

Reconhecimento de padrões na avaliação de distúrbios vocais em docentes

Pattern recognition in the evaluation of vocal disorders in teachers



Resumo

O objetivo deste artigo é apresentar uma metodologia para a avaliação de distúrbios vocais em docentes, tomando por base dados de docentes de uma escola localizada no município de Curitiba (PR). Para tanto, foram analisados registros históricos de cem docentes, cada um deles com dez informações (atributos), bem como suas respectivas classificações (sugestão para: aumentar, diminuir ou manter a carga horária, visando à saúde e ao bem-estar desses profissionais). Com a utilização do processo KDD (Knowledge Discovery in Databases, ou Descoberta de Conhecimento em Bases de Dados), primeiramente, os atributos foram codificados e, em seguida, na etapa de Data Mining (ou Mineração de Dados), foram utilizadas duas técnicas para o Reconhecimento de Padrões. Essas técnicas, Redes Neurais Artificiais (RNAs) e da Função Discriminante Linear de Fisher (FDLF), tiveram as suas acurácias comparadas apresentando 91,35% e 72,12%, respectivamente. Dessa forma, a especialista (fonoaudióloga da escola) terá um respaldo adicional, a partir das RNAs, para o problema aqui analisado, e para o diagnóstico quanto à classificação de novos padrões (docentes).

Palavras-chave: Processo KDD. Mineração de Dados. Redes Neurais Artificiais. Função Discriminante Linear de Fisher.

Abstract

The goal of this paper is to present a methodology for evaluating the severity of vocal disorders in teachers, based on data from a school located in the city of Curitiba (PR). The research was based on the analysis of historical data about 100 teachers, considering ten attributes for each of them and also their respective classification (as suggested: to increase, to reduce or to maintain to workload, aiming to improve the teachers' health and wellbeing). By using the Knowledge Discovery in Databases (KDD) process, firstly the attributes were codified and then, in the stage of Data Mining, two pattern recognition techniques were used. Those techniques – Artificial Neural Networks (ANNs) and the Fisher Linear Discriminant Function (FLDF) – had their accuracy levels compared, presenting 91.35% and 72.12% respectively. Therefore, the expert will have additional support, by using ANNs for the problem under analysis, for diagnosing and classifying new patterns (in teachers).

Keywords: KDD Process. Data Mining. Artificial Neural Networks. Fisher Linear Discriminant Function.

¹ Mestre em Métodos Numéricos em Engenharia pela UFPR. E-mail: diva_mbl@yahoo.com.br.

² Doutora em Engenharia da Produção pela UFSC. Pós-doutorado no ITA. Professora Associada da UFPR (1978-2010). Professora da PUC-PR no Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS). E-mails: tere@ufpr.br; maria.steiner@pucpr.br.

³ Doutora em Engenharia da Produção pela UFSC. Professora da UFPR do Departamento de Expressão Gráfica e Programas de Pós-Graduação em Métodos Numéricos em Engenharia (PPGMNE) e de Engenharia de Produção (PPGEP). E-mail: deise@ufpr.br.

Introdução

A saúde pode ser entendida como o estado dinâmico de equilíbrio entre os seres humanos e seu meio físico, biológico e social, compatível com as atividades funcionais. A saúde no trabalho, de forma análoga, é um estado de equilíbrio entre o trabalhador e os meios de produção com os quais ele interage (PACHECO et al., 2005).

Segundo Rua et al. (2010), são muitos os trabalhos que exigem ritmo acelerado — horas extras não remuneradas, pressão hierárquica, instabilidade no emprego, uso excessivo da voz, dentre outros —, provocando fadiga, sofrimento mental, estresse, desmotivação, anulando a capacidade de raciocínio e de criatividade do trabalhador.

A voz é um importante instrumento de comunicação e, para os docentes, ocupa lugar de destaque, já que influencia na relação entre professor e alunos. Segundo Jardim (2006), várias pesquisas têm mostrado prevalência de disфония em professores. Esses resultados reforçam a necessidade de melhorias nas condições ambientais e organizacionais das escolas, além da análise de fatores externos.

A voz é um importante instrumento de comunicação e, para os docentes, ocupa lugar de destaque, já que influencia na relação entre professor e alunos.

Existem muitos fatores de risco para a voz aos quais os docentes estão suscetíveis, e dentre esses riscos se podem destacar os seguintes: a não hidratação do organismo e falar em ambientes secos e empoeirados; falar com ataques vocais bruscos; tossir excessivamente ou pigarrear; falar em ambientes ruidosos ou abertos (competição vocal); utilizar tom grave ou agudo demais; falar excessivamente durante quadros gripais ou crises alérgicas; dentre outros.

Assim, a orientação preventiva, sob supervisão médica e fonoaudiológica, torna-se fator imprescindível para a saúde vocal dos docentes. Além disso, as atividades mais indicadas para quem utiliza a voz profissionalmente são: a natação, caminhadas, ginástica sem impacto, exercícios de alongamento e ioga, ou seja, atividades em que não há nenhuma movimentação violenta que causaria tensão muscular nas regiões do pescoço, ombro, tórax e costas.

O objetivo principal desse trabalho é encontrar uma técnica capaz de classificar o grau de distúrbio vocal de um docente com a maior precisão possível, a partir de dados coletados de docentes preliminarmente classificados. Desse modo, ter-se-á um respaldo adicional ao diagnóstico da especialista na área, no caso, de uma fonoaudióloga, em cumprir para com o interesse da escola de prevenir e/ou detectar precocemente possíveis disfonias em seus docentes.

Buscando alcançar esse objetivo, foram utilizadas duas técnicas bastante consagradas na literatura, as Redes Neurais Artificiais (RNAs) e a Função Discriminante Linear de Fisher (FDLF), com a intenção de comparar seus resultados verificando qual delas oferece o menor percentual de erros, ou seja, a que apresenta o melhor desempenho em realizar tal classificação.

1 Aspectos Gerais sobre a Fonaudiologia

O objetivo da fonaudiologia é a manutenção ou o retorno a uma função vocal normal, e, para isso, todas as causas devem ser analisadas. Segundo Behlau e Pontes (1995), a voz é produzida na laringe que, por sua vez, é constituída por pregas vocais; assim, ao inspirar, o ar entra nos pulmões e as pregas vocais se afastam, e ao expirar, o ar sai dos pulmões e, passando pela laringe, causa a vibração das pregas vocais. Nesse momento, é produzido um som de pequena intensidade que é amplificado nas cavidades de ressonância (laringe, faringe, boca e nariz) e se transforma em diversos sons da fala por meio dos movimentos dos órgãos miofuncionais (boca, língua, lábios, bochechas, mandíbula, dentes e palato). Assim sendo, para que o som seja produzido com boa qualidade, há necessidade da integridade dos sistemas respiratório e digestivo, assim como de toda musculatura envolvente neste processo.

Além desses aspectos, a carga afetiva também influencia na alteração da voz, sendo assim, cada pessoa possui uma qualidade vocal individual e, portanto, algumas pessoas são mais suscetíveis às disfonias do que outras. A voz é adquirida e vai se formando conforme nosso crescimento físico e emocional.

A carga afetiva também influencia na alteração da voz, sendo assim, cada pessoa possui uma qualidade vocal individual e, portanto, algumas pessoas são mais suscetíveis às disfonias do que outras.

Segundo Pinho (1997), muitos utilizam a voz de forma inadequada em sua profissão, podendo danificar os tecidos da laringe e produzir um distúrbio vocal. Por isso, orientações sobre o mecanismo de produção da voz, noções de higiene bucal e técnica vocal são indispensáveis para auxiliar esses profissionais na manutenção da qualidade da própria voz.

Dessa forma, é importante determinar o comportamento vocal do professor, as situações de abuso vocal e os possíveis agentes prejudiciais à voz, assim como a influência de fatores psicológicos e de estresse, pois todos esses dados são importantes para a orientação e o tratamento das alterações vocais.

2 Coleta de Dados

Os dados utilizados para o desenvolvimento deste trabalho foram obtidos junto a uma instituição de ensino da cidade de Curitiba (PR), cuja fonoaudióloga forneceu os critérios de cem docentes, já avaliados e, conseqüentemente, já classificados. O objetivo da escola é de, a partir da análise dos dados de cada docente, determinar o seu grau de distúrbio, podendo sugerir a carga horária que lhe será mais adequada.

No QUADRO 1, apresentado mais abaixo, têm-se os dez critérios e suas respectivas variáveis utilizados pela escola para a classificação da gravidade de distúrbios vocais de seus docentes. A pontuação contida na terceira coluna desse quadro, definida pela fonoaudióloga da escola, varia de zero (menor impacto sobre a voz) até 7 (maior impacto). A forma atual utilizada pela fonoaudióloga para a classificação do distúrbio vocal do docente, apresentada no QUADRO 2, é de acordo com a soma acumulada pela pontuação.

A fim de se tentar obter um desempenho mais apurado das técnicas utilizadas (RNAs e FDLF), os critérios contidos no QUADRO 1 foram tratados de duas formas. Na primeira, os dez critérios definem as 'entradas' para as técnicas,

cujos valores variam de 0 a 7; na segunda, as variáveis são, primeiramente, transformadas em coordenadas binárias que formaram, então, as 'entradas' para as técnicas, conforme dados ilustrativos de um exemplo contidos na quarta coluna do QUADRO 1. Assim, se o docente possui 'tempo de docência' (critério 8) 'de até 5 anos ou acima de 20 anos', ele terá uma pontuação igual a '2' como entrada para o primeiro caso; já para o segundo caso, ele terá uma entrada igual a '1'.

Já com relação às saídas ('valores desejados' ou grupos ou classes, na aplicação de ambas as técnicas, RNAs e FDLF), apresentadas no QUADRO 2, trabalhou-se de diversas formas, visando o melhor desempenho possível.

Tais formas estão detalhadas a seguir:

- apenas uma saída pertencente ao intervalo (0; 1). Nesse caso, os padrões pertencentes ao grupo 1 (caso leve) deverão ter uma saída pertencente ao intervalo (0; 0,25); ao grupo 2 (caso leve a moderado), saída no intervalo [0,25; 0,5); ao grupo 3 (caso moderado), saída no intervalo [0,5; 0,75); e ao grupo 4 (caso grave), saída no intervalo [0,75; 1);
- da mesma forma, com apenas uma saída pertencente ao intervalo (0; 1), mas com diferente interpretação. Nesse caso, a saída contida no intervalo de (0; 0,5) indicará que o docente se enquadra em um dos quatro grupos, e a saída contida no intervalo de [0,5; 1) se enquadra nos demais três grupos. Nesse caso, ambas as técnicas deverão ser aplicadas quatro vezes, uma para cada grupo de classificação. Posteriormente, ao se testar um novo padrão, este deverá ser testado quatro vezes (uma vez para cada grupo) e pertencerá ao grupo que fornecer o maior valor (o mais próximo de '1');
- análoga ao caso 2 anterior, mas com duas saídas. Nesse caso, a saída (1; 0) indicará que o docente se enquadra em um dos quatro grupos e a saída (0; 1), que se enquadra nos demais três grupos;
- com quatro saídas. Nesse último caso, os padrões pertencentes ao grupo 1 deverão ter uma saída do tipo (1; 0; 0; 0); ao grupo 2 (0; 1; 0; 0); ao grupo 3 (0; 0; 1; 0); e ao grupo 4 (0; 0; 0; 1).

QUADRO 1 – Critérios (atributos) e suas respectivas variáveis utilizadas pela escola

continua

Critério	Variáveis	Pontuação para as variáveis	Variáveis com codificação binária
1. Fatores de risco	1. Ausentes	0	0
	2. RGE / ou suspeita de RGE	3	1
	3. Atopia / ou suspeita de atopia	3	1
	4. Tabagismo	3	0
2. Medidas de Prevenção: aquecimento vocal e ingestão de água	5. Cumpre os 2	0	0
	6. Cumpre só 1	1	1
	7. Cumpre nenhum	2	0
3. Fonoterapia	8. Não necessita / Alta fonoterápica	0	0
	9. Realiza regularmente	1	1
	10. Interrupção / Realiza irregularmente	3	0
	11. Não realiza, apesar da indicação	5	0

QUADRO 1 – Critérios (atributos) e suas respectivas variáveis utilizadas pela escola

conclusão

Critério	Variáveis	Pontuação para as variáveis	Variáveis com codificação binária
4. Sintomas vocais	12. Ausentes	0	1
	13. Não associados a patologia	3	0
	14. Associados a patologia	5	0
5. Patologia	15. Ausente	0	0
	16. Adquirida	3	1
	17. Congênita	5	0
6. Cirurgia	18. Não necessita	0	1
	19. Indicada, mas não realizada	4	0
	20. Realizada há menos de um ano	3	0
	21. Realizada há mais de um ano	2	0
7. Carga horária total atual (semanal)	22. até 25 horas/aula	1	0
	23. de 26 a 35 h/a	2	1
	24. de 36 a 45 h/a	4	0
	25. de 46 a 55 h/a	5	0
	Acima de 55 h/a	7	0
8. Tempo de docência	26. Até 5 anos ou acima de 20 anos	2	1
	27. 6 a 19 anos	1	0
9. Outra profissão da voz – não docente (exemplo: cantor)	Não	0	1
	Uso profissional da voz esporádico	1	0
	Uso profissional da voz freqüente	4	0
10. Uso de microfonedocência	28. Sim	0	1
	29. Não	1	0

FONTE: Dados da Pesquisa

QUADRO 2 – Pontuação utilizada pela escola (classificação atual)

Pontuação	Classificação	Sugestão de Carga Horária
0 a 10	Caso leve	Aumentar até 10 h/a
11 a 15	Caso leve a moderado	Aumentar até 5 h/a
16 a 25	Caso moderado	Manter carga horária
26 ou mais	Caso grave	Reduzir carga horária

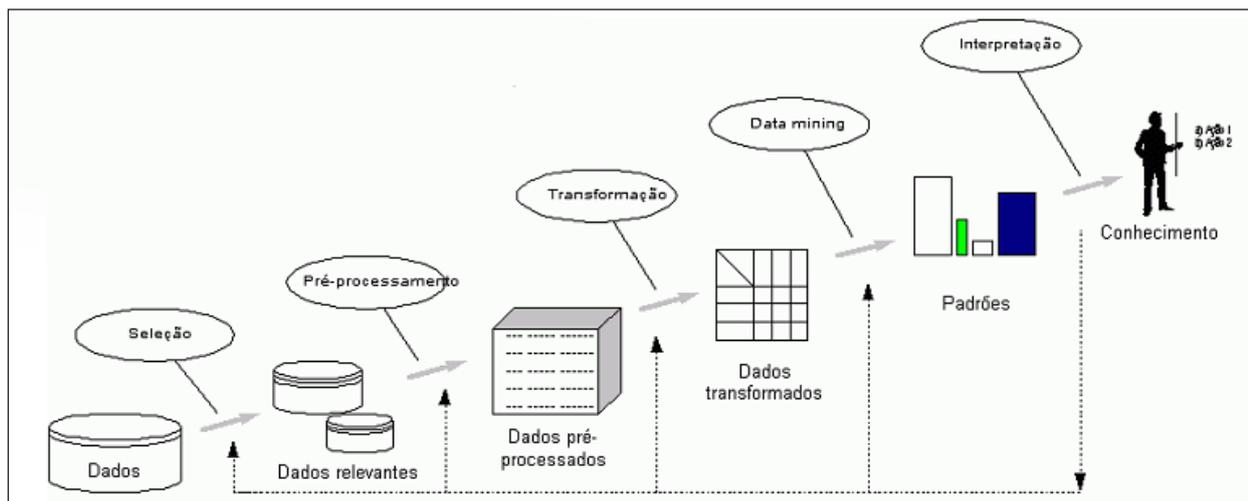
FONTE: Dados da Pesquisa

3 Metodologia

Com a finalidade de analisar, discriminar e classificar esses dados, utilizou-se o processo KDD (*Knowledge Discovery in Databases*, ou seja, Descoberta de Conhecimento em Bases

de Dados) que, segundo Fayyad et al. (1996), é composto de cinco etapas: seleção dos dados; pré-processamento e limpeza dos dados; transformação dos dados; mineração de dados (*Data Mining* ou reconhecimento de padrões – principal etapa do processo KDD); interpretação e avaliação dos resultados, conforme FIG. 1.

FIGURA 1 – Etapas do Processo KDD



FONTE: Fayyad et al. (1996)

Segundo Lemos, Steiner e Nievola (2005), o processo de KDD começa com o entendimento do domínio da aplicação e dos objetivos finais a serem atingidos. A partir dessa etapa, os dados são selecionados de acordo com os critérios definidos; na etapa de pré-processamento ou limpeza dos dados, são removidas as informações julgadas desnecessárias. Os dados pré-processados devem, ainda, passar por uma transformação que os armazena adequadamente, facilitando o uso das técnicas de *Data Mining*. Para o presente trabalho, as três primeiras etapas do processo KDD foram detalhadas na seção 3 anterior, em que já se realizou a seleção e a limpeza dos dados, assim com a sua codificação (binária).

Após essas etapas, chega-se à fase de *Data Mining*, que começa com a escolha das ferramentas (algoritmos) a serem utilizadas, essa escolha depende fundamentalmente do objetivo do processo de KDD: classificação, agrupamento, associação ou outras dos padrões. Essas ferramentas deverão procurar por padrões no comportamento dos dados.

Como o presente trabalho objetiva a classificação de padrões, na etapa de *Data Mining* foram utilizadas duas técnicas, conforme já comentado: a FDLF e as RNAs. Essas duas técnicas tiveram seus desempenhos comparados,

com o objetivo de se utilizar, a técnica com melhor acurácia para a classificação de novos padrões.

Ao final do processo, o sistema de *Data Mining* gera um relatório das descobertas, o qual será interpretado pelos analistas, no caso, a fonoaudióloga da escola. Após essa interpretação, encontra-se conhecimento. Vale salientar que a utilização de tais técnicas objetiva fornecer um respaldo adicional aos especialistas das mais diversas áreas, detentores de toda a experiência e intuição.

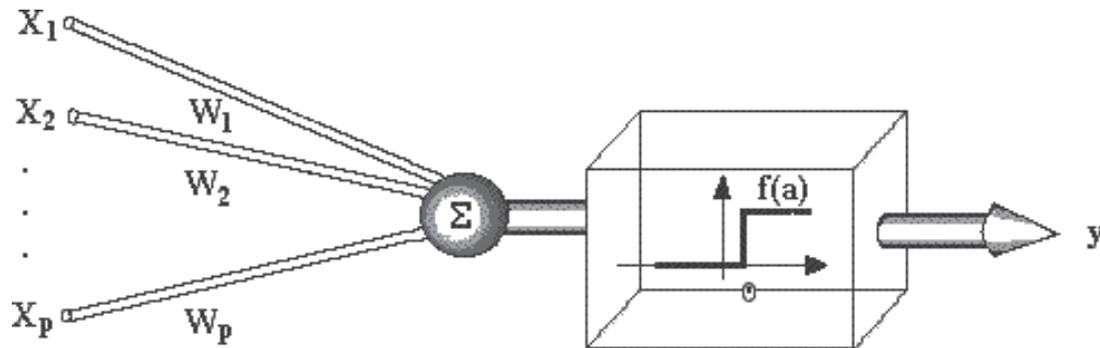
4 Redes Neurais Artificiais (RNAs)

Baseado nos estudos do cérebro, nas ideias de redes de neurônios e nos modelos dos neurônios, foram propostas as estruturas de redes neurais ou redes de neurônios artificiais. No entanto, uma RNA pode ter centenas ou milhares de unidades de processamento, enquanto o cérebro de um mamífero possui bilhões de neurônios (OLIVEIRA, 2002).

Segundo Tonsig (2000), as primeiras informações sobre neurocomputação surgiram em 1943, em artigos do neurofisiologista Warren McCulloch, do Instituto Tecnológico de Massachusetts, e do matemático Walter Pitts, da Universidade de Illinois.

Ambos fizeram uma analogia entre células nervosas vivas e o processo eletrônico, simulando o comportamento do neurônio natural, no qual o neurônio possuía apenas uma saída, a qual era uma função da soma de valor de suas diversas entradas, conforme ilustrado na FIG. 2.

FIGURA 2 – Neurônio Artificial projetado por MCCulloch e Pitts



FONTE: Tonsig (2000)

Na FIG. 2, o vetor x representa um conjunto de p entradas, que multiplicado por um vetor peso w nos fornece o produto $p = x w$, aplicado aos canais de entrada do neurônio. A função de ativação, $F(x)$, que produz o sinal de saída do neurônio (binária ou contínua), é dada pela expressão (1):

$$y = F\left(\sum_0^p x_i w_i\right), \text{ para } x_0 = 1 \text{ e } w_0 = \theta, \quad (1)$$

sendo que o parâmetro θ é o bias ou vício, que aumenta o número de graus de liberdade disponíveis no modelo, permitindo que a RNA tenha maior capacidade de se ajustar ao conhecimento a ela fornecido.

Todo o conhecimento de uma RNA está armazenado nas sinapses que são os pesos atribuídos às conexões entre os neurônios. Segundo Tatibana e Kaetsu (2009), de 50% a 90% do total de padrões deve ser separado para o treinamento da RNA, escolhidos aleatoriamente para que a rede realmente ‘aprenda’ as regras. O restante dos dados apenas é apresentado à RNA na fase de testes, a fim de averiguar a capacidade de generalização da rede, ou seja, o quanto a rede, de fato, ‘aprendeu’.

Ainda segundo Tatibana e Kaetsu (2009), existem seis passos necessários para o desenvolvimento de aplicações utilizando RNAs. Os dois primeiros passos do processo para o treinamento

de RNAs são, conforme já comentado, a coleta de dados relativos ao problema e a separação desses dados em um conjunto de treinamento e outro de testes.

O terceiro passo é a definição da configuração da rede, que pode ser dividida em três etapas: seleção do paradigma neural apropriado à aplicação, determinação da topologia da rede a ser utilizada — o número de camadas e o número de unidades em cada camada — e a determinação de parâmetros do algoritmo de treinamento e funções de ativação. Esse passo tem grande impacto no desempenho do sistema resultante.

O quarto passo é o treinamento da rede. Nessa fase serão ajustados os pesos das conexões, nas quais, geralmente, os valores iniciais são números aleatórios uniformemente distribuídos, em um intervalo definido. Uma escolha adequada dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento; por outro lado, a escolha errada desses pesos pode levar a uma saturação prematura.

O treinamento deve ser interrompido quando a rede apresentar uma capacidade apropriada de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima.

O quinto passo é o teste da rede, sendo que o desempenho é uma boa indicação do

desempenho real. Durante essa fase, o conjunto de teste é utilizado para determinar o desempenho da rede com padrões que não foram utilizados durante o treinamento. Finalmente, com a rede treinada e avaliada (testada), pode-se integrá-la a um sistema do ambiente operacional da aplicação. Esse é o sexto passo: integração.

São muitos os modelos de RNAs, dentre os quais se pode citar: o Perceptron, Redes Lineares e Redes de Múltiplas Camadas, que são as mais comuns; e outras, como Redes de Base Radial, Redes Recorrentes, Redes de Hopfield, Redes de Kohonen e Redes Construtivas. O modelo que foi utilizado nesse trabalho foi o das Redes de Múltiplas Camadas.

As Redes de Múltiplas Camadas, ou também chamadas de Redes *Feed-Forward* (alimentadas para a frente), formam um sistema artificial composto de células elementares — neurônios — organizadas em camadas sucessivas que são conectadas entre si. Essas redes foram criadas generalizando a regra de aprendizagem de *Windrow-Hoff* para redes de múltiplas camadas e funções de transferência diferenciáveis não lineares, podendo ser treinadas com o algoritmo de treinamento *back-propagation*, dividido em duas fases: as propagações *forward* e *backward*, cujos vetores de entrada e saída são usados para treinar a rede até que ela possa aproximar uma função que classifique os vetores de entrada de maneira apropriada.

Essas redes frequentemente usam função de transferência sigmoide, que gera saídas no intervalo (0, 1) para entradas variando no intervalo $(-\infty, +\infty)$ e, em geral, possuem três camadas: a de entrada, cujos padrões são apresentados à rede; a intermediária ou oculta, na qual é realizado o processamento; e a de saída, que apresenta os valores de saídas da rede. Cada uma dessas camadas é totalmente conectada à camada seguinte e à anterior. O sinal que chega à camada de entrada se propaga, camada a camada, até a saída. Os valores de saída para cada um dos padrões são comparados com os valores desejados para os padrões e o erro E é calculado. Com base no valor do erro, os pesos da rede são ajustados.

Dessa forma, os parâmetros que caracterizam uma rede multicamada são os seguintes: número de camadas, número de neurônios por camada, escolha dos valores iniciais para as conexões (pesos), tipo

de funções de ativação dos neurônios e valores iniciais aos parâmetros α (taxa de momento) e γ (taxa de aprendizagem), assim como a forma de ajuste desses dois parâmetros.

A propriedade mais importante das RNAs é a habilidade de aprender a partir de seu ambiente e, com isso, melhorar seu desempenho. Modelos de RNAs podem lidar com dados imprecisos e situações não totalmente definidas. Uma rede treinada tem a habilidade de generalizar quando é apresentada a entradas que não estavam presentes nos dados já conhecidos por ela.

5 Função Discriminante Linear de Fisher (FDLF)

O método estatístico abordado nesse trabalho, a FDLF, pode ser apresentado da seguinte forma: dadas duas populações de observações multivariadas com certa dimensão n , a ideia de Fisher foi transformar essas observações multivariadas em observações univariadas, tal que estejam separadas tanto quanto possível. Devem-se determinar variáveis que melhor discriminem esses grupos, utilizando essas variáveis para criar funções discriminantes que serão utilizadas para alocar novos indivíduos, objetos ou observações no grupo mais adequado (a função discriminante otimiza a alocação de novos padrões). Outro fator importante é que esse método é de fácil cálculo, pois utiliza a combinação linear das observações multivariadas para criar as observações univariadas.

Segundo Johnson e Wichern (1998), foi Ronald A. Fisher que introduziu a terminologia 'discriminar' e 'classificar' no primeiro tratamento moderno dos problemas de separação de conjuntos na década de 1930. O objetivo básico do método de Fisher é separar populações, além de também poder ser usado com o propósito de classificar. Esse método pode ser usado tanto para duas populações quanto para diversas populações.

6 Resultados

De cada docente (padrão), foram obtidas dez informações (critérios) contidas no QUADRO 1 e, a partir delas, 33 variáveis (2ª coluna do QUADRO 1). Dentre os cem docentes, nenhum apresentou o critério 9 (outra profissão da voz — não docente), nem o critério 7 (acima de 55 h/a), sendo então retirados. Assim, têm-se nove critérios e 29 variáveis.

Os algoritmos (RNAs e FDLF) foram programados no MATLAB e, em ambas as técnicas utilizou-se o procedimento de avaliação *holdout*, que separa dois terços dos dados para o treinamento das técnicas e um terço para os testes das técnicas. Além disso, a amostragem foi estratificada, assegurando que cada grupo seria representado de forma proporcional nos dois conjuntos de dados (treinamento e teste).

Ao mesmo tempo, com a finalidade de avaliar as técnicas utilizadas, calculou-se a Taxa Aparente de Erro (APER) para cada um dos resultados apresentados. Segundo Mendes, Fiúza e Steiner (2010), essa taxa é definida como sendo a fração das observações no treinamento amostral referente ao reconhecimento errôneo pela função obtida, e deve ser interpretada como a proporção de observações classificadas incorretamente. Essa taxa é calculada pela Matriz de Confusão que apresenta a situação real das observações nos grupos comparando-a com o reconhecimento apresentado pelo modelo encontrado.

Para o treinamento das RNAs, utilizou-se o algoritmo *back-propagation* e foram desenvolvidas oito redes, alterando o número de neurônios das camadas de entrada, escondida e de saída. Serviu-se apenas de uma camada escondida, pois, segundo o Teorema de Kolmogorov (KRÖSE; VAN DER SMAGT, 1993), uma RNA com apenas uma camada oculta pode calcular uma função arbitrária qualquer a partir dos dados fornecidos.

Foram utilizados dois tipos de entradas: nove entradas, referente aos nove critérios e 29 entradas, que se referem às variáveis; redes de

uma saída, duas saídas e quatro saídas (conforme já explicitado anteriormente) e, a camada oculta com número de neurônios variando de zero a 20 neurônios, tendo-se, assim, quatro testes (testes de I a IV no QUADRO 3, a seguir).

O treinamento da FDLF foi feito de forma semelhante. Nesse caso, foram desenvolvidos dois programas, um para o caso de duas amostras (dois grupos a serem discriminados), e outro para mais de três amostras (utilizado para o caso de discriminação dos quatro grupos). Então, foram realizados dois testes (testes V e VI no QUADRO 3). Em ambas as técnicas, os melhores resultados foram encontrados no caso de se ter dois grupos a serem discriminados, conforme se pode observar no teste IV para as RNAs e teste VI para a FDLF, no QUADRO 3. Esse quadro mostra os melhores resultados de todos os treinamentos realizados, especificando a topologia, as classes, o número de neurônios nas camadas de entrada, escondida e de saída, e o percentual de acerto em cada simulação.

QUADRO 3 – Melhores resultados obtidos através das duas técnicas utilizadas

Técnica	Teste	Classes	Entrada	Neurônios Oculta	Saída	% de Acertos
RNAs	I		29	6	1	75
	II		9	16	4	60,71
	III	1; 2; 3; 4	9	16	1	96,15
	III	1 e 2; 3; 4	29	12	1	88,46
	III	2 e 1; 3; 4	29	7, 9, 15	1	57,69
	III	3 e 1; 2; 4	9	0	1	92,31
	IV	1 e 2; 3; 4	29	0	2	100
	IV	2 e 1; 3; 4	9	5	2	96,15
	IV	3 e 1; 2; 4	9	12	2	80,77
	IV	4 e 1; 2; 3	9 e 29	4, 10, 11, 13, 18, 19	2	88,46
FDLF	V		9	-	4	57,14
	VI	1; 2; 3; 4	9	-	2	84,62
	VI	1 e 2; 3; 4	9	-	2	53,85
	VI	2 e 1; 3; 4	9	-	2	69,23
	VI	3 e 1; 2; 4	9	-	2	80,77

FONTE: As autoras

Conclusão

Como se pôde observar no QUADRO 3, as RNAs e a FDLF apresentaram um melhor desempenho nos testes IV e VI, respectivamente, ou seja, ao se ter dois conjuntos a serem discriminados. Conforme já mencionado, esses dois testes foram realizados em quatro etapas: I) separou-se os padrões em dois grupos (um grupo contendo os padrões da 1ª classe — caso leve —, e o outro contendo os padrões das demais três classes, 2ª, 3ª e 4ª classes); II) separou-se novamente os padrões em dois grupos (um contendo os padrões da 2ª classe — caso leve a moderado —, e o outro contendo os padrões das demais três classes: 1ª, 3ª e 4ª classes). E, assim, procedeu-se para as outras duas etapas.

Para cada uma dessas quatro situações do teste IV (RNAs; melhores resultados dentre as duas técnicas abordadas), os pesos foram devidamente registrados. Assim, ao se apresentar um novo padrão (docente), com as suas respectivas 29

variáveis devidamente codificadas, teremos de avaliar cada uma dessas quatro situações para esse docente, verificando em qual delas o seu percentual será maior. Tal situação, que fornece o maior percentual, será, então, a classe desse novo padrão. A acurácia média será de 91,35%, obtido pela média das acurácias do teste IV do QUADRO 3.

Como esses resultados do QUADRO 3 foram satisfatórios, conclui-se que as técnicas aqui apresentadas podem ser utilizadas com segurança pela fonoaudióloga da escola, auxiliando-a na classificação dos docentes quanto aos distúrbios vocais. Assim, tem-se um respaldo adicional quanto à decisão/sugestão se os docentes poderão aumentar, manter ou diminuir sua carga horária de trabalho.

Pode-se tornar este estudo, em um trabalho futuro, mais abrangente, realizando a avaliação dos riscos do uso da voz na ação profissional como um todo, não somente para o âmbito da docência.

- Recebido em: 07/01/2012
- Aprovado em: 16/04/2012

Referências

- BEHLAU, M.; PONTES, P. **Avaliação e tratamento das disfonias**. São Paulo: Lovise, 1995.
- FAYYAD, Usama M... [et al.]. **Advances in knowledge discovery & data mining**. Menlo Park, Calif.: AAA Press: MIT Press, [c1996].
- JARDIM, R. **Voz, trabalho docente e qualidade de vida**. 75 f. 2006. Dissertação (Mestrado do Programa de Pós-Graduação em Saúde Pública) - Universidade Federal de Minas Geais, Belo Horizonte, 2006.
- JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4th. Upper Saddle River, NJ: Prentice-Hall, 1998.
- KRÖSE, B. J. A.; VAN DER SMAGT, P. P. **An Introduction to neural networks**. Amsterdam: University of Amsterdam, 1993.
- LE MOS, E. P.; STEINER, M. T. A.; NIEVOLA, J. C. Análise de crédito bancário por meio de redes neurais e árvores de decisão: uma aplicação simples de Data Mining. **Revista de Administração**, São Paulo, v. 40, n. 3, p.225-34, jul./set. 2005.
- MENDES, K. B.; FIUZA, R. M.; STEINER, M. T. A. Diagnosis of headache using artificial neural Networks. **International Journal of Computer Science and Network Security**, v. 10, n. 7, p. 172-178, 2010.
- OLIVEIRA, C. **Redes neurais**. São Paulo, 2002. Disponível em: <<http://www.lem.ep.usp.br/Pef411/~Cristiano%20Oliveira/CristianoOliveira/Paginas/RedesNeurais.htm>>. Acesso em: 29 dez. 2009.
- PACHECO, W. et al. A Era da tecnologia da informação e comunicação e a saúde do trabalhador. **Revista Brasileira de Medicina do Trabalho**, Rio de Janeiro, v. 3, n. 2, p. 114-122, 2005.
- PINHO, S. M. R. **Manual de higiene vocal para profissionais da voz**. Carapicuíba, SP: Pró-Fono, 1997.
- RUA, M. P. A. et al. Transtornos traumáticos cumulativos em bancários. **Revista Brasileira de Medicina do Trabalho**, Rio de Janeiro, v. 8, n. 2, p. 60-67, 2010.
- TATIBANA, C. Y; KAETSU, D. Y. **Uma Introdução às redes neurais**. Disponível em: < <http://www.din.uem.br/~ia/neurais/>>. Acesso em: 25 maio 2009.
- TONSIG, S. L. **Redes neurais artificiais multicamadas e o algoritmo backpropagation**. 2000. Disponível em: <<http://funk.on.br/esantos/doutorado/INTELIG%CANCIA%20ARTIFICIAL/T%C9CNICAS/REDES%20NEURAS/Redes%20Neurais%20Artificiais%20Multicamadas/Backp.PDF>>. Acesso em: 15 jun. 2010.

