode ser utilizada tanto como uma ferramenta para venda direta de produtos e serviços, quanto para o suporte a vendas que foram realizadas por meios mais tradicionais. Por exemplo, o jornal O Globo só pode ser adquirido, efetivamente, nos pontos de venda ou através da subscrição de assinaturas. O site do jornal na Internet é apenas um mero instrumento de suporte a atividade de venda, ainda que extremamente poderoso. Por outro lado, a empresa americana Amazon.com, que se tornou famosa por comercializar livros, CDs, roupas, acessórios, brinquedos, jogos, equipamentos eletrônicos, etc., através da Internet, utiliza a rede mundial de computadores como o único canal de venda disponível para comercialização de seus produtos (DIRECT MARKETING, 1999 e SPECTOR, 2002).

Independente do tipo de estratégia adotada pelas empresas que utilizam a Internet, o aumento do número de internautas em todo o mundo faz com que aumente também a quantidade de solicitações de informações que são efetuadas através da rede mundial de computadores. Afinal, se um produto é comercializado através da Internet, é natural que seus compradores desejem esclarecer as suas dúvidas, anseios e temores através do mesmo canal de comunicação. Em adição, se as características de um produto se encontram descritas na Internet, mesmo que ele não possa ser adquirido através do comércio eletrônico, é natural que seus compradores em potencial desejem direcionar questões relativas ao produto a seus fornecedores, utilizando a Internet como canal de comunicação.

Para atender ao aumento da demanda por informações via Internet, muitas organizações têm optado por oferecer serviços de atendimento on-line na forma de endereços de correio eletrônico (*e-mail*) e serviços de atendimento em tempo real

através de facilidades do tipo *chat*²² com operadores de *telemarketing* (DOUGLAS, 2004 e TOTTY, 2003).

Se uma organização, com presença na Internet, captura a preferência de um grande número de consumidores, ela pode se ver diante de um quadro no qual tenha que aumentar substancialmente sua capacidade de atender à demanda de informação via correio eletrônico ou via *chat*. Como o aumento da capacidade de atendimento via Internet tem impacto direto nos custos das organizações, muitas empresas começam a despertar para a possibilidade de utilizar sistemas de resposta automática via *web*, ou seja, sistemas computadorizados que sejam capazes de detectar, interpretar e responder automaticamente solicitações de informações enviadas pela Internet. Mais comumente estes sistemas atendem a solicitações no formato de texto feitas tanto via correio eletrônico quanto *chat*.

Os principais módulos que compõem um sistema de resposta automática via *web* são:

- Aquisição da solicitação de informações – que obtém uma cópia da solicitação de informação efetuada por um usuário;
- Filtragem – que elimina as palavras com baixo poder de discriminação da resposta a ser fornecida à solicitação de informação;
- Identificação e análise de *tokens* – que qualifica os *tokens* com poder de discriminação da resposta a ser fornecida;
- Identificação da resposta – que seleciona a resposta adequada à solicitação de informações; e
- Envio da resposta via *web* – que transmite a resposta ao solicitante.

²² O serviço de atendimento via *Chat* é uma forma de comunicação onde os usuários trocam informações em tempo real.

6.1.3 Como sistemas de resposta automática via *web* impactam nas estratégias de marketing das organizações?

Os três principais benefícios de um sistema de resposta automática via *web* são: a rapidez do atendimento à solicitação de informações, a padronização da resposta e a capacidade de rastreamento, que possibilita saber que resposta foi fornecida a cada cliente diante de cada solicitação realizada.

A rapidez de atendimento tem reflexo positivo na satisfação do cliente que recebe de imediato uma resposta adequada à pergunta que acaba de efetuar. A padronização da resposta também tem reflexos na satisfação do cliente que observa que, no decorrer do tempo, as respostas que lhe foram oferecidas são as mesmas que foram fornecidas a outros clientes diante de situações semelhantes.

Já a capacidade de rastreamento oferece uma nova dimensão à atividade de suporte de decisões de marketing, uma vez que cada resposta pode ser associada, ao longo do tempo, ao comportamento do cliente frente à organização. Enquanto algumas respostas acabam por influenciar positivamente a propensão do cliente efetuar novas compras no futuro próximo, outras respostas podem ter exatamente o efeito reverso.

A capacidade de se poder distinguir entre os dois tipos de resposta oferece a possibilidade de alteração das respostas que causam dissonância junto ao cliente, favorecendo o processo de compra e satisfação com os produtos adquiridos.

6.1.4 Como os consumidores, em geral, se beneficiam da existência de sistemas de resposta automática via *web*?

Um dos principais benefícios propiciados pela existência da Internet é a possibilidade dos consumidores procurarem, de acordo com sua conveniência, pela melhor oferta dos produtos e serviços que desejam adquirir. Sistemas de resposta automática via *web* favorecem a existência de mecanismos de resposta a questões levantadas naturalmente pelo consumidor durante ou após o processo de compra, que estão disponíveis 24 horas por dia, todos os dias da semana nos 365 dias do ano.

Em adição, na medida em que as organizações passam a responder a questões levantadas pelos seus clientes de forma padronizada e automática, em oposição às respostas mecânicas que são proporcionadas oralmente pelos serviços de atendimento ao cliente, elas acabam se tornando, perante a sociedade e a lei, mais responsáveis pelas respostas que fornecem. Afinal, o erro de uma resposta inadequada concedida por um operador de *telemarketing* ou atendente sempre pode ser atribuído à falha humana ou a incapacidade de compreensão da resposta por parte do consumidor. Por outro lado, em geral, a organização tem mais dificuldade em se eximir da responsabilidade por respostas que, em princípio, podem ser revisadas em minúcia, com grande antecedência.

O aumento da responsabilidade favorece, naturalmente, a clareza e precisão das respostas que são fornecidas, que aliado ao baixíssimo tempo de resposta dos sistemas automatizados, faz com que o consumidor gaste menos tempo na procura das respostas a suas questões.

6.1.5 Por que desenvolver um sistema de resposta automática via *web* para o atendimento aos participantes do Desafio SEBRAE?

O Desafio SEBRAE é um jogo virtual, onde dezenas de milhares de participantes, de todos os estados da federação e de diversos países da América Latina, são submetidos a uma grande variedade situações de decisões de negócio, que ocorrem comumente no dia-a-dia das empresas.

Estas situações, constantemente, suscitam dúvidas nos participantes do jogo. Portanto, no decorrer das diversas etapas do Desafio SEBRAE, seus participantes solicitam um grande volume de informações sobre questões das mais diversas, a saber: alterações cadastrais, dúvidas sobre as regras do jogo, questões sobre a configuração do computador, solicitações de alteração sobre as decisões de jogo tomadas por sua equipe, etc.

Para responder estas questões, em tempo hábil, o SEBRAE disponibiliza uma central de atendimento via *web* com dezenas de operadores, cujo custo precisa ser repassado, de alguma forma, aos participantes do Desafio. O sistema de resposta automática proposto no escopo desta dissertação oferece ao SEBRAE a

oportunidade de prover a mesma qualidade de atendimento aos participantes do Desafio a um custo e tempo de resposta significativamente menores.

Em adição, um sistema de resposta automática via *web* que esteja disponível 24 horas por dia, todos os dias da semana nos 365 dias do ano, oferece aos participantes do Desafio a oportunidade de terem suas questões respondidas de acordo com suas conveniências e possibilidades. É importante lembrar que o Desafio SEBRAE envolve participantes de fusos-horários diferentes tanto no Brasil, quanto nos demais países que participam do jogo.

6.1.6 Como os participantes do Desafio SEBRAE se beneficiam da existência de um sistema de resposta automática via *web*?

O Desafio SEBRAE é um jogo via Internet onde os participantes, do Brasil e dos demais países da América Latina, enviam suas decisões em prazos pré-estipulados para a realização de cada rodada. Segundo as regras do jogo, se uma equipe não encaminhar suas decisões no prazo pré-determinado, respeitando rigorosamente a data e hora limites, ela será automaticamente desclassificada do jogo.

Entretanto, freqüentemente, as decisões que as diversas equipes devem tomar, não são imediatas. Do ponto de vista dos participantes, trata-se, na verdade, de decisões de grande complexidade, que suscitam dúvidas e questionamentos. Muitas destas dúvidas e questionamentos acabam, inevitavelmente, sendo direcionadas através de e-mail ao sistema de *Help-Desk*, disponibilizado pelo Desafio SEBRAE aos participantes do jogo.

Até o momento em que esta dissertação foi escrita, o atendimento proporcionado pelo sistema de *Help-Desk* não era feito em tempo real. Em adição, as questões apresentadas pelos participantes durante a noite, feriados nacionais e finais de semana eram processados, somente, a partir das 9 horas do primeiro dia útil subsequente (FERREIRA, 2004).

Portanto, não é difícil de imaginar que equipes de participantes, premidas pelo tempo, freqüentemente, tinham que tomar decisões vitais para sua sobrevivência no Desafio, sem que questões importantes tivessem sido esclarecidas pela SEBRAE.

Assim, ao utilizar um sistema de resposta automática que esteja disponível 24 horas por dia, todos os dias da semana nos 365 dias do ano, oferece às equipes de participantes do Desafio a oportunidade de terem suas questões respondidas em concordância com suas conveniências e possibilidades. Vale lembrar que o Desafio SEBRAE envolve participantes de fusos-horários diferentes tanto no Brasil, quanto nos demais países da América Latina que participam do jogo.

Além disso, sistemas de resposta automática favorecem a existência de respostas padronizadas com clareza e precisão de conteúdo, que são disponibilizadas com grande rapidez. Tudo isso, facilita a tomada de decisão dos participantes do desafio, tornado o jogo mais competitivo e desafiador.

6.1.7 Por que o modelo de resposta automática é baseado na tecnologia de Redes Neurais?

Redes neurais designam uma família de métodos matemáticos, desenvolvida inicialmente por McCulloch e Pitts (1943) e mais tarde aperfeiçoada por Rosenblatt (1958). Estes métodos espelham a forma de pensar do cérebro humano para efetuar operações, tais como: previsão, distinção entre elementos (classificação de padrões), divisão de elementos em grupos similares (clusterização), associação entre dois ou mais elementos (memória associativa²³), entre outras (BIGUS, 1996).

A vasta literatura que se formou no decorrer dos anos sobre redes neurais aponta entre os principais benefícios propiciados pelo método:

- Capacidade de aprendizado supervisionado ou não supervisionado – as redes neurais são capazes de aprender certo conhecimento por sucessivas apresentações de padrões (experiência), sem a necessidade de explicitar os

²³ O termo memória associativa refere-se ao mapeamento de dois padrões que estejam relacionados na memória. Logo, quando um é encontrado, subseqüentemente, o outro pode ser recordado.

algoritmos para executar uma tarefa. Este aprendizado pode ser do tipo supervisionado, através da observação de um conjunto de exemplos sendo estes com informação das respostas desejadas a cada estímulo; ou não supervisionado, sem apresentação das respostas desejadas (BRAGA, CARVALHO, LUDERMIR, 1998).

- Grande precisão dos resultados fornecidos, tanto para previsão quanto para classificação – os modelos neurais podem captar interações não-lineares complexas entre variáveis, que melhoram a precisão e a robustez das previsões (WEST, 2000).
- Tolerância a ruídos – as redes neurais provêm a habilidade de generalização, sendo capaz de suportar ruídos e imperfeições no ambiente, ainda mantendo o resultado desejado (TARASSENKO, 1998).
- Paralelismo no treinamento e utilização – na fase de treinamento das redes neurais ocorre, em paralelo, o teste de todas as possibilidades de solução. Este teste é realizado através do envio e recebimento de sinais, de forma paralela, entre os diversos nós da rede. Além disso, acontece também o paralelismo na utilização da rede, visando à busca de informação. Isto ocorre, devido à capacidade da rede de receber ao mesmo tempo várias entradas e distribuí-las, de maneira organizada e paralela, reduzindo o tempo de processamento (KROSE, SMAGT, 1996).
- Não linearidade – as redes neurais podem ser treinadas para gerar mapeamentos não lineares e, conseqüentemente, fornecem a vantagem de trabalhar com problemas complexos do mundo real (TARASSENKO, 1998).

As funcionalidades das redes neurais constituem, nos dias de hoje, uma solução real e disponível para resolver uma grande parte dos problemas práticos existentes nos negócios, indústria e ciência (WIDROW *et al. apud* ZHANG, 2003). Dentre esses problemas, podemos citar: previsões financeiras e econômicas, modelagem de processos de fabricação, detecção de falhas em máquinas, autorização de crédito, simulações do comportamento do mercado, etc. (BIGUS, 1996 e TRIPPI, TURBAN, 1996).

Com vistas a resolver problemas dos mais variados, como os mencionados anteriormente, um número cada vez maior de artigos, em jornais relacionados a diversas áreas científicas, vêm sendo publicados. Estes artigos comprovam o interesse crescente dos pesquisadores em redes neurais como uma ferramenta computacional para resolução de problemas (ZHANG, 2003).

Uma das áreas onde a aplicação de redes neurais tem se destacado é a de processamento de texto. A tecnologia de redes neurais está sendo largamente utilizada para o processamento de texto para a resolução de problemas que envolvem o reconhecimento de padrão (MIIKKULAINEN, MAYBERRY, 1999 e SELAMAT, OMATU, 2004).

Neste sentido, os benefícios, descritos anteriormente, em conjunto com o fato da tecnologia de redes neurais estar, atualmente, presente de forma abrangente em aplicações de processamento textual proporcionam fortes incentivos para a escolha da tecnologia de redes neurais, como uma opção apropriada para construção do modelo de resposta automática, objeto desta dissertação.

6.1.8 Em que aspectos o sistema proposto se diferencia de outras propostas na mesma linha de pesquisa?

A despeito dos esforços que empreendemos não nos foi possível localizar outros sistemas de resposta automática baseados no uso de redes neurais artificiais. Neste sentido, este trabalho vem preencher uma lacuna importante nas áreas de mineração de texto e inteligência computacional aplicada.

6.2 Conclusões

Na medida em que o uso da Internet se populariza em todo o mundo, diversificam-se também as várias aplicações as quais a rede mundial de computadores é submetida (GOFF, 1999 e BURGER, 2001). Dentre estas aplicações se destaca o comércio eletrônico que movimenta bilhões de dólares anualmente em serviços e produtos (REYNOLDS, 2004).

Com a popularização da Internet, um volume cada vez maior organizações disponibiliza informações sobre seus produtos e serviços na Internet, com ou se a intenção de se engajarem em atividades de comércio eletrônico, e com isso, cresce também o volume de solicitações de informações sobre os produtos e serviços oferecidos por estas empresas.

Para atender a demanda crescente por informação, muitas empresas estão recorrendo à montagem de serviços de atendimento ao cliente que podem ser acessados via Internet. Embora estes serviços tenham o objetivo de manter o cliente informado, eles possuem três desvantagens importantes: tendem a funcionar dentro de um período reduzido de tempo, a resposta às questões apresentadas pelo usuário varia de acordo com a experiência e habilidade do operador, entre o estabelecimento da conexão e as primeiras interações com operador existe um tempo de latência, que atua como fator de desestímulo ao cliente. Em adição, o custo de manutenção deste tipo de serviço aumenta, na proporção em que aumenta o número de solicitações de informações.

Um sistema de resposta automática surge como uma ferramenta para endereçar estes problemas de forma eficaz e econômica. Ele permite um sistema de atendimento ao cliente funcione 24 horas por dia, todos os dias da semana nos 365 dias do ano, respostas padronizadas e sem um tempo de latência significativo, a não ser aquele inerente à velocidade da conexão, e um custo, para grandes volumes de solicitações, que tende a ser menor do que a de um serviço manual.

Em conseqüência, não nos causaria surpresa se, nos anos que seguem, um número cada vez maior de organizações desenvolvam sistemas de resposta automática, com reflexo positivo tanto na intensidade do relacionamento com seus clientes quanto na valorização da imagem da empresa.

6.3 Sugestões para Trabalhos Futuros

Atualmente, o Desafio SEBRAE disponibiliza aos participantes do jogo um ambiente único para o envio de sugestões, dúvidas e reclamações. Isso possibilita não apenas mensagens com perguntas misturadas com reclamações e parabenizações, mas também perguntas de diferentes assuntos.

Em adição, o fato de neste ambiente não haver um controle sobre tamanho de cada mensagem, permite que o participante não seja objetivo na sua pergunta, acrescentando informações irrelevantes.

Em conseqüência, o operador de *telemarketing* desperdiça uma grande parte do seu tempo lendo frases que não agregam nenhuma informação relevante para a construção de uma resposta ao problema enviado pelo participante.

Em adição, o fato de existir múltiplas perguntas em uma só mensagem onera o tempo de preparação dos dados, uma vez que é necessária a realização da etapa de divisão das mensagens, de forma que cada uma contenha apenas uma pergunta, visando diminuir a complexidade do sistema de resposta automática.

Neste sentido, seria importante encontramos uma forma de criar um ambiente de comunicação, com os participantes do Desafio SEBRAE, que induza o participante a enviar mensagens com apenas um assunto e ao mesmo tempo limitando o tamanho do texto a ser enviado.

Como por exemplo, o ambiente ilustrado na Figura 6.1. Este ambiente é um exemplo de espaço para o envio de mensagens contendo apenas dúvidas, onde é possível selecionar o assunto relacionado a cada mensagem a ser enviada.

[Home](#)
[Fale Conosco](#)
[Perguntas Frequentes](#)
 Login: Senha: [esqueci login/senha](#)

[O Desafio SEBRAE](#)
[O Jogo](#)
[Inscreva-se](#)
[Noticias](#)
[Final Mercosul](#)

DESAFIO SEBRAE 2005

Fale Conosco

Use o Fale Conosco para enviar as suas dúvidas

Nome: * E-mail: *

Assunto: *
Pagamento

Mensagem: *
Gostaria de saber se realmente minha equipe está inscrita, pois efetuamos o pagamento a um tempo e não recebemos a confirmação de inscrição.

*Envie apenas uma pergunta por mensagem

Execução:
 Realização:
 Apoio:
 Patrocínio:

Figura 6.1: Exemplo de ambiente de comunicação com o participante de desafio

Uma outra questão que deve ser considerada é o fato do Desafio SEBRAE estar sendo realizado, desde 2003, em países como Argentina, Chile, Uruguai e Paraguai. Em outras palavras, com a expansão do Desafio SEBRAE para estes países, começam a participar do jogo estudantes latinos que se comunicam através de línguas diferentes do português brasileiro.

Conseqüentemente, torna-se necessário que os operadores de *telemarketing* sejam profissionais mais qualificados em relação à capacidade de interpretar e responder às mensagens escritas em uma língua latina pelas equipes participantes.

Faz-se então necessário que o sistema de resposta automática seja estendido para permitir a sua utilização por usuários de outras línguas, tais como o espanhol.

Além disso, um assunto que requer discussão envolve o fato de nem sempre ser possível aos participantes do Desafio SEBRAE estarem conectados à Internet para tirarem as suas dúvidas.

No entanto, atualmente, a forma como o Desafio SEBRAE está implementado requer que os participantes estejam conectados à Internet não apenas para enviarem as suas decisões, mas também para tirarem as suas dúvidas, sendo que a frequência com que este último evento ocorre é, em geral, bem maior que a do primeiro.

Como o sistema de resposta automática tem um grande poder de simplificação e uma alta taxa de acerto, uma forma de contornar este problema é a integração do sistema de resposta automática ao jogo do Desafio SEBRAE que é instalado localmente na máquina do participante.

Isso permite um aumento na velocidade de resposta às dúvidas enviadas pelos participantes, pelo fato da maior parte delas serem respondidas pelo sistema local de resposta automática. Apenas no caso do sistema não poder responder a alguma dúvida, esta deverá ser enviada remotamente pelo participante, ou seja, via Internet.

CAPÍTULO 7. REFERÊNCIAS BIBLIOGRÁFICAS

1. ASSEF, L.V. **NEUROLAB – Um Ambiente de Desenvolvimento e Aplicação de Redes Neurais**, 1999. Monografia (Bacharelado em Informática). Instituto de Matemática – Departamento da Ciência da Computação, Universidade Federal do Rio de Janeiro, Rio de Janeiro, cap. 2.
2. BAXTER, R.A. **Supervised Adaptive Resonance Networks**. ACM Press: New York, Proceedings of the conference on Analysis of neural network applications, p. 123 – 137, 1991.
3. BILOTTI, M. W. **Query Expansion Techniques for Question Answering**. Dissertação de Mestrado, Massachusetts Institute of Technology, 2004
4. BIGUS, J.P. **Data Mining with Neural Networks**. New York: McGraw-Hill, 1º ed., cap. 2, 20 mai. 1996.
5. BISHOP, C.M. **Neural Networks for Pattern Recognition**. Oxford, Oxford University Press, 1995.
6. BOCANEGRA, C.W.R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**, 2002. Dissertação de Mestrado (Mestrado em Engenharia Civil). Departamento de Transportes, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, cap. 2.
7. BORGES, B. **Estudantes de Mato Grosso do Sul são vencedores da edição 2003**. Agência SEBRAE de Notícias, Rio de Janeiro, 9 dez. 2003.
Disponível em:
http://www.df.SEBRAE.com.br/preview/creator2/webs/SEBRAE/jornal/area5_cont_noticia_geral_detalhe.cfm?cd_noticia=2194
Acesso em: 30 mar. 2004.
8. _____.; GONDIM, A. **Mais de 110 mil universitários já simularam administração de empresas**. Agência SEBRAE de Notícias, Rio de Janeiro, 22 mar. 2004.
Disponível em: <http://asn.interjornal.com.br/site/ultimas>
Acesso em: 29 mar. 2004.
9. BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Fundamentos de Redes Neurais Artificiais**. 11º Escola de Computação, Rio de Janeiro: DCC/IM, COPPE/Sistemas, NCE/UFRJ, 20 a 24 jul. 1998, cap. 1 a 4.
10. BREIMAN, L.; *et.al.* **Classification and Regression Trees**, Wadsworth & Brooks, 1984.
11. BURGER, K. **Things change?** New York: Insurance & Technology, v. 26, n. 4, p. 4, mar. 2001.
12. CABRAL, L.S. **Princípios do Sistema Alfabético: do português do Brasil**. 1º

ed. São Paulo: Editora Contexto, 2003.

13. CHAMPION, C. **Taking advantage of Web self-care to meet client needs.** Norwalk: Customer Inter@ction Solutions, nov. 2003, vol. 22, iss. 5, p. 48.
14. CICHOCKI, A.; UNBEHAUEN, R. **Neural Networks for Optimization and Signal Processing.** Chichester: John Wiley & Sons, cap. 1 a 2, 1993.
15. DALE, R. *et. al.* **Handbook of Natural Language Processing.** Marcel Dekker, 1 jun. 2000.
16. DINIZ, S.S. **Uso de Técnicas Neurais para o Reconhecimento de Comandos de Voz,** 1997. Dissertação de Mestrado (Mestrado em Engenharia Elétrica). Instituto Militar de Engenharia - IME, Rio de Janeiro, cap. 4.
17. DIRECT MARKETING. **Amazon.Com opens gift, video stores.** ABI/INFORM Global. Garden City: jan. 1999, v. 61, p. 11.
18. DOUGLAS, A.K. **Marketing Your Firm on the Internet.** Chicago: Journal of Tax Practice Management, jan./feb. 2004, v. 3, iss. 1, p. 25.
19. DRAXLER, B.; MEISL, K.; THEINER, M. **Empirical Comparison of the Error Convergence Rate of Standard and Evolved ANNs.** PS Natural Computation SoSe2002, 2002.
Disponível em: <http://student.cosy.sbg.ac.at/~bdraxler/natcomp/natcomp.html>
Acesso em: 06 out. 2004.
20. DYBOWSKI, R.; GANT, V. **Clinical Applications of Artificial Neural Networks.** Cambridge: Cambridge University Press, 1º ed., 2001.
21. ESTADAO. **Economia de energia superou as expectativas das distribuidoras.** Jornal: Estadão.com.br, Agência Estado: Economia, 29 jun. 2001.
Disponível em:
<http://www.estadao.com.br/agestado/noticias/2001/jun/29/67.htm?ap>
Acesso em: 16 jun. 2004.
22. ESTEBON, M.D. **Perceptrons: An Associative Learning Network.** Virginia Tech, 1997.
Disponível em: <http://ei.cs.vt.edu/~history/Perceptrons.Estebon.html>
Acesso em: 04 out. 2004.
23. FEIGUINA, O. KÉGL, B. **Learning To Classify Questions.** CLiNE (Computational Linguistics in the North-East), Université du Québec en Outaouais (Gatineau, Québec), ago. 2005.
24. FERREIRA, A.L. **Rota de Navegação: Desafio SEBRAE 2004.** Rio de Janeiro: Expertbooks, 2004, 4º ed., cap. 2 e 3, p. 97 a 106.
25. FRENGER, P. **A Forth-based hybrid neuron for neural.** ACM Press: New York, SIGFORTH, Proceedings of the second and third annual workshops on Forth, p. 99-102, 1991.

26. FU, L. **Knowledge discovery based on neural networks**. ACM Press: New York, Communications of the ACM, v. 42, p. 47 – 50, 1999.
27. GERMAN, G. W. H.; GAHEGAN, M. N. 1996. **Neural network architectures for the classification of temporal image sequences**. Computers Geosciences, v. 22, n.9, p. 969 – 979.
28. GLOBO, O. **O Dia em que a Internet travou**. Jornal: O Globo, Editoria: O Mundo, Caderno: Primeiro Caderno, 11 set. 2001.
29. GOFF, L. **Internet Explosion**. Framingham Computerworld, v.33, n. 46; p. 118, 15 nov. 1999.
30. GOVERNO BRASILEIRO. **LEI-008029 de 12/04/1990**. Catálogo: Administração Federal. Diário Oficial da União, 12 abr. 1990.
31. _____. **DEC-099570 de 09/10/1990**. Catálogo: Administração Federal. Diário Oficial da União, 9 out. 1990.
32. _____. **LEI-009790 de 23/03/1999**. Catálogo: Organização Social. Diário Oficial da União, 23 mar. 1999.
33. HAYKIN, S. **Redes Neurais: Princípios e Prática**. Porto Alegre: Bookman, 2001, 2º ed., cap. 1ª 3.
34. HRYCEJ, T. **Modular Learning in Neural Networks: A Modularized Approach to Neural Network Classification**. New York: John Wiley & Sons, 1º ed, cap.1, 1992.
35. IBGE. **As Micro e Pequenas Empresas Comerciais e de Serviços no Brasil: Cresce a Participação das Micro e Pequenas Empresas no Setor de Comércio e Serviços**. Comunicação Social, 11 set. 2003.
Disponível em: <http://www.ibge.gov.br/home/presidencia/noticias/pdf/11092003microempresa.pdf>
Acesso em: 23 abr. 2004.
36. INTERNET WORLD STATS. **World Internet Users and Population Stats**. Disponível em: <http://www.internetworldstats.com/stats.htm>
Acesso em: 3 ago. 2005.
37. JAIN, A.K.; MAO, J.; MOHIUDDIN, K. **Artificial Neural Networks: A Tutorial**. IEEE Computer Society, v. 29, n. 3, p. 31-44, 1996.
38. KORDING, K.P.; KONING, P. **Supervised and Unsupervised Learning with Two Sites of Synaptic Integration**. Journal of Computation Neuroscience, n. 11, p. 207-215, 2001.
39. KROSE, B; SMAGT, P.V.D. **An Introduction to Neural Networks**. The University of Amsterdam, 8º ed., 1996.
Disponível em: http://www.avaye.com/files/articles/nnintro/nn_intro.pdf
Acesso em: 25 mai. 2004.

40. MATOS, J. D. **Indicadores Econômicos: FEE - Fundação Econômica e Estatística**. Revista Indicadores Econômicos FEE, Porto Alegre, v. 31, n. 3, p. 47-70, nov. 2003.
41. MCCULLOCH, W.S. **An upper bound on the informational capacity of a synapse**. ACM Press: New York, ACM/CSC-ER, Proceedings of the 1952 ACM national meeting (Pittsburgh), p. 113-114, 1952.
42. MIIKKULAINEN, R.; MAYBERRY, M.R. **Sardsrn: A neural network shift-reduce parser**. In Proceedings of the 16th Annual International Joint Conference on Artificial Intelligence, 1999.
43. NG, H. T.; TEO, L. H.; KWAN, J. L. P. **A Machine Learning Approach to Answering Questions for Reading Comprehension Tests**. Proceedings of the 2000 Joint SIGDAT Conference on Empirical Methods in Natural Language Processing and Very Large Corpora (EMNLP/VLC-2000), Hong Kong, p. 124-132, 2000.
44. NOTARI, D.L. **Aplicação de Redes Neurais Artificiais à Mineração de Dados**, 1997. Monografia (Bacharelado em Ciência da Computação). Departamento de Informática, Centro de Ciências Exatas e Tecnologia, Universidade de Caxias do Sul, Caxias do Sul, cap. 4.
45. OKIN, J.R. **The Internet Revolution: The Not-for-Dummies Guide to the History, Technology, and Use of the Internet**. Ironbound Press, 1 jun. 2005.
46. PAULA, M.B. **Reconhecimento de palavras faladas utilizando Redes Neurais Artificiais**, 2000. Monografia (Bacharelado em Informática). Instituto de Física e Matemática, Universidade Federal de Pelotas, Rio Grande do Sul, cap. 5.
47. PERANTONIS, S.J.; VIRVILIS, V. **Efficient perceptron learning using constrained steepest descent**. Neural Networks, v. 13, p. 351–364, 2000.
48. REPONEN, T. **Information Technology Enabled Customer Service**. Idea Group Publishing, 4 nov. 2002.
49. REYNOLDS, J. **The Complete E-Commerce Book: Design, Build, and Maintain a Successful Web-Based Business**. California: Publishers Group West, 2^o ed., cap. 1, abr. 2004.
50. RIBEIRO, L. N. **Rede Neural com Retropropagação: uma Aplicação na Classificação de Imagens de Satélite**, 2003. Dissertação de Mestrado. Departamento de Computação e Estatística, Centro de Ciências Exatas e Tecnologia, Universidade Federal do Mato Grosso do Sul, Mato Grosso do Sul, cap. 3.
51. READ, B.; FLEISCHER, J. **The Complete Guide to Customer Support: How to Turn Technical Assistance into a Profitable Relationship**. CMP Books; 1^o ed., jun. 2002.
52. RILOFF, E.; THELEN, M. **A Rule-based Question Answering System for**

Reading Comprehension Tests. ANLP/NAACL-2000 Workshop on Reading Comprehension Tests as Evaluation for Computer-Based Language Understanding Systems, 2000.

53. ROSSI, B.R.; MOTTA, S.L. **Preferences Process Formation in Internet Environment.** Escola de Administração de Empresas de São Paulo: Fundação Getúlio Vargas. Área: Technology and Innovation Management, n. 318, 2003.
Disponível em: <http://www.fgvsp.br/iberoamerican/program.pdf>
Acesso em: 7 jun. 2004.
54. RUMELHART, D.E.; WIDROW, B.; LEHR, M.A. **The basic ideas in neural networks.** ACM Press: New York, Communications of the ACM, v. 37, p. 87-92, 1994.
55. RYDLEWSKI, C. **Economia e Negócios: A Vida Sem Crédito.** Abril: Rio de Janeiro, Revista Veja, 1850^o ed., ano 37, n. 16, p. 100-101, 21 abr. 2004.
56. SANTOS, R.C. **Alunos da Unicamp vencem “Desafio SEBRAE”.** Jornal da Unicamp, São Paulo, 16 a 22 dez. 2002, 202^o ed., p.10.
57. SARKAR, D. **Methods to Speed Up Error Back-Propagation Learning Algorithm.** ACM Press: New York, ACM Computing Surveys, v. 27, p. 519 – 544, 1995.
58. SCOCUGLIA, A.C. **Sociedade, Trabalho e Educação Empreendedora.**
Disponível em: <http://www.SEBRAEce.com.br/info/concurso3.htm>
Acesso em: 19 abr. 2004.
59. SEBRAE. **Programas e Projetos: Desafio SEBRAE**
Disponível em:
http://www.SEBRAE.com.br/br/programaseprojetos/programaseprojetos_1072.asp
Acesso em: 23 mar. 2004.
60. _____. **O SEBRAE.**
Disponível em: <http://www.SEBRAE.com.br/br/oSEBRAE/oSEBRAE.asp>
Acesso em: 23 mar. 2004.
61. _____. **Estatuto.** Capítulo II: Do Âmbito de Atuação e Objetivos Institucionais.
Disponível em: <http://www.SEBRAE.com.br/br/oSEBRAE/estatuto.asp>
Acesso em: 23 abr. 2004.
62. _____. **Quem Somos.** Estrutura.
Disponível em: <http://www.SEBRAE.com.br/br/oSEBRAE/quemsomos.asp>
Acesso em: 06 mai. 2004.
63. _____. **História.**
Disponível em: <http://www.SEBRAE.com.br/br/oSEBRAE/historia.asp>
Acesso em: 06 mai. 2004.
64. _____. **Rodadas de Negócio.**
Disponível em:

<http://www.SEBRAE.com.br/br/parasuaempresa/rodadasdenegocios.asp>

Acesso em: 06 mai. 2004.

65. _____ **Feiras.**

Disponível em: <http://www.SEBRAE.com.br/br/parasuaempresa/feiras.asp>

Acesso em: 07 mai. 2004.

66. _____ **Programas e Projetos.**

Disponível em:

<http://www.SEBRAE.com.br/br/programaseprojetos/programaseprojetos.asp>

Acesso em: 07 mai. 2004.

67. SEBRAECE. **Histórico do SEBRAE: O Sistema SEBRAE e o Contexto em que Atua.**

Disponível em: <http://www.SEBRAEce.com.br/info/concurso1.htm>

Acesso em: 19 abr. 2004.

68. _____ **As Micro e Pequenas Empresas no Contexto Econômico Nacional.**

Disponível em: <http://www.SEBRAEce.com.br/info/concurso4.htm>

Acesso em: 19 abr. 2004.

69. SELAMAT, A.; OMATU, S. **Web page feature selection and classification using neural networks.** Elsevier Science Inc.: Information Sciences—Informatics and Computer Science: An International Journal, v. 158, iss. 1, p. 69 – 88, 2004.

70. SEVERANCE, D.G. **Identifier Search Mechanisms: A Survey and Generalized Model.** ACM Computing Surveys, v. 6, iss. 3, p.175-194, 1974.

71. SILVA, E. **Reconhecimento Inteligente de Caracteres Manuscritos**, 2002. Dissertação de Mestrado (Mestrado em Sistemas e Computação). Instituto Militar de Engenharia - IME, Rio de Janeiro, cap. 1.

72. SIMMONS, R. F. **Natural Language Question-Answering Systems: 1969.** ACM Press: New York, v. 13, iss.1, p. 15 – 30, 1970.

73. SMITH, K; GUPTA, J. **Neural Networks in Business: Techniques and Applications.** Hershey: Idea Group Publishing, cap. 1, 2002.

74. SONDAK, N.E.; SONDAK, V.K. **Neural Networks and Artificial Intelligence.** ACM Press: New York, ACM SIGCSE Bulletin, Proceedings of the twentieth SIGCSE technical symposium on Computer science education, v. 21, p. 241 – 245, 1989.

75. SPECTOR, R. **Amazon.com: Get Big Fast.** New York: HarperBusiness, 1^o ed., 22 jan. 2002.

76. STERNE, J. **Customer Service on the Internet: Building Relationships, Increasing Loyalty, and Staying Competitive.** Wiley; 2^o ed., 8 mai. 2000.

77. STOPWORD. **StopWord List.** Institut Interfacultaire d'Informatique. University of Neuchatel. Neuchatel, 2002.

Disponível em: <http://www.unine.ch/info/clef/>
Acesso em: 10 ago. 2004.

78. TARASSENKO, L. **Guide to Neural Computing Applications**. London: Butterworth-Heinemann, Hardcover ed., cap. 2, 30 jan. 1998.
79. TOTTY, P. **Anywhere, anytime service**. Madison: Credit Union Magazine, abr. 2003, v. 69, iss. 4, p. 33.
80. TRIPPI, R.R.; TURBAN, E. **Neural Networks in Finance and Investing**. New York: McGraw-Hill, cap. 1, 1996.
81. VARGAS-VERA, M.; MOTTA, E. **AQUA - Ontology-based Question Answering System**. Third International Mexican Conference on Artificial Intelligence (MICAI-2004), Lecture Notes in Computer Science 2972 Springer Verlag, (eds R. Monroy et al), 26-30 abr. 2004.
82. WEST, D. **Neural Network Credit Scoring Models**. Elsevier Science Ltd.: Computers & Operations Research, v. 27, iss. 11-12, p. 1131-1152, 2000.
83. WU, M. *et.al.* **Question Answering: By Pattern Matching, Web-Proofing, Semantic Form Proofing**. ILS Institute, Computer Science Department, SUNY Albany, 2004.
Disponível em: <http://trec.nist.gov/pubs/trec12/papers/ualbany-suny.qa.pdf>
Acesso em: 16 ago. 2005.
84. ZHANG, G.P. **Neural Networks in Business Forecasting**. Information Science Publishing, Digital ed., cap. 1, 1 out. 2003.
85. ZURADA, J.M. **Introduction to Artificial Neural Systems**. Boston: PWS Publishing Company, cap. 1 a 2, 1995.

ANEXO I

Respostas padrões definidas para o sistema de resposta automática

- **Resposta 1**

Prezada Equipe,

Agradecemos a sua informação, mas pedimos que seja acusado o recebimento ou não do material na área específica para este fim (a primeira janela que aparece ao abrir a área restrita). Lembrando às equipes que o material do Desafio Sebrae será entregue no período disponibilizado no site www.desafiosebrae.com.br/data_entrega.

Sendo enviado a cada representante um Manual e o CD para instalação do software e para os demais participantes, somente o manual, dando prioridade ao reenvio do material do representante. Pois, o não envio deste, implicaria na não participação da equipe na competição.

Além disso, advertimos que o preenchimento correto dos endereços no ato da inscrição é de responsabilidade exclusiva da equipe. Assim, conforme o regulamento, os participantes e o representante receberão o material nos endereços indicados na ficha de inscrição, não existindo outra opção para o recebimento do mesmo.

O material será entregue ao destinatário ou a pessoa presente na residência no momento da entrega mediante assinatura. Caso não haja qualquer pessoa (o próprio integrante ou qualquer outra pessoa) no endereço indicado na ficha de inscrição para o recebimento do material, ele poderá ser devolvido à organização do Desafio SEBRAE. Fiquem atentos! Nesse caso, não haverá o reenvio do material, exceto no caso do representante cujo material será tratado de forma diferenciada.

Lembramos que não é necessário o material para participar do Aquecimento e não nos responsabilizamos pelo envio de material para integrantes incluídos após a data de envio, como consta no Regulamento.

Atenciosamente, Equipe Desafio Sebrae.

- **Resposta 2**

Prezada Equipe,

O Aquecimento é uma atividade que tem como objetivo auxiliar as equipes na compreensão do jogo e aumentar seus conhecimentos gerais.

Essa atividade terá regulamento próprio, que em breve estará disponível no site oficial do Desafio Sebrae, e deverá ser lido antes do início da participação da equipe.

A data de início do Aquecimento estará disponível no quadro de avisos da área restrita e as rodadas serão divulgadas durante a competição. Quem não participou das outras rodadas pode participar das atuais e não é necessário o software para participar.

No regulamento você encontrará todas as informações necessárias para participar do Aquecimento. Qualquer dúvida, favor entrar em contato novamente.

Lembramos que só participarão equipes com o pagamento já efetuado.

No caso do link do Aquecimento não encontrar-se disponível na área da sua equipe, favor verificar o *cache* da máquina (ir no *link* ferramentas do seu *browse* e limpar o *cache*) ou então baixar o *plugin shockwave* e instalá-lo (disponível no site www.macromedia.com.br).

Em alguns casos, ao instalar o *shockwave*, o programa ativa automaticamente o *anti-popup* (que é um programa que não abre janelas). Pedimos que, por favor, desativem o *anti-popup*. Se o problema persistir, nos comunique.

Atenciosamente,

Equipe Desafio Sebrae.

- **Resposta 3**

Prezada Equipe,

Caso esteja tendo problemas para o recebimento de e-mails do Desafio Sebrae, aconselhamos verificar os filtros utilizados, como "AntiSpam" e caixas de e-mail lotadas para que futuramente não tenha estes problemas.

Caso esteja com problemas com o software do Desafio Sebrae, favor verificar inicialmente se a máquina utilizada para a instalação cumpre os pré-requisitos que constam no regulamento. No caso de cumprir, verifique se esta máquina possui algum tipo de *firewall* ou antivírus e, caso possuam, desinstale-os, instale o CD do Desafio, e instale-os novamente. Favor verificar também se vocês possuem a versão mais nova do *shockwave* que está disponível no item *download* na sua área restrita.

Outros possíveis fatores que podem estar ocasionando problemas são: *anti-popup*, versão desatualizada do Browser e opção de Java Script acionada no *browser*.

Em caso de problemas com a máquina durante a competição, basta fazer uma reinstalação, pois durante a primeira instalação pode ter sido corrompido algum arquivo.

Para a reinstalação transcorrer sem problemas, certifique-se de que o software foi completamente desinstalado utilizando para tal a opção "DESINSTALAR" em seu computador (clicar em "INICIAR/START" no menu do seu computador, depois em "PROGRAMAS", "DESAFIO SEBRAE", "DESINSTALAR" e "APAGAR TUDO").

Em relação à instalação do software em mais de um computador, advertimos que não é possível, uma vez que todas as decisões durante o jogo devem ser enviadas e recebidas por este computador.

Aconselhamos fazer a instalação em um PC de fácil acesso à equipe.

Atenciosamente,

Equipe Desafio Sebrae.

- **Resposta 4**

Prezada Equipe,

Para verificar se o pagamento da taxa de inscrição já consta em nosso sistema, aconselhamos verificar sempre que possível, o quadro de avisos da área restrita e seus *e-mails*. Não esqueça de confirmar a existência de filtros *anti-spam* e se a caixa de *e-mail* não está lotada, para facilitar futuras comunicações.

Em caso de atraso no pagamento da taxa de inscrição, este poderá ser efetuado depois do vencimento desde que seja feito nas agências do Banco do Brasil, diretamente no caixa sem qualquer ônus para equipe. A data de vencimento se encontra na região superior do boleto, ao lado do número do CPF.

Em adição, será necessário que nos envie o comprovante de pagamento, via fax, para o número (21)2590-4334, não esquecendo de colocar "Aos Cuidados do Desafio Sebrae", o nome da equipe e o CPF do representante.

No caso de impossibilidade de impressão do boleto, a equipe poderá efetuar o pagamento tendo em mãos o código numérico identificador do boleto. Lembramos que não será reconhecido nenhum outro tipo de pagamento que não o efetuado através do boleto impresso ou de seu código numérico.

Após efetuar o pagamento da taxa de inscrição verifique se os integrantes receberam o e-mail de confirmação de pagamento que é enviado no prazo máximo de cinco dias úteis. Caso não o receba, favor entrar em contato novamente e mandando um fax com o comprovante de pagamento (21) 2590-4334.

Atenciosamente,

Equipe Desafio Sebrae.

- **Resposta 5**

Prezada Equipe,

A mensagem com o link para o questionário (confirmação de cadastro) é gerada automaticamente ao final do cadastramento da equipe, e não temos como fazer o reenvio.

O não preenchimento do questionário por um ou mais membros da equipe não acarretará qualquer prejuízo a mesma.

Aconselhamos verificar os filtros utilizados, como "AntiSpam" e caixas de e-mail lotadas para que futuramente não tenha problemas para o recebimento de e-mails do Desafio Sebrae.

Pedimos que verifique se não há um antipop up (evita que janelas se abram) instalado em sua máquina, uma versão desatualizada no Browser (Explorer 6.0), se a opção de Java Script está acionada no Browser, se estão digitando a senha correta, se estão digitando em caixa alta e/ou nenhum defeito, neste caso, pedimos que faça um teste em outra máquina.

Atenciosamente,

Equipe Desafio Sebrae.

ANEXO II

Função resultante do treinamento da rede neural

```

/*
** Código Fonte da função de classificação mlp
**
** A interface da função mlp é:
**   int mlp(float *inputs, float *outputs);
**
** Os valores de confiança são retornados pela função através do vetor
<outputs>
**
** O classificador mlp tem as seguintes características:
**   50 entradas, 6 saídas
**   entradas normalizadas pelo função zscore.
**   1 camada escondida.
*/
#include <stdio.h>
#include <math.h>
#include <float.h>

#define NUM_INPUTS 50
#define REDUCED_INPUTS 50
#define HIDDEN1_NODES 19
#define NUM_OUTPUTS 6

#define MAX_EXP 87.4982

static long double zs_input_mean[REDUCED_INPUTS] =
{0.049239, 0.0680394, 0.0993733, 0.0599821, 0.0725157,
0.0626679, 0.0689346, 0.038496, 0.0581916, 0.049239,
0.0340197, 0.0537153, 0.0340197, 0.102954, 0.10564,
0.102059, 0.034915, 0.0295434, 0.0322292, 0.0859445,
0.0322292, 0.0510295, 0.0304387, 0.177261, 0.466428,
0.0886303, 0.0519248, 0.12265, 0.0850492, 0.116383,
0.0393912, 0.034915, 0.0241719, 0.2641, 0.249776,
0.558639, 0.143241, 0.0752014, 0.0537153, 0.0555058,
0.0608773, 0.0850492, 0.0564011, 0.459266, 0.0662489,
0.0322292, 0.0483438, 0.034915, 0.0528201, 0.0313339};

static long double zs_input_stdv[REDUCED_INPUTS] =
{0.216464, 0.251926, 0.299297, 0.23756, 0.259456,
0.242473, 0.253456, 0.192476, 0.23421, 0.216464,
0.181361, 0.225556, 0.181361, 0.304035, 0.307514,
0.302862, 0.183647, 0.1694, 0.176687, 0.280408,
0.176687, 0.220157, 0.171868, 0.38206, 0.499095,
0.284337, 0.221975, 0.328182, 0.27908, 0.320827,
0.194611, 0.183647, 0.153651, 0.44105, 0.433077,
0.496772, 0.350475, 0.263834, 0.225556, 0.229067,
0.239212, 0.27908, 0.230798, 0.498561, 0.248828,
0.176687, 0.214588, 0.183647, 0.223774, 0.174297};

static float hidden1_weights[HIDDEN1_NODES][REDUCED_INPUTS+1] = {
{(float)0.0408068, (float)-0.0630033, (float)-0.466823, (float)0.178331,
(float)-0.236354, (float)-0.0711949, (float)0.313743, (float)-0.0247992,
(float)-0.0388035, (float)0.00980041, (float)0.081262, (float)-0.0547164,
(float)-0.187889, (float)0.280979, (float)-0.0866499, (float)0.0244529,

```


(float) 0.0905559, (float) -0.103286, (float) 0.218777, (float) 0.102935,
(float) 0.128722, (float) 0.0406674, (float) 0.0316778, (float) 0.0226303,
(float) -0.0918379, (float) 0.0972994, (float) -0.0639085, (float) -0.00472633,
(float) 0.199173, (float) -0.0649791, (float) -0.0261676, (float) 0.103941,
(float) -0.0699593, (float) -0.0674922, (float) 0.365845, (float) -0.155338,
(float) -0.488264, (float) -0.0551953, (float) -0.0555447, (float) -0.126832,
(float) 0.441648, (float) 0.0364922, (float) 0.66525, (float) 0.216304,
(float) 0.107212, (float) -0.0211354, (float) 0.107383, (float) 0.0821677,
(float) 0.279594, (float) -0.191858, (float) 0.196495},
{(float) -0.0565073, (float) -0.0112634, (float) 0.961271, (float) -0.482473,
(float) -0.0925968, (float) -0.159511, (float) -0.00541646, (float) 0.107999,
(float) 0.173389, (float) 0.237908, (float) -0.301193, (float) 0.103795,
(float) 0.305943, (float) -0.387481, (float) 0.094652, (float) 0.384226,
(float) 0.0348984, (float) -0.0523836, (float) 0.0650152, (float) 0.0808065,
(float) 0.0131572, (float) -0.132799, (float) 0.0970032, (float) 0.0720102,
(float) -0.343765, (float) -0.304511, (float) 0.0854339, (float) 0.0592956,
(float) -0.307633, (float) 0.0852013, (float) 0.244448, (float) -0.0460495,
(float) 0.193668, (float) 0.481593, (float) 0.184394, (float) 0.0143848,
(float) -0.144142, (float) -0.0659207, (float) 0.0293357, (float) 0.200482,
(float) 0.359304, (float) -0.198637, (float) 0.357927, (float) 0.279168,
(float) -0.0338326, (float) -0.0104601, (float) -0.241639, (float) -0.308806,
(float) 0.199179, (float) -0.0256591, (float) 0.0837631},
{(float) -0.0611163, (float) -0.115019, (float) -0.390641, (float) -0.44096,
(float) -0.113474, (float) -0.0256488, (float) 0.33228, (float) -0.0426335,
(float) -0.188913, (float) 0.274318, (float) -0.178036, (float) 0.176006,
(float) -0.136827, (float) -0.431501, (float) -0.0541978, (float) -0.0333214,
(float) 0.00963123, (float) 0.0257299, (float) -0.226892, (float) -0.0209074,
(float) 0.126239, (float) -0.0349397, (float) 0.271829, (float) 0.44199,
(float) -0.0513931, (float) -0.400936, (float) -0.202566, (float) 0.113525,
(float) -0.494991, (float) -0.132165, (float) -0.358201, (float) -0.120192,
(float) 0.425212, (float) 0.84064, (float) 0.111821, (float) 0.0344336,
(float) -0.326919, (float) -0.0406685, (float) -0.0528431, (float) 0.146649,
(float) 0.133905, (float) -0.479142, (float) 0.135953, (float) 0.787308,
(float) 0.104347, (float) -0.00226708, (float) -0.256133, (float) -0.199332,
(float) 0.247739, (float) -0.199781, (float) -0.225083},
{(float) -0.18208, (float) -0.115944, (float) -0.561966, (float) -0.0757785,
(float) 0.325835, (float) -0.00408368, (float) -0.15542, (float) -0.131083,
(float) -0.231052, (float) -0.1383, (float) -0.000538871, (float) 0.0527092,
(float) -0.15459, (float) -0.277395, (float) 0.0307023, (float) -0.342953,
(float) -0.140598, (float) 0.181376, (float) -0.299244, (float) -0.146089,
(float) -0.0370436, (float) -0.173113, (float) 0.330716, (float) 0.183868,
(float) -0.012005, (float) -0.0761872, (float) -0.0907381, (float) -0.0547726,
(float) -0.31524, (float) -0.03955, (float) -0.337134, (float) 0.00419183,
(float) -0.00130889, (float) 0.568827, (float) -0.268786, (float) -0.129913,
(float) 0.716352, (float) 0.432873, (float) -0.0865264, (float) -0.142423,
(float) -0.39485, (float) -0.233948, (float) -0.480763, (float) 0.356602,
(float) -0.114518, (float) -0.274467, (float) -0.115436, (float) -0.0453305,
(float) -0.133157, (float) 0.357163, (float) -0.481964},
{(float) -0.228405, (float) -0.269981, (float) -0.462568, (float) 0.376829,
(float) 0.00558245, (float) 0.0197891, (float) 0.0675001, (float) -0.0830725,
(float) -0.26447, (float) -0.382061, (float) 0.0164755, (float) -0.0905632,
(float) 0.100822, (float) -0.4529, (float) 0.283327, (float) 0.179878,
(float) 0.0519346, (float) -0.00084065, (float) 0.0308059, (float) 0.144517,
(float) 0.250867, (float) -0.234684, (float) 0.272452, (float) 0.156888,
(float) 0.29049, (float) -0.761674, (float) 0.0315669, (float) 0.10463,
(float) -0.281392, (float) -0.506957, (float) -0.307562, (float) -0.115626,
(float) -0.159832, (float) 0.61316, (float) 0.194358, (float) 0.015646,
(float) 0.0246808, (float) 0.154643, (float) 0.128947, (float) 0.0175934,
(float) 0.184247, (float) -0.206229, (float) 0.529719, (float) 0.528649,
(float) 0.205707, (float) -0.0141349, (float) -0.362505, (float) -0.351783,
(float) 0.271623, (float) 0.0704651, (float) 0.674076},

```

{(float) 0.151343, (float) 0.0288694, (float) -0.930889, (float) 0.561309,
(float) 0.0108568, (float) 0.195528, (float) 0.380227, (float) -0.0303415,
(float) -0.121998, (float) -0.190496, (float) 0.0775367, (float) -0.258161,
(float) -0.336123, (float) 0.424763, (float) -0.0833218, (float) -0.108972,
(float) 0.219242, (float) -1.63007e-005, (float) 0.293964, (float) 0.197243,
(float) 0.141183, (float) 0.0936804, (float) -0.124914, (float) -0.00717469,
(float) 0.160677, (float) 0.159207, (float) -0.252408, (float) 0.118065,
(float) 0.425089, (float) -0.113878, (float) -0.0455866, (float) 0.16053,
(float) -0.310588, (float) -0.987214, (float) 0.295613, (float) 0.111249,
(float) -0.0986483, (float) 0.108382, (float) 0.0995071, (float) 0.0419622,
(float) 0.230355, (float) 0.17419, (float) 0.352647, (float) -0.129869,
(float) 0.186954, (float) 0.00492304, (float) 0.308607, (float) 0.22134,
(float) 0.156917, (float) 0.0450157, (float) 0.00587271},
{(float) -0.0454834, (float) 0.31291, (float) -0.571263, (float) -0.302657,
(float) 0.246391, (float) -0.240957, (float) -0.416984, (float) 0.118044,
(float) 0.388222, (float) 0.473206, (float) 0.0120914, (float) 0.28585,
(float) -0.15613, (float) 0.429659, (float) -0.171306, (float) -0.619228,
(float) 0.0167197, (float) 0.213295, (float) -0.430534, (float) 0.21488,
(float) -0.0605458, (float) -0.194362, (float) 0.166269, (float) 0.7221,
(float) -0.229114, (float) 0.367606, (float) 0.208757, (float) -0.169581,
(float) 0.229237, (float) -5.57541e-005, (float) -0.101066, (float) 0.119614,
(float) 0.112992, (float) 0.525092, (float) -0.157845, (float) 0.0935621,
(float) 0.718276, (float) 0.507365, (float) -0.624249, (float) -0.092496,
(float) -0.626191, (float) -0.0870125, (float) -0.733299, (float) 0.157931,
(float) -0.335371, (float) -0.214394, (float) 0.0295347, (float) 0.00834375,
(float) -0.259358, (float) 0.423552, (float) 0.277124},
{(float) -0.0691899, (float) -0.0129499, (float) 0.603089, (float) 0.463271,
(float) -0.0904359, (float) 0.195062, (float) -0.259837, (float) 0.141955,
(float) -0.385751, (float) -0.632662, (float) -0.0771226, (float) -0.203373,
(float) 0.000419218, (float) -0.39161, (float) 0.0543873, (float) 0.192758,
(float) -0.139897, (float) -0.0426073, (float) 0.173265, (float) -0.052924,
(float) -0.119212, (float) -0.171535, (float) -0.0614298, (float) -0.51234,
(float) 0.0726587, (float) -0.191167, (float) -0.208015, (float) -0.00306633,
(float) -0.533302, (float) -0.192295, (float) -0.132736, (float) -0.156254,
(float) -0.299332, (float) -0.888911, (float) -0.294481, (float) 0.0657307,
(float) 0.404304, (float) -0.0696827, (float) -0.0436208, (float) 0.290183,
(float) -0.176367, (float) 0.109129, (float) -0.325397, (float) -0.764728,
(float) 0.0367909, (float) 0.071254, (float) -0.0576759, (float) 0.00142878,
(float) -0.25257, (float) 0.0352196, (float) -0.878601},
{(float) -0.00709578, (float) 0.0615363, (float) -0.412812, (float) -0.035155,
(float) -0.144827, (float) -0.0708982, (float) -0.0491158, (float) -0.153859,
(float) -0.101776, (float) -0.148143, (float) -0.0753826, (float) -0.0309204,
(float) 0.000311188, (float) -0.0803898, (float) -0.201628, (float) -0.227345,
(float) 0.00883522, (float) 0.0192517, (float) 0.096834, (float) -0.121521,
(float) -0.0466413, (float) -0.0382429, (float) -0.0449701, (float) -0.0277174,
(float) -0.0734181, (float) -0.182264, (float) 0.0332209, (float) -0.0524786,
(float) -0.195271, (float) -0.110758, (float) -0.0567251, (float) -0.0882623,
(float) -0.153039, (float) -0.223393, (float) -0.186123, (float) 0.0292805,
(float) -0.359381, (float) -0.142172, (float) -0.0109421, (float) -0.0918089,
(float) -0.107771, (float) -0.0320844, (float) -0.186685, (float) 0.0229015,
(float) 0.0262671, (float) 0.00447328, (float) -0.0677785, (float) 0.154993,
(float) -0.108602, (float) -0.0274757, (float) -1.30489},
{(float) 0.369501, (float) 0.348225, (float) 0.563517, (float) -0.363096,
(float) -0.00178417, (float) 0.038886, (float) 0.185763, (float) 0.167071,
(float) 0.39389, (float) 0.148039, (float) 0.0449281, (float) 0.00904038,
(float) -0.00170043, (float) 0.490889, (float) 0.0109423, (float) 0.0222941,
(float) 0.0691305, (float) -0.00035336, (float) -0.069054, (float) 0.100002,
(float) 0.039876, (float) 0.249516, (float) -0.201793, (float) 0.0286469,
(float) -0.375056, (float) 0.287551, (float) 0.100845, (float) 0.0430158,
(float) 0.275611, (float) 0.249001, (float) 0.382335, (float) 0.0446693,
(float) 0.0851863, (float) -0.612594, (float) 0.518194, (float) 0.177008,

```

```

(float)-0.309685, (float)0.0122284, (float)-0.0511273, (float)0.125548,
(float)0.205733, (float)0.23003, (float)0.29821, (float)-0.169093,
(float)0.0991653, (float)-0.0234283, (float)0.0749462, (float)0.159731,
(float)0.120799, (float)-0.136133, (float)0.0307541},
{(float)0.105794, (float)0.137646, (float)0.234406, (float)0.261762,
(float)-0.309479, (float)-0.0538941, (float)-0.0914895, (float)-0.0160167,
(float)0.0144117, (float)-0.0528856, (float)0.126669, (float)-0.172246,
(float)0.142585, (float)-0.319327, (float)-0.596131, (float)0.186788,
(float)0.0186871, (float)0.044015, (float)-0.0404528, (float)-0.0607194,
(float)-0.0774518, (float)0.157352, (float)0.112818, (float)-0.150149,
(float)-0.00896854, (float)0.0203217, (float)0.177067, (float)-0.124599,
(float)-0.0649065, (float)0.19048, (float)-0.448666, (float)-0.0583161,
(float)0.289904, (float)1.27072, (float)-0.883595, (float)0.260395,
(float)-0.497556, (float)-0.451214, (float)0.116697, (float)-0.0455596,
(float)-0.424141, (float)0.0762986, (float)-0.54184, (float)-0.182917,
(float)-0.18443, (float)0.147679, (float)0.0693766, (float)0.0496597,
(float)-0.312554, (float)-0.361898, (float)0.553765},
{(float)0.0377585, (float)0.0195633, (float)-0.579606, (float)0.370314,
(float)-0.301337, (float)-0.0598813, (float)0.0854997, (float)-0.00279077,
(float)-0.0821719, (float)-0.000527977, (float)0.262741, (float)0.0620826,
(float)-0.24995, (float)0.173092, (float)-0.231915, (float)-0.248672,
(float)0.0458727, (float)-0.0361654, (float)0.107401, (float)0.144944,
(float)-0.0302897, (float)-0.000719948, (float)-0.139742, (float)-
0.0281202,
(float)0.210807, (float)0.26901, (float)0.0150484, (float)-0.0811289,
(float)0.248503, (float)0.0294111, (float)-0.100727, (float)0.0893394,
(float)-0.0298559, (float)0.259759, (float)-0.290299, (float)-0.0677526,
(float)-0.372128, (float)-0.330347, (float)0.0172782, (float)-0.178898,
(float)-0.20444, (float)0.15919, (float)-0.272439, (float)-0.0900431,
(float)-0.00330501, (float)-0.0206091, (float)0.173162, (float)0.248343,
(float)-0.202649, (float)0.125878, (float)0.223202},
{(float)-0.116461, (float)-0.280523, (float)-0.242053, (float)0.142805,
(float)0.0722387, (float)0.238379, (float)0.0185964, (float)-0.112897,
(float)-0.254006, (float)-0.548733, (float)0.0243999, (float)-0.161313,
(float)-0.0685577, (float)-0.131619, (float)0.36617, (float)-0.000593336,
(float)0.0303884, (float)-0.0296213, (float)0.0669078, (float)-0.0128607,
(float)0.133315, (float)-0.1327, (float)-0.153183, (float)-0.274171,
(float)-0.0996198, (float)-0.179898, (float)-0.0987207, (float)0.101055,
(float)-0.321324, (float)-0.330683, (float)0.254902, (float)0.000647139,
(float)-0.219238, (float)-0.964103, (float)0.547408, (float)-0.125078,
(float)0.0473143, (float)0.229814, (float)0.159173, (float)0.0188012,
(float)0.451684, (float)-0.427281, (float)0.464273, (float)-0.225837,
(float)0.163401, (float)0.047183, (float)-0.236052, (float)-0.252188,
(float)0.214851, (float)0.161274, (float)-0.910991},
{(float)-0.0686826, (float)-0.0243117, (float)0.486384, (float)0.209716,
(float)0.415157, (float)0.15809, (float)0.0356682, (float)0.142233,
(float)0.0951143, (float)-0.0333122, (float)-0.12642, (float)0.0821111,
(float)0.0624608, (float)-0.0972941, (float)0.150196, (float)0.157193,
(float)-0.0750512, (float)-0.0438303, (float)-0.0133688, (float)0.250257,
(float)0.0437604, (float)-0.00608589, (float)0.0760332, (float)-0.0327601,
(float)0.205965, (float)-0.0667615, (float)-0.0402214, (float)0.147311,
(float)0.112025, (float)0.0875623, (float)0.138996, (float)0.0294558,
(float)0.0436122, (float)0.209823, (float)0.0398933, (float)0.0271053,
(float)0.723627, (float)0.185899, (float)0.135374, (float)0.12591,
(float)0.0966518, (float)0.0793274, (float)0.0984547, (float)-0.107482,
(float)0.0646352, (float)0.0172921, (float)-0.000959543, (float)-0.126324,
(float)0.135728, (float)0.10088, (float)0.901741},
{(float)0.111558, (float)-0.180581, (float)0.540629, (float)-0.559417,
(float)-0.0307454, (float)-0.103162, (float)0.195769, (float)-0.0219853,
(float)0.0119138, (float)0.361722, (float)-0.313761, (float)0.156143,
(float)0.152422, (float)-0.207531, (float)-0.0231714, (float)0.340932,

```

(float)-0.0298586, (float)0.0345785, (float)0.0840407, (float)-0.10239,
(float)0.0577594, (float)0.0549203, (float)0.230136, (float)0.248864,
(float)-0.222669, (float)-0.278273, (float)0.0329338, (float)0.238894,
(float)-0.273679, (float)-0.0279116, (float)0.0107374, (float)-0.0569224,
(float)0.303623, (float)0.744134, (float)0.279756, (float)-0.0745569,
(float)-0.281827, (float)0.071527, (float)-0.0636776, (float)-0.244474,
(float)0.349483, (float)-0.280995, (float)0.491436, (float)0.428342,
(float)0.0376595, (float)-0.176094, (float)-0.277725, (float)-0.372122,
(float)0.293165, (float)-0.115525, (float)0.162212},
{(float)-0.246671, (float)-0.119456, (float)-0.247582, (float)0.314728,
(float)-0.344855, (float)0.064423, (float)0.299409, (float)-0.136471,
(float)-0.296634, (float)-0.1522, (float)0.095121, (float)0.0292521,
(float)-0.0383899, (float)-0.273497, (float)-0.10757, (float)0.20303,
(float)0.0357485, (float)-0.0818419, (float)0.318248, (float)-0.0330561,
(float)0.188121, (float)-0.201357, (float)0.167929, (float)0.0785807,
(float)0.269323, (float)-0.403568, (float)-0.0611008, (float)0.0278615,
(float)-0.253713, (float)-0.47011, (float)-0.352606, (float)-0.140539,
(float)0.0711964, (float)0.672871, (float)0.0763532, (float)-0.0340833,
(float)-0.476682, (float)-0.179052, (float)0.28274, (float)-0.0346946,
(float)0.401356, (float)-0.144429, (float)0.313062, (float)0.416443,
(float)0.187635, (float)0.0494198, (float)-0.164043, (float)-0.141591,
(float)0.16272, (float)-0.105226, (float)0.410314},
{(float)0.173799, (float)0.036026, (float)0.29438, (float)-0.192223,
(float)0.223683, (float)0.0332756, (float)-0.000465185, (float)0.0802873,
(float)0.16693, (float)0.150129, (float)0.0941652, (float)-0.028995,
(float)0.0336663, (float)0.171397, (float)0.32105, (float)0.104532,
(float)-0.039777, (float)0.0487154, (float)-0.205185, (float)-0.0376092,
(float)0.089087, (float)0.0862783, (float)-0.0243992, (float)0.0694556,
(float)-0.1349, (float)0.131403, (float)-0.0296978, (float)-0.0589,
(float)0.247705, (float)0.152718, (float)0.0440814, (float)0.00098571,
(float)0.102045, (float)0.0744323, (float)0.37676, (float)-0.0825377,
(float)0.275042, (float)0.247783, (float)-0.0856457, (float)0.0506406,
(float)0.113425, (float)0.0205569, (float)0.289818, (float)0.05808,
(float)-0.00564985, (float)-0.0460885, (float)-0.0237365, (float)0.0146245,
(float)0.164808, (float)-0.0972104, (float)0.967497},
{(float)-0.188738, (float)-0.131348, (float)0.411938, (float)0.206675,
(float)-0.00539358, (float)0.0789389, (float)-0.101487, (float)0.00459898,
(float)-0.0721338, (float)-0.545953, (float)-0.0552516, (float)-0.187216,
(float)0.11613, (float)-0.154151, (float)0.144002, (float)0.0477822,
(float)0.0593333, (float)-0.0313417, (float)0.181246, (float)-0.134181,
(float)-0.0395827, (float)-0.117775, (float)-0.0726602, (float)-0.257128,
(float)0.0521413, (float)-0.190361, (float)0.0427554, (float)-0.0175358,
(float)-0.180285, (float)-0.17361, (float)0.0654951, (float)-0.0927822,
(float)-0.299987, (float)-0.877104, (float)0.135063, (float)-0.091433,
(float)0.130183, (float)-0.00238183, (float)0.119926, (float)0.0282215,
(float)0.0332506, (float)-0.0352093, (float)0.0344706, (float)-0.465171,
(float)-0.0112203, (float)0.0225959, (float)-0.0381733, (float)0.0130868,
(float)-0.0107933, (float)-0.0149872, (float)-0.620234},
{(float)0.169634, (float)-0.00524443, (float)-0.63681, (float)0.396096,
(float)-0.287304, (float)0.0207204, (float)0.375534, (float)0.0411915,
(float)-0.0590132, (float)-0.0776101, (float)0.08965, (float)-0.11351,
(float)-0.210538, (float)0.378094, (float)-0.0359538, (float)-0.0268401,
(float)0.195892, (float)-0.101543, (float)0.334317, (float)0.140297,
(float)0.0304175, (float)0.0160582, (float)-0.106445, (float)-0.0564709,
(float)-0.103235, (float)0.118611, (float)-0.122502, (float)-0.00680604,
(float)0.420372, (float)-0.104979, (float)0.09883, (float)0.0727916,
(float)-0.169077, (float)-0.787851, (float)0.409002, (float)0.00316629,
(float)-0.538721, (float)-0.186395, (float)0.0160807, (float)0.0106888,
(float)0.467717, (float)0.122126, (float)0.586027, (float)0.083135,
(float)0.184893, (float)-0.0648881, (float)0.258616, (float)0.19011,
(float)0.198357, (float)-0.190895, (float)-0.190717}

```

};

static float output_weights[NUM_OUTPUTS][HIDDEN1_NODES+1] = {
{(float)-0.0502985, (float)-0.491064, (float)-0.183889, (float)0.20927,
(float)0.364562, (float)0.0977787, (float)-1.34321, (float)1.31814,
(float)1.14033, (float)-0.873929, (float)0.672878, (float)0.673031,
(float)0.496641, (float)-0.76784, (float)-0.869372, (float)0.788387,
(float)-1.25, (float)0.664705, (float)0.149659, (float)-2.40321},
{(float)-0.754997, (float)0.864172, (float)-0.376564, (float)-0.396626,
(float)-1.57978, (float)-0.840686, (float)-0.824532, (float)0.826191,
(float)0.498209, (float)0.416996, (float)0.0267337, (float)-0.506777,
(float)0.09146, (float)-0.298044, (float)0.325919, (float)-0.811112,
(float)-0.44266, (float)0.608913, (float)-0.391638, (float)-2.89216},
{(float)1.05546, (float)0.802877, (float)0.774774, (float)-0.393406,
(float)0.677372, (float)0.55955, (float)-0.876981, (float)-0.142542,
(float)0.450445, (float)0.400348, (float)-1.05595, (float)-0.510944,
(float)1.37144, (float)-0.664281, (float)0.895411, (float)0.618704,
(float)0.0330636, (float)0.284439, (float)1.0775, (float)-2.53405},
{(float)-0.2529, (float)0.300876, (float)1.56898, (float)0.899702,
(float)0.503642, (float)-1.22581, (float)0.956631, (float)-0.745551,
(float)0.667255, (float)-0.826674, (float)1.04974, (float)0.132724,
(float)-0.459934, (float)-0.66102, (float)0.616525, (float)0.413064,
(float)-0.538926, (float)-0.922935, (float)-0.736291, (float)-2.05907},
{(float)0.114439, (float)-0.656696, (float)-0.647154, (float)-0.381727,
(float)-1.23947, (float)1.0568, (float)0.851427, (float)-0.85405,
(float)0.775005, (float)0.901555, (float)-0.291572, (float)0.679135,
(float)-0.526303, (float)-0.927156, (float)-0.403301, (float)-0.745477,
(float)-0.329855, (float)-0.414159, (float)0.890888, (float)-2.12848},
{(float)-0.572741, (float)-0.832776, (float)-0.305592, (float)1.41247,
(float)-0.195634, (float)0.167745, (float)1.0958, (float)0.994468,
(float)0.484701, (float)-0.172089, (float)-1.44524, (float)-0.485963,
(float)1.33019, (float)0.337454, (float)-0.965036, (float)-0.814033,
(float)-0.23882, (float)0.770712, (float)-0.548828, (float)-2.99811}
};

static float tanhoid(float x)
{
float f;
if (x < -MAX_EXP)
return((float)-1.0);
f = (float)exp(-x);
f = (float)1.0 / ((float)1.0 + f);
f = f * (float)2.0 - (float)1.0;
return(f);
}

static float sigmoid(float x)
{
float f;

/* SIGH(x) = 1.0 / (1.0 + E^-x) */
f = (float)exp(-x);
if (f == (float)FLT_MAX) /* 1.0 / (1.0 + INF) = 0 */
f = (float)0.0;
else if (f == (float)FLT_MIN) /* 1.0 / (1.0 + 1.0) = 0.5 */
f = (float)0.5;
else
f = (float)1.0 / ((float)1.0 + f);
return(f);
}

```

```

int mlp(float *inputs, float *outputs)
{
float hidden1_outputs[HIDDEN1_NODES];
float sum;
unsigned i,j;
float final_inputs[REDUCED_INPUTS];

/* zscore input normalization */
for (i=0; i<REDUCED_INPUTS; i++)
final_inputs[i] = (float)((inputs[i] - zs_input_mean[i]) /
zs_input_stdv[i]);

inputs = final_inputs;

for (i=0; i<HIDDEN1_NODES; i++)          /* hidden layer 1 */
{
sum = hidden1_weights[i][REDUCED_INPUTS]; /* threshold */
for (j=0; j<REDUCED_INPUTS; j++)
sum += hidden1_weights[i][j] * inputs[j];
hidden1_outputs[i] = tanhoid(sum);        /* tanh transfer */
}

for (i=0; i<NUM_OUTPUTS; i++)          /* output layer */
{
sum = output_weights[i][HIDDEN1_NODES]; /* threshold */
for (j=0; j<HIDDEN1_NODES; j++)
sum += output_weights[i][j] * hidden1_outputs[j];
outputs[i] = sigmoid(sum);              /* sigmoid output */
}

return(0);
}

```

ANEXO III

Palavras relevantes utilizadas no treinamento da rede neural

acessar	cd	efetuar	<i>login</i>	participar
aparecer	chave	entregar	loja	pesquisar
aplicativo	chegar	enviar	mandar	programa
aquecimento	começar	equipe	manual	questionário
arquivo	computador	fase	material	receber
boleto	confirmação	iniciar	mensagem	responder
br	conseguir	inscrição	não	resultado
cadastrar	dados	instalar	pagamento	resultados
carga	data	jogo	pagar	senha
carregar	decisões	ligação	participantes	taxa

Palavras que deram origem aos fonemas utilizados no treinamento da rede neural