

Discriminação de Sinais de Voz com Análise de Quantificação de Recorrência e Redes Neurais MLP

Vinícius J. D. Vieira, Silvana C. Costa, Washington C. de A. Costa, Suzete E. N. Correia e F. M. de Assis

Resumo—Este artigo trata da discriminação entre vozes saudáveis e vozes afetadas por patologias na laringe a partir da análise de quantificação de recorrência e redes neurais *Multilayer Perceptron* (MLP). São empregadas quinze características obtidas dos gráficos de recorrência. As patologias laringeas consideradas são: paralisia, edema e nódulos nas pregas vocais. A classificação é realizada com cada medida de recorrência, individualmente, e de forma combinada. A maior taxa de acurácia obtida foi de 99,11%, na classificação entre sinais de vozes saudáveis e sinais de vozes afetadas por nódulos vocais.

Palavras-Chave—Análise de Quantificação de Recorrência, Redes MLP, Patologias laringeas, Processamento de sinais de voz.

Abstract—This article deals with the discrimination between healthy and voices affected by laryngeal pathologies using recurrence quantification analysis and Multilayer Perceptron neural networks (MLP). Fifteen features from the recurrence plots are employed. The considered pathologies are: vocal folds paralysis, edema and nodules. The classification is made with each individual recurrence measure and from their combination. The highest rate of accuracy obtained was 99.11%, on the classification between healthy and pathological voices affected by vocal nodules.

Keywords—Recurrence Quantification Analysis, MLP neural networks, laryngeal pathologies, speech signal processing.

I. INTRODUÇÃO

Medidas objetivas de análise acústica de voz tem sido buscadas para atuarem como instrumentos auxiliares a tratamentos laringeos. Patologias na laringe alteram o padrão de vibração das pregas vocais, afetando a qualidade vocal, trazendo prejuízos à comunicação oral, principalmente aos profissionais que utilizam a fala como instrumento de trabalho (cantores, locutores e professores). Sistemas de Telecomunicações podem ser desenvolvidos como meios de avaliação clínica remota, reduzindo o desconforto de exames invasivos, tais como a videolaringoscopia, e possibilitando o compartilhamento de prontuários [1].

Recentemente, o estudo da Análise de Quantificação de Recorrência tem sido empregado como ferramenta de avaliação da qualidade vocal [2]. A utilização dos gráficos de recorrência [3] e de suas medidas de quantificação [4],

Vinícius J. D. Vieira, Silvana C. Costa e Suzete E. N. Correia, Programa de Pós-Graduação em Engenharia Elétrica, Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, João Pessoa-PB, Brasil; Washington C. de A. Costa, Coordenação de Ciências da Natureza, Matemática e suas Tecnologias, Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, João Pessoa-PB, Brasil; F. M. de Assis, Departamento de Engenharia Elétrica, UFCG, Campina Grande-PB, Brasil. E-mails: viniciusjdv@gmail.com, silvana@ifpb.edu.br, washington@ifpb.edu.br, suzete@ifpb.edu.br, fmarcos@dee.ufcg.edu.br. Este trabalho foi parcialmente financiado pela CAPES.

[5] no processamento digital de sinais de voz considera as não linearidades intrínsecas ao sistema de produção da fala. Diversos fatores estão associados às não linearidades, entre os quais: a variação temporal da forma do trato vocal, as ressonâncias associadas à sua fisiologia, a radiação do som nos lábios, o acoplamento nasal e a flexibilidade (comportamento dinâmico) associada à vibração das pregas vocais [6].

Na Análise de Quantificação de Recorrência, medidas objetivas conhecidas como medidas de quantificação de recorrência, descrevem como estão distribuídos os pontos no gráfico de recorrência, representativo do sinal de voz em análise. Processos determinísticos apresentam gráficos com linhas diagonais totalmente preenchidas, ao contrário de processos estocásticos, os quais apresentam, predominantemente, pontos isolados nos Gráficos de Recorrência [7]. Assim, por exemplo, medidas baseadas em estruturas diagonais podem identificar se um processo é determinístico ou estocástico.

Em trabalhos anteriores [2], [8] a Análise de Quantificação de Recorrência é empregada em trechos não-estacionários de sinais de voz, com o objetivo de identificar a presença de patologias laringeas. Neste trabalho, além das medidas anteriormente avaliadas (Taxa de Recorrência, Determinismo, Comprimento máximo das estruturas diagonais, Entropia de Shannon, Laminaridade, Tempo de Permanência e Comprimento máximo das estruturas verticais), é investigado o potencial discriminativo de outras medidas, por meio da segmentação dos sinais em intervalos de tempo em que o sinal de voz ainda é considerado estacionário. As medidas empregadas, adicionalmente, são: Transitividade, a relação entre Determinismo e Taxa de Recorrência, o comprimento médio das estruturas diagonais, Divergência, Tempos de recorrência do tipo 1 e do tipo 2 e a entropia do tempo de recorrência do tipo 1. A classificação é realizada utilizando redes neurais MLP (*Multilayer Perceptron*). As principais contribuições deste trabalho estão centradas na avaliação do potencial discriminativo das medidas de recorrência, de forma individual e combinada, empregando o classificador MLP.

O trabalho está organizado como segue. Na Seção II, são apresentados os aspectos teóricos referentes aos gráficos de recorrência e suas medidas de quantificação. Na Seção III, a metodologia empregada, na Seção IV, os resultados obtidos. As conclusões são apresentadas na Seção V.

II. GRÁFICOS DE RECORRÊNCIA E SUAS MEDIDAS DE QUANTIFICAÇÃO

Os Gráficos de Recorrência foram propostos por [3] como uma técnica de análise de sistemas dinâmicos, a fim de

proporcionar uma visualização bidimensional do comportamento multidimensional desses sistemas no espaço de fases [9]. Basicamente, os Gráficos de Recorrência são matrizes quadradas preenchidas por zeros e uns. Nos pontos em que houver a unidade, significa que esses pontos são recorrentes, ou seja, os estados do sistema dinâmico, referentes a esses pontos, visitam regiões próximas uns dos outros na trajetória do espaço de fases.

Matematicamente, um Gráfico de Recorrência pode ser definido por:

$$\mathcal{R}_{i,j}^{m,\varepsilon} = \Theta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), \quad \vec{x}_i \in R^m, \quad i, j = 1 \dots N. \quad (1)$$

Em que \vec{x}_i representa cada um dos N estados do sistema, obtidos por meio do método dos atrasos temporais [10], o qual imerge a série temporal num espaço m -dimensional com tempo de defasagem τ . A distância entre os estados do sistema, $\|\cdot\|$, comumente é calculada por meio da norma euclidiana. O raio de vizinhança, ε , define quais pontos que são mapeados como recorrentes pela função de degrau unitário, $\Theta(\cdot)$.

Exemplos de Gráficos de Recorrência são apresentados na Figura 1. Em todos os casos foi utilizado um segmento de 800 amostras (32 ms) para a vogal sustentada /ah/, considerando um sinal de cada classe avaliada.

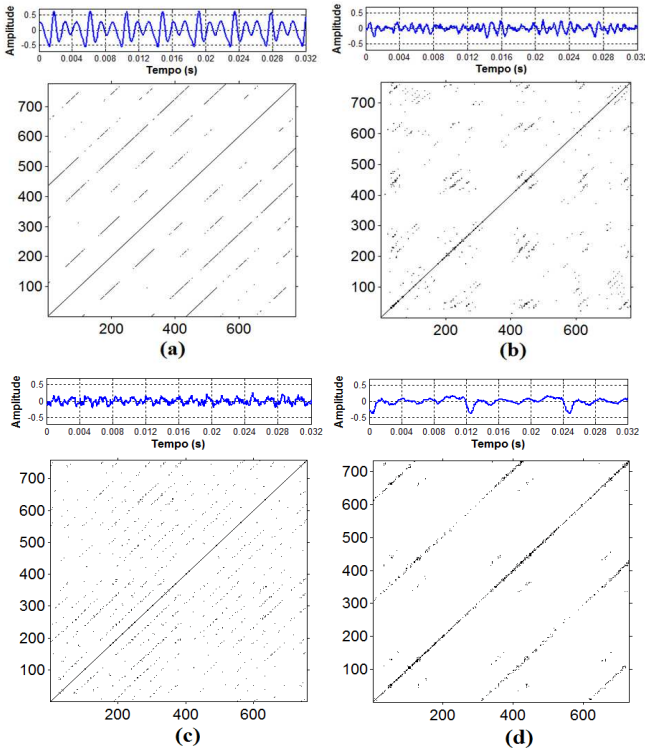


Fig. 1. Forma de onda e gráfico de recorrência para (a) um sinal de voz saudável ($m = 4$, $\tau = 8$), (b) um sinal de voz afetada por paralisia ($m = 6$, $\tau = 7$), (c) um sinal de voz afetada por edema ($m = 6$, $\tau = 9$), e (d) um sinal de voz afetada por nódulo vocal ($m = 4$, $\tau = 23$).

As medidas de quantificação de recorrência foram desenvolvidas no intuito de fornecer uma análise mais robusta e objetiva sobre o comportamento dos sistemas dinâmicos [4]. A primeira delas, conhecida como Taxa de Recorrência

(*REC*), simplesmente mede o percentual de pontos recorrentes presentes no gráfico de recorrência, e é definida como:

$$REC = \frac{1}{N^2} \sum_{i,j=1}^N \mathcal{R}_{i,j}^{m,\varepsilon}. \quad (2)$$

A medida Transitividade (*TRANS*) é uma espécie de taxa de recorrência local (*local clustering*), baseada na teoria das redes recorrentes complexas [11], sendo dada por:

$$TRANS = \frac{\sum_{i,j,k=1}^N \mathcal{R}_{i,j}^{m,\varepsilon} \mathcal{R}_{i,k}^{m,\varepsilon} \mathcal{R}_{k,i}^{m,\varepsilon}}{\sum_{i,j,k=1}^N \mathcal{R}_{i,j}^{m,\varepsilon} \mathcal{R}_{k,i}^{m,\varepsilon}}. \quad (3)$$

A Taxa de Recorrência pode ser utilizada em conjunto com o raio de vizinhança para a construção do Gráfico de Recorrência [2]. Dessa forma, o raio é escolhido de modo que a Taxa de Recorrência não ultrapasse determinado valor. Essa metodologia é empregada quando se deseja que outras medidas não tenham valores saturados [12], como é o caso da medida Determinismo (*DET*), definida por:

$$DET = \frac{\sum_{l=l_{min}}^N l \times P^\varepsilon(l)}{\sum_{i,j}^N \mathcal{R}_{i,j}^{m,\varepsilon}}, \quad (4)$$

em que $P^\varepsilon(l) = \{l_i, i = 1 \dots N_l\}$, representa a distribuição de frequência dos comprimentos l das N_l estruturas diagonais e l_{min} o número mínimo de estruturas diagonais que se deseja contabilizar dentro do gráfico de recorrência [5]. O Determinismo mede a quantidade dos pontos de recorrência presentes na formação das linhas diagonais em relação a todo o conjunto dos pontos de recorrência.

A relação entre Determinismo e Taxa de Recorrência, *RATIO*, pode descrever transições na dinâmica do sistema [5], e é dada por:

$$RATIO = N^2 \frac{\sum_{l=l_{min}}^N l \times P^\varepsilon(l)}{(\sum_{l=1}^N l \times P^\varepsilon(l))^2}. \quad (5)$$

O Comprimento médio das linhas diagonais (L_{med}) é definido como o tempo médio que dois segmentos de uma trajetória estão próximos um do outro, podendo ser interpretado como o tempo médio de predição e é calculado da seguinte maneira:

$$L_{med} = \frac{\sum_{l=l_{min}}^N l \times P^\varepsilon(l)}{\sum_{l=l_{min}}^N P^\varepsilon(l)}. \quad (6)$$

O comprimento máximo das estruturas diagonais (L_{max}) é quantificado como:

$$L_{max} = \max(\{l_i, i = 1 \dots N_l\}). \quad (7)$$

O recíproco do comprimento máximo é a Divergência (*DIV*), que está relacionada com o maior expoente de Lyapunov positivo [13], mensurada na análise de quantificação de recorrência como:

$$DIV = \frac{1}{L_{max}}. \quad (8)$$

A Entropia de Shannon ($ENTR$) mede a distribuição de frequência dos comprimentos das linhas diagonais. Ela reflete a complexidade da estrutura determinística no sistema.

$$ENTR = - \sum_{l=l_{min}}^N p(l) \ln p(l), \quad (9)$$

em que $p(l) = \frac{P^\varepsilon(l)}{\sum_{l=l_{min}}^N P^\varepsilon(l)}$.

A Laminaridade (LAM) é a razão entre os pontos de recorrência que formam estruturas verticais e todo o conjunto dos pontos de recorrência, definida como:

$$LAM = \frac{\sum_{v=v_{min}}^N v \times P^\varepsilon(v)}{\sum_{v=1}^N v \times P^\varepsilon(v)}, \quad (10)$$

em que $P^\varepsilon(l) = \{v_i, i = 1 \dots N_v\}$, representa a distribuição de frequência dos comprimentos v das N_v estruturas verticais e v_{min} o número mínimo de estruturas verticais que se deseja contabilizar dentro do gráfico de recorrência [5].

O Comprimento médio das estruturas verticais (TT), também conhecido como o tempo de permanência em um estado, é definido como:

$$TT = \frac{\sum_{v=v_{min}}^N v \times P^\varepsilon(v)}{\sum_{v=v_{min}}^N P^\varepsilon(v)}. \quad (11)$$

A medida TT contém informação acerca da quantidade e do comprimento das estruturas verticais no gráfico de recorrência, medindo o tempo médio que o sistema permanece em um estado específico.

Além do comprimento médio, pode-se utilizar, ainda, como medida de recorrência, o comprimento máximo das estruturas verticais (V_{max}), definida como:

$$V_{max} = \max\{v_i; i = 1 \dots N_v\}. \quad (12)$$

Dentro de uma região definida a partir do raio de vizinhança adotado, existem dois tipos de pontos recorrentes. O conjunto de todos os pontos recorrentes na vizinhança constitui os pontos de recorrência do tipo 1. Os pontos de recorrência do tipo 2 são os primeiros pontos da trajetória do espaço de fases que caem naquela vizinhança. Assim, é possível estimar dois tipos de tempo de recorrência, os quais estão relacionados a transições de energia na dinâmica do sistema [14].

O tempo de recorrência do tipo 1 (T^1) indica a distância entre o ponto recorrente \vec{x}_j e o ponto referência do raio de vizinhança, \vec{x}_i [5], dado por:

$$T_j^1 = |\{i, j : \vec{x}_i, \vec{x}_j \in \mathcal{R}_i\}|, \quad (13)$$

em que \mathcal{R}_i representa os pontos de recorrência na vizinhança de \vec{x}_i .

O tempo de recorrência do tipo 2 (T^2) pode indicar com mais precisão do que T^1 transições de energia significativamente baixas [15]. É calculado como a distância entre o primeiro ponto recorrente da trajetória do espaço de fases, \vec{x}_j , e o ponto referência do raio de vizinhança, \vec{x}_i , dado por:

$$T_j^2 = |\{i, j : \vec{x}_i, \vec{x}_j \in \mathcal{R}_i, \vec{x}_{j-1} \notin \mathcal{R}_i\}|. \quad (14)$$

A entropia do tempo de recorrência do tipo 1, ou $RPDE$ (*Recurrence Probability Density Entropy*) [16], é medida por:

$$RPDE = \frac{- \sum_{i=1}^{T_{max}^1} P(i) \ln P(i)}{\ln T_{max}^1}, \quad (15)$$

em que $P(i)$ é a densidade de probabilidade do tempo de recorrência do tipo 1, e T_{max}^1 é o tempo máximo de recorrência de tipo 1.

III. METODOLOGIA

Neste trabalho, são analisados 167 sinais de voz, oriundos da *Disordered Voice Database, Model 4337*, desenvolvida pelo *Kay Massachusetts Eye and Ear Infirmary (MEEI) Voice and Speech Lab* [17]. Destes, 53 são sinais de vozes saudáveis e 114 são sinais de vozes afetadas por patologias laríngeas (52 sinais de vozes afetadas por paralisia nas pregas vocais, 44 sinais de vozes afetadas por edema de Reinke, e 18 sinais de vozes afetadas por nódulos vocais). A taxa de amostragem empregada é de 25000 amostras/s.

Cada sinal é particionado em segmentos consecutivos de 32 ms (quadros de 800 amostras). Em cada segmento, a análise de quantificação de recorrência é realizada utilizando a *toolbox CRP (Cross Recurrence Plots)* [18] no Matlab 2009 (*Mathworks*). Essa *toolbox* permite a extração dos parâmetros de imersão (τ e m) e das medidas de quantificação de recorrência. As medidas são extraídas de modo que a Taxa de Recorrência não ultrapasse 1%. Dessa forma, para cada segmento é obtido um valor para o raio de vizinhança, ε , que mantenha esse patamar de Taxa de Recorrência.

Um total de 15 características são extraídas dos sinais de voz. Além das 14 medidas de recorrência citadas, o comportamento do raio de vizinhança (ε) também é investigado. Em uma fase de avaliação individual, uma análise estatística, com o teste de hipótese não paramétrico de Mann-Whitney para o caso de duas amostras independentes, é realizada considerando um nível de significância de 0,05, a fim de investigar o potencial discriminativo das medidas consideradas.

Na fase de classificação dos sinais, são utilizadas as redes neurais MLP por meio do *software WEKA* [19]. As classes observadas são: sinais de vozes saudáveis (SDL), o conjunto de todos os sinais de vozes patológicas (PTL), sinais de vozes afetadas por paralisia (PRL), sinais de vozes afetadas por edema (EDM) e sinais de vozes afetadas por nódulos (NDL). A classificação é realizada entre dois grupos: $SDL \times PTL$, $SDL \times PRL$, $SDL \times EDM$, $SDL \times NDL$, $PRL \times EDM$, $PRL \times NDL$ e $EDM \times NDL$. Em todos os casos de classificação, é empregado o algoritmo *Backpropagation* [20], com taxa de aprendizagem igual a 0,3 e taxa de momento igual a 0,2. A fase de teste do classificador é realizada com validação cruzada, a qual permite dividir o conjunto de dados em n subconjuntos. Desses, $n - 1$ são utilizados na fase de treino do classificador, e o subconjunto restante é utilizado na fase de teste. O procedimento se repete n vezes, de maneira que todos os subconjuntos (*folds*) sejam empregados na fase de teste. Neste trabalho, utiliza-se n igual a 10.

Inicialmente, para cada uma das 15 características de recorrência é empregada uma rede MLP com um neurônio

TABELA I
ACURÁCIA (%) OBTIDA DA CLASSIFICAÇÃO NA REDE MLP.

Medidas	SDL×PTL	SDL×PRL	SDL×EDM	SDL×NDL	PRL×EDM	PRL×NDL	EDM×NDL
<i>Raio</i>	66,25	72,35	57,90	74,65	61,53	72,48	70,97
<i>REC</i>	68,26	54,00	58,80	76,67	53,44	73,90	70,97
<i>TRANS</i>	81,64	84,38	78,01	85,63	58,85	74,29	70,97
<i>DET</i>	81,37	85,49	77,66	85,87	60,10	74,29	70,97
<i>RATIO</i>	67,21	76,29	60,27	77,70	61,40	74,29	70,75
L_{med}	84,51	88,10	80,69	91,31	59,97	74,29	70,97
L_{max}	80,36	78,25	78,18	87,84	51,63	74,29	70,97
<i>DIV</i>	69,34	52,83	77,32	88,12	51,67	74,29	70,97
<i>ENTR</i>	73,49	79,75	69,24	82,02	61,94	74,29	70,97
<i>LAM</i>	75,69	65,91	67,01	74,64	51,98	74,29	70,97
<i>TT</i>	81,74	77,59	72,82	73,43	53,75	74,29	70,97
V_{max}	82,61	83,81	77,87	83,10	59,06	74,29	70,97
T^1	78,04	87,36	75,12	83,76	64,58	74,09	70,97
T^2	68,26	67,97	50,10	74,65	66,25	75,57	70,97
<i>RPDE</i>	75,67	81,78	77,63	82,96	59,27	74,29	70,97

na camada de entrada, 2 neurônios na camada oculta e 2 neurônios na camada de saída. Após a observação do comportamento discriminativo de cada medida de recorrência, todas elas são combinadas em um único vetor de características e imersas na rede com 15 neurônios de entrada, 9 neurônios na camada oculta e 2 neurônios na camada de saída.

IV. RESULTADOS

A. Classificação Individual das Medidas

Na Tabela I estão apresentados os melhores resultados dos valores de acurácia obtidos na classificação, utilizando as redes MLP, para cada caso considerado. Na discriminação entre os sinais saudáveis e patológicos, a medida do comprimento médio das estruturas diagonais, L_{med} , é a que apresenta melhor potencial discriminativo. O melhor caso de classificação ocorre entre os sinais de vozes saudáveis e os sinais afetados por nódulos, apresentando uma acurácia de 91,31% e área da curva ROC igual a 0,94. Pode ser observado na Figura 1 o comportamento diferenciado das diagonais em cada gráfico de recorrência apresentado.

Na discriminação entre patologias, a medida do tempo de recorrência do tipo 2 (T^2), foi a que apresentou melhor desempenho. Por se tratar de uma medida que consegue identificar transições de energia significativamente baixas nas séries temporais, T^2 apresenta potencial discriminativo entre sinais patológicos, os quais apresentam uma maior variabilidade para essa medida, como pode ser observado na Figura 3. Devido à vibração aperiódica das pregas vocais, causada pela presença de patologia, esses sinais apresentam menor energia e maior característica de ruído.

Na classificação entre as patologias edema e nódulos, observa-se resultados iguais para quase todas as medidas avaliadas. Isto se justifica pelo fato de ambas apresentarem lesões de massa nas pregas vocais, com características similares tanto fisiológicas quanto perceptuais, dificultando a discriminação entre as mesmas.

Foram realizados testes estatísticos, para os melhores casos (L_{med}) e (T^2) da Tabela I, para avaliar o potencial discriminativo dessas medidas. Na Tabela II está apresentado o nível de significância obtido para cada caso, indicando diferenças estatísticas entre as classes, uma vez que o valor obtido ($P < 0,001$) é menor que o valor suficiente para inferir a separabilidade dos grupos envolvidos no teste ($P = 0,05$). Os *boxplots* dessas medidas são apresentados nas Figuras 2 e 3.

TABELA II
DESEMPENHO DISCRIMINATIVO DA MELHOR MEDIDA PARA CADA CASO DE CLASSIFICAÇÃO.

Classificação	Medida	Significância	Área ROC
SDL×PTL	L_{med}	$P < 0,001$	0,91
SDL×PRL	L_{med}	$P < 0,001$	0,94
SDL×EDM	L_{med}	$P < 0,001$	0,85
SDL×NDL	L_{med}	$P < 0,001$	0,94
PRL×EDM	T^2	$P < 0,001$	0,70
PRL×NDL	T^2	$P < 0,001$	0,60
EDM×NDL	L_{med}	$P < 0,001$	0,61


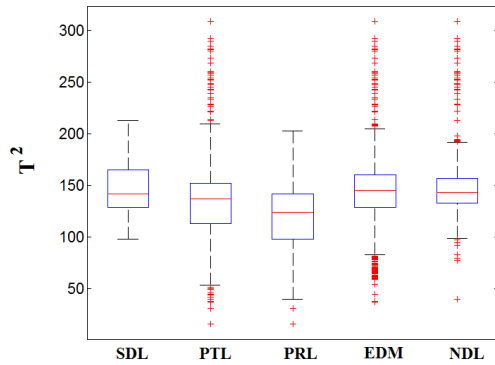


Fig. 2. Distribuição da medida L_{med} nas classes de sinais avaliadas.

Fig. 3. Distribuição da medida T^2 nas classes de sinais avaliadas.

B. Classificação das Medidas Combinadas

A combinação de características tem como objetivo aumentar a taxa global de classificação dos padrões dos quais são obtidas essas características. Na Tabela III estão apresentados os resultados da combinação das 15 características de recorrência quando aplicadas na rede MLP para cada caso considerado.

TABELA III
RESULTADOS DA CLASSIFICAÇÃO DE 15 CARACTERÍSTICAS DE
RECORRÊNCIA COMBINADAS.

Classificação	Ac (%)	Área ROC
SDL×PTL	94,19	0,98
SDL×PRL	96,73	0,99
SDL×EDM	92,20	0,96
SDL×NDL	99,11	0,99
PRL×EDM	75,14	0,83
PRL×NDL	85,14	0,91
EDM×NDL	75,59	0,81

A combinação das medidas num vetor único de características contribuiu de forma significativa na classificação. A melhor taxa de correta classificação está no caso entre sinais de vozes saudáveis e sinais de vozes afetadas por nódulos, com acurácia de 99,11% e área da curva ROC igual a 0,99.

A maior contribuição da combinação de características na rede MLP para discriminação entre sinais saudáveis e sinais patológicos está no caso entre sinais saudáveis e sinais afetados por edema (a acurácia aumentou 11,51%). Entre patologias, a maior contribuição está no caso entre os sinais afetados por paralisia e os sinais afetados por nódulos (a acurácia aumentou 6,85%). Os resultados obtidos mostram que as medidas apresentam aspectos complementares.

V. CONCLUSÕES

Neste trabalho, são avaliadas quinze medidas de quantificação de recorrência na discriminação entre vozes saudáveis e vozes patológicas. As medidas que mais se destacaram foram: o comprimento médio das linhas diagonais, L_{med} , na discriminação entre vozes saudáveis e patológicas (edema, nódulos e paralisia). Já entre as patologias, o tempo de recorrência do tipo 2, T^2 , apresentou o melhor resultado de classificação. Pelos resultados obtidos,

a utilização das medidas de recorrência, de forma combinada, podem ser empregadas para detectar a presença das patologias edema, paralisia e nódulos, com precisão acima de 90%. Já a discriminação entre patologias requer uma maior investigação.

REFERÊNCIAS

- [1] J. I. Godino-Llorente, P. Gomes-Vilda, and M. Blanco-Velasco. Dimensionality reduction of a pathological voice quality assessment system based on gaussian mixture models and short-term cepstral parameters. *IEEE Transactions on Biomedical Engineering*, 53(10):1943–1953, 2006.
- [2] WC de A Costa, Francisco M Assis, Benedito G Aguiar Neto, Silvana Cunha Costa, and Vinicius J Dias Vieira. Pathological voice assessment by recurrence quantification analysis. In *Biosignals and Birobotics Conference (BRC), 2012 ISSNIP*, pages 1–6. IEEE, 2012.
- [3] J. P. Eckmann, S. O. Kamphorst, and D. Ruelle. Recurrence plots of dynamical systems. *Europhys. Letters*, 4(9):973–977, 1987.
- [4] C. L. Webber-Jr. and J. P. Zbilut. Dynamical assessment of physiological systems and states using recurrence plot strategies. *J. Appl. Physiol.*, 76:965–973, 1994.
- [5] N. Marwan. *Encounters With Neighbours - Current Developments of Concepts Based on Recurrence Plots and Their Applications*. PhD thesis, University of Potsdam, 2003.
- [6] Julián D Arias-Londoño, Juan I Godino-Llorente, Germán Castellanos-Domínguez, Nicolás Sáenz-Lechón, and Víctor Osma-Ruiz. Complexity analysis of pathological voices by means of hidden markov entropy measurements. In *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE*, pages 2248–2251. IEEE, 2009.
- [7] Norbert Marwan, M Carmen Romano, Marco Thiel, and Jürgen Kurths. Recurrence plots for the analysis of complex systems. *Physics Reports*, 438(5):237–329, 2007.
- [8] C de A Washington, FM de Assis, BG Aguiar Neto, Silvana C Costa, and Vinicius JD Vieira. Pathological voice classification based on recurrence quantification measures. In *Anais do XXX SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES - SBt'12*, 2012.
- [9] Norbert Marwan and Jürgen Kurths. Line structures in recurrence plots. *Physics Letters A*, 336(4):349–357, 2005.
- [10] F. Takens. Detecting strange attractors in turbulence dynamical systems and turbulence. In D Rand and L-S Young, editors, *Lecture Notes in Mathematics*, pages pp 366–381. Berlin: Springer, 1981.
- [11] Norbert Marwan, Jonathan F Donges, Yong Zou, Reik V Donner, and Jürgen Kurths. Complex network approach for recurrence analysis of time series. *Physics Letters A*, 373(46):4246–4254, 2009.
- [12] C. L. Webber-Jr. and J. P. Zbilut. Recurrence quantification analysis of nonlinear dynamical systems. In Michael A. Riley and Guy C. Van Orden, editors, *Tutorials in Contemporary Nonlinear Methods for the Behavioral Sciences*, 2005.
- [13] Joseph P Zbilut, José-Manuel Zaldívar-Comenges, and Fernanda Strozzi. Recurrence quantification based liapunov exponents for monitoring divergence in experimental data. *Physics Letters A*, 297(3):173–181, 2002.
- [14] Jianbo Gao and Huaqing Cai. On the structures and quantification of recurrence plots. *Physics Letters A*, 270(1):75–87, 2000.
- [15] JB Gao, Yinhe Cao, Lingyun Gu, JG Harris, and JC Principe. Detection of weak transitions in signal dynamics using recurrence time statistics. *Physics Letters A*, 317(1):64–72, 2003.
- [16] Max A Little, Patrick E McSharry, Stephen J Roberts, Declan AE Costello, Irene M Moroz, et al. Exploiting nonlinear recurrence and fractal scaling properties for voice disorder detection. *BioMedical Engineering OnLine*, 6(1):23, 2007.
- [17] K. Elemetrics. Kay elemetrics corp. disordered voice database. Model 4337, 03 Ed., 1994.
- [18] N Marwan and Potsdam Institute for Climate Impact Research. Cross recurrence plot toolbox for matlab, version 5.17 (r28.16), January 2013. Disponível em <http://tocsy.pik-potsdam.de/CRPtoolbox/index.html>. Acesso em fevereiro de 2013.
- [19] Mark Hall; Eibe Frank; Geoffrey Holmes; Bernhard Pfahringer; Peter Reutemann and Ian H. Witten. The weka data mining software: An update; sigkdd explorations, volume 11, issue 1, 2009. Disponível em <http://www.cs.waikato.ac.nz/ml/weka/index.html>. Acesso em março de 2013.
- [20] Simon S Haykin. *Neural networks: a comprehensive foundation*. Prentice Hall, Inc., 1999.