

# Simulador de Reconhecedores de Palavras Isoladas

ALI HUSSEIN SAYED  
NORMONDS ALENS

Neste trabalho é apresentado um simulador de reconhecedores de comandos da fala [1]. O simulador permite testar vários algoritmos propostos na literatura e variações destes algoritmos.

## 1. INTRODUÇÃO

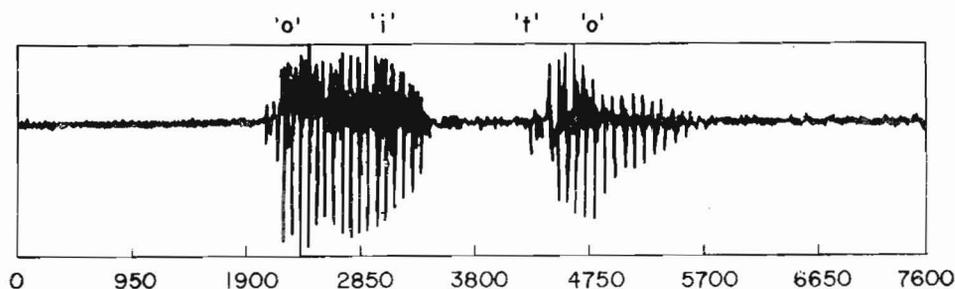
A área de reconhecimento de voz preocupa-se em prover meios de comunicação com as máquinas através da fala humana. Estudos recentes mostram que a comunicação através da fala é o meio preferido pelas pessoas e que tenderá a ser uma alternativa barata para a entrada de dados em computadores [2, 3]. O simulador desenvolvido neste trabalho abrange a área de reconhecimento de comandos da fala. O sistema opera com vocabulário limitado e deve ser previamente treinado. Testes realizados com o auxílio do simulador desenvolvido, para uma configuração freqüente na literatura, (ver seção 19), forneceram taxas de acerto entre 95% e 98%.

## 2. APARELHO FONADOR HUMANO

O primeiro passo no processamento do sinal de voz consiste em modelar o aparelho fonador humano. O aparelho fonador constitui-se de um tubo acústico que se estende entre a glote e os lábios. A cavidade nasal pode ser acoplada ou não à cavidade oral através da movimentação da úvula. O tubo acústico possui características e dimensões variáveis em função da pessoa e do som emitido [11]. Os sons classificam-se em sons vocálicos (ex. vogais), sons oclusivos (/p/, /t/), sons fricativos (/s/, /f/) e sons nasais (/n/, /m/) [11, 12].

Ali Hussein Sayed é professor assistente, EPUSP e Normonds Alens professor titular, EPUSP  
DEE - EPUSP - CP 8174 - SÃO PAULO, SP - 05508 - Julho 1989

A figura 1 mostra o sinal acústico do dígito "oito", onde pode-se observar as regiões vocálicas e as regiões de "silêncio" da palavra. O termo "silêncio" refere-se ao ruído de fundo do ambiente acústico do reconhecedor.



**Figura 1.** Sinal acústico do dígito "oito". São 7600 amostras relativas a uma taxa de amostragem de 8 KHz.

Resultados experimentais mostram que as características do sistema de geração do sinal de voz mudam lentamente. A mudança ocorre em períodos em torno de 10 a 30ms [8, 12, 13, 14, 15]. A **Figura 2** mostra um intervalo do som "oi" do dígito "oito". Percebe-se que o sinal não apresenta mudanças bruscas de comportamento. Pode-se, então, modelar o aparelho fonador humano por um sistema *linear e lentamente variável* com o tempo [12, 13], que pode ser excitado tanto por um trem de impulsos quasi-periódicos (no caso de sons vocálicos) ou por ruído branco (no caso de sons não-vocálicos), conforme **Figura 3**. Filtrando o sinal de voz proveniente do microfone com um filtro  $L(z)$  do tipo:

$$L(z) = 1 - \mu z^{-1}$$

obtém-se um sistema global  $V(z)$ , com os efeitos da radiação nos lábios e da variação da área da glote reduzidos. A este processo de tratamento do sinal de voz, dá-se o nome de *pré-ênfase*, conforme **Figura 4**. O parâmetro  $\mu$  é denominado *fator de pré-ênfase* e o seu valor pode ser programado pelo SIR PI (Simulador de Reconhecedores de Palavras Isoladas) (valores típicos de  $\mu$  são próximos de 1,0).

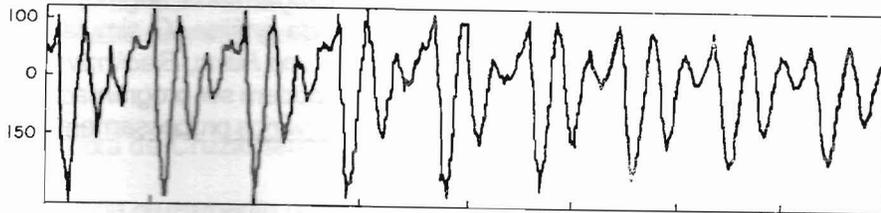


Figura 2. Intervalo do som "oi" do dígito "oito"

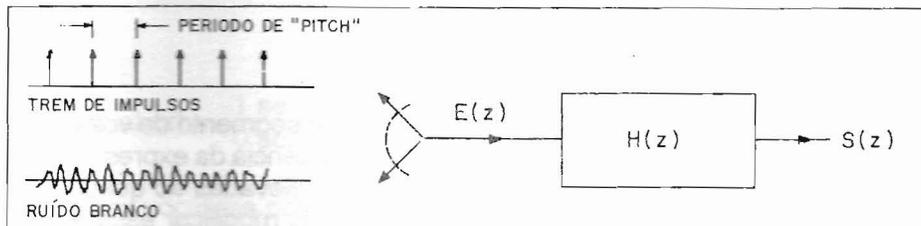


Figura 3. Modelo linear e lentamente variável (variável quadro a quadro).

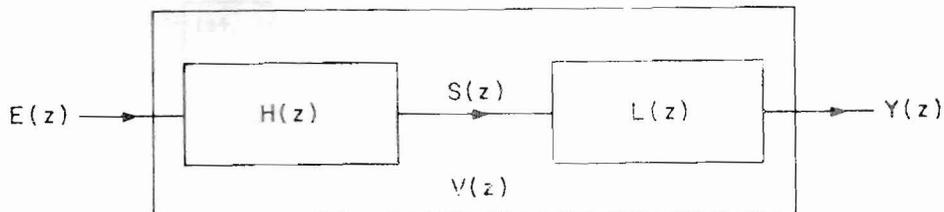


Figura 4. Modelo com pré-ênfase

Tal modelo, adotado neste trabalho, tem-se mostrado eficiente e funciona bem na prática [8].

### 3. PROCESSAMENTO TEMPORAL DO SINAL DE VOZ

O sinal de voz pode ser analisado em intervalos de duração curta, segmentando-o utilizando janelas de duração igual à duração da análise. O simulador permite escolher entre as janelas do tipo *Retangular*, *von Hann*, *Blackmann* e *Bartlett* [16]. A largura  $N$  e o deslocamento  $D$  da janela podem ser programados. Após o janelamento, o segmento de voz é submetido a vários processamentos:

#### 3.1. Medida de Energia de Tempo Curto

A amplitude dos sons não-vocálicos é bem menor que a amplitude dos sons vocálicos. A "energia" quadrática de tempo curto,  $E(n)$ , fornece uma boa representação desta variação de amplitude [12, 15]:

$$E(n) = \sum_{m=0}^{N-1} |y(n-m)w(m)|^2 \quad (2)$$

onde  $w(m)$  é uma janela de largura  $N$  e  $y(n-m)$  é um segmento de voz entre  $n-N+1$  e  $n$  para  $0 \leq m \leq N-1$ . A principal inconveniência da expressão (2) é o destaque dado às grandes amplitudes (que são elevadas ao quadrado) em relação aos níveis mais baixos. Uma maneira de modificar esse efeito seria utilizar a medida de "energia" absoluta de tempo curto,  $M(n)$ :

$$M(n) = \sum_{m=0}^{N-1} |y(n-m)w(m)| \quad (3)$$

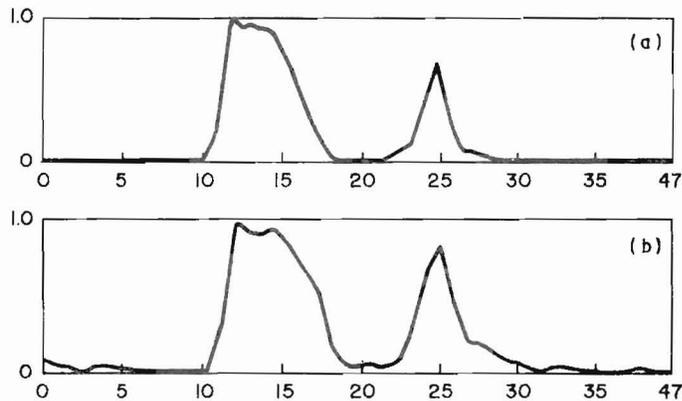


Figura 5. "Energias" quadrática (a) e absoluta (b) do dígito "oito" em função de segmentos de 20ms ( $N = 160$  amostras).

O simulador permite escolher entre a medida absoluta e a medida quadrática. A **Figura 5** mostra as "energias" absoluta e quadrática do dígito "oito", calculadas com uma janela retangular de largura  $N = 160$  amostras e deslocada sem sobreposições ( $D = 160$ ).

### 3.2. Taxa de Cruzamento por Zero de Tempo Curto

A taxa de cruzamento por zero,  $z(n)$ , ao longo do sinal de voz, fornece uma idéia robusta do conteúdo espectral do sinal [12, 15, 17].  $Z(n)$  é definida por:

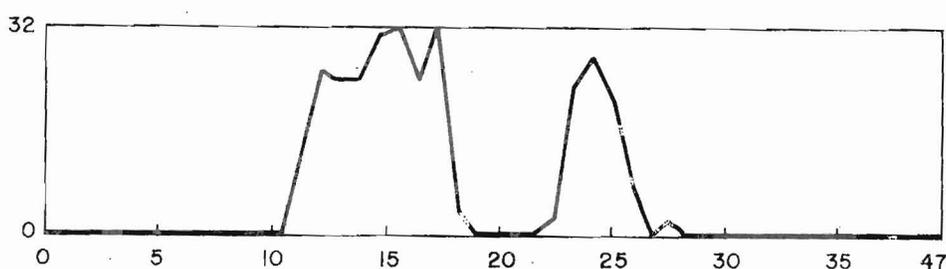
$$Z(n) = \sum_{m=0}^{N-1} | \text{sinal}\{y(n-m)\} - \text{sinal}\{y(n-m-1)\} | w(m) \quad (4a)$$

onde

$$\text{Sinal}(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases} \quad (4b)$$

As regiões vocálicas possuem taxas de cruzamento por zero menores que as regiões não vocálicas. A **Figura 6** mostra a taxa de cruzamento de zero do dígito "oito", calculada com uma janela retangular de largura  $N = 160$  amostras e deslocada sem sobreposições.

Deve-se mencionar que o nível DC e interferências de 60 Hz prejudicam o cálculo de  $Z(n)$  [12]. O simulador SIR PI permite controlar o nível DC do sinal de voz.



**Figura 6.** Taxa de cruzamento de zero do dígito "oito" em função de segmentos de 20ms ( $N = 160$  amostras)

### 3.3. Função de Autocorrelação de Tempo Curto

A função de autocorrelação de tempo curto,  $R(k)$ , é utilizada na análise do sinal de voz pela técnica de *predição linear*. O *coeficiente de autocorrelação de índice  $k$*  é dado por [12].

$$v_n(m) = y(n - m) w(m), \quad 0 \leq m \leq N - 1 \quad (5a)$$

$$R(k) = \sum_{m=0}^{N-1-k} v_n(m) v_n(m+k) \quad (5b)$$

onde  $v_n(m)$  é um segmento janelado do sinal de voz, de lagura  $N$ . As amostras que compõem  $v_n(m)$  vão de  $y(n - N + 1)$  a  $y(n)$ .

### 4. PONTOS EXTREMOS DA PALAVRA

A localização dos pontos extremos do comando pronunciado, é um fator importante que permite reduzir o número de amostras a serem analisadas pelo sistema e *que afeta consideravelmente a sua taxa de acerto de reconhecimento*. O algoritmo empregado foi sugerido por Rabiner e Sambur [18] e caracteriza-se pela sua simplicidade. O algoritmo emprega dois parâmetros: a "energia" de tempo curto,  $E(n)$  ou  $M(n)$ , e a taxa de cruzamento por zero,  $Z(n)$ , do sinal de voz. Estes parâmetros são utilizados na determinação de limiares que controlam o processo de decisão. São definidos dois limiares de energia  $L_{es}$  e  $L_{ei}$  (superior e inferior respectivamente) e um limiar de cruzamento de zero  $L_{zcr}$ . Uma vez determinados os limiares, o algoritmo parte para a localização dos extremos. O algoritmo realiza a busca a partir do início da palavra segundo o critério de energia. O segmento  $N1$ , em que a energia excede o limiar inferior  $L_{ei}$  e continua subindo até exceder  $L_{es}$ , é adotado como estimativa inicial para o começo da palavra. O mesmo procedimento é repetido para a localização da estimativa  $N2$  do final da palavra. As estimativas  $N1$  e  $N2$  são então corrigidas de acordo com o critério da taxa de cruzamento de zero. Neste caso, parte-se de  $N1$  em direção ao início da palavra e determina-se o número de vezes em que  $Z(n)$  ultrapassa  $L_{zcr}$  em  $\alpha$  segmentos anteriores a  $N1$ . Se este número exceder 3, a estimativa inicial  $N1$  é deslocada até o primeiro ponto, *no tempo*, em que  $Z(n)$  ultrapassa  $L_{zcr}$ . O mesmo procedimento é repetido para  $\beta$  segmentos posteriores à estimativa  $N2$ . O número de segmentos  $\alpha$  e  $\beta$  devem ser escolhidos adequadamente (valores típicos são  $\alpha = \beta = 25$ ). O simulador SIR PI permite controlar o cálculo dos

limiares e portanto, permite controlar a precisão do algoritmo. Aplicando o algoritmo ao dígito "oito" (janela retangular com  $N = 160$  e deslocamento sem sobreposição), resultam os pontos extremos ( $N1 = 10$  e  $N2 = 30$ ) indicados na figura 7.

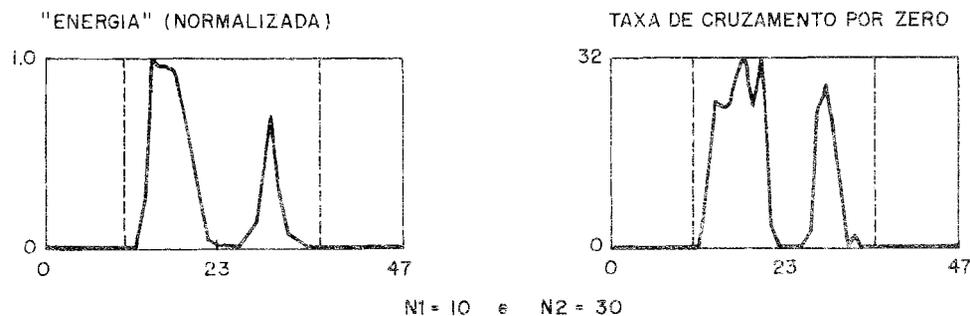


Figura 7. Pontos extremos do dígito "oito"

## 5. PREDIÇÃO LINEAR

A análise da voz por *predição linear*, baseia-se na hipótese de que uma amostra do sinal de voz pode ser aproximada por uma combinação linear das amostras anteriores ou das amostras futuras [14]. Uma predição de ordem  $P$ , procura estimar a amostra  $y_w(n)$ , do instante  $n$ , a partir de  $P$  amostras anteriores. O índice  $w$  indica janelamento da amostra  $y(n)$ . Pode-se, também, estimar a amostra  $y_w(n - P)$ , do instante  $n - P$ , a partir de  $P$  amostras futuras:

$$\bar{y}(n) = \sum_{k=1}^P \bar{a}_k y_w(n - k) \quad (6a)$$

$$\bar{y}(n - P) = \sum_{k=1}^P \bar{a}_k y_w(n - P + k) \quad (6b)$$

As expressões (6a) e (6b) permitem definir os *erros de predição futura*,  $f_p(n)$ , e de *predição passada*,  $b_p(n)$ , de origem  $P$  [12, 14]:

$$f_p(n) = y_w(n) - \sum_{k=1}^P \bar{a}_k y_w(n-k) \quad (7a)$$

$$b_p(n) = y_w(n-P) - \sum_{k=1}^P \bar{a}_k y_w(n-P+k) \quad (7b)$$

Os erros quadráticos médios totais de predição futura e de predição passada, de ordem P,  $\xi_f^P$  e  $\xi_b^P$  respectivamente, em um intervalo de largura N, são definidos pelas expressões abaixo:

$$\xi_f^P = \sum_{n=0}^{N-1} f_p^2(n) \quad (8a)$$

$$\xi_b^P = \sum_{n=0}^{N-1} b_p^2(n) \quad (8b)$$

A idéia da predição linear é obter o conjunto de coeficientes  $\{\bar{a}_k\}$  ou  $\{\bar{\bar{a}}_k\}$  que sirva como estimativa dos coeficientes  $\{a_k\}$  do sistema  $V(z)$ , que modela a geração do sinal de voz. Convém mencionar que  $V(z)$  pode ser representado, adequadamente, por um modelo composto apenas por pólos [13]:

$$V(z) = \frac{G}{1 - \sum_{k=1}^P a_k z^{-k}} \quad (9)$$

onde G é um fator de ganho. A presença de zeros em (9) melhoraria a representação de sons nasais. O denominador da expressão (9) é denominado *filtro inverso* relativo aos coeficientes  $\{a_k\}$ . Existem vários algoritmos propostos para a obtenção das estimativas  $\{\bar{a}_k\}$  ou  $\{\bar{\bar{a}}_k\}$ . O critério utilizado é o de minimização do erro quadrático médio total. Pode-se mostrar que os coeficientes  $\{\bar{\bar{a}}_k\}$  são iguais aos coeficientes  $\{\bar{a}_k\}$ , mas com a ordem invertida [14]. Por isso, os coeficientes serão referenciados por  $\{\bar{a}_k\}$  no decorrer deste trabalho e serão denominados de coeficientes LPC ("Linear Prediction Coefficients"). As opções de cálculo dos coeficientes  $\{\bar{a}_k\}$ , oferecidas pelo SIR PI, conforme **Figura 8**, são:

Método da Autocorrelação – Algoritmo de Durbin

Métodos Lattice:

Método "Forward" – Minimização do Erro de Predição Futura

Método "Backward" – Minimização do Erro de Predição Passada

Método de Itakura

Método do Mínimo

Método de Burg

### 5.1. Método da Autocorrelação – Algoritmo de Durbin

O algoritmo baseia-se na minimização do erro quadrático total de predição futura  $\xi_P^P$ . Derivando  $\xi_P^P$  em relação aos coeficientes  $\{\bar{a}_k\}$  e igualando a zero, resulta um sistema linear de equações, de ordem  $P$ :

$$\sum_{k=1}^P \bar{a}_k R(i-k) = R(i) \quad i = 1, 2, \dots, P \quad (10)$$

onde  $R(i)$  é o coeficiente de autocorrelação de ordem  $i$ . O algoritmo de Durbin permite uma solução iterativa deste sistema de equações [12]:

$$\xi_m^0 = R(0)$$

$$k_i = \frac{R(i) - \sum_{j=1}^{i-1} \bar{a}_j^{(i-1)} R(i-j)}{\xi_m^{i-1}}, \quad 1 \leq i \leq P \quad (11a)$$

$$\bar{a}_i^{(i)} = k_i \quad (11b)$$

$$\bar{a}_j^{(i)} = \bar{a}_j^{(i-1)} - k_i \bar{a}_{i-j}^{(i-1)}, \quad 1 \leq j \leq i-1 \quad (11c)$$

$$\xi_m^i = (1 - k_i^2) \xi_m^{i-1} \quad (11d)$$

$$G = \sqrt{R(0) - \sum_{k=1}^P \bar{a}_k R(k)} \quad (11e)$$

Os coeficientes  $\{\bar{a}_j^{(i)}\}$ ,  $j = 1, 2, \dots, i$ ; são os coeficientes do preditor de ordem  $i$ .  $R(i)$  são os coeficientes de autocorrelação *normalizados* em relação à energia do sinal  $R(0)$ . Os coeficientes  $\{k_i\}$  são denominados *coeficientes de reflexão*. O termo  $\xi_m^i$  é o erro quadrático médio total de predição futura *normalizado* em relação a  $R(0)$  e  $G$  é fator de ganho da expressão (9). Uma condição necessária e suficiente para que o sistema  $V(z)$  resultante seja estável é que  $|k_i|$  seja menor que 1,0 [11].

## 5.2. Métodos Lattice

Teoricamente, o método da autocorrelação resulta sempre em um sistema  $V(z)$  estável. No entanto, o método sofre do efeito do cálculo com precisão finita, enquanto a *formulação lattice* possui uma sensibilidade muito menor [19]. A formulação lattice baseia-se no fato dos erros de predição futura e passada de um preditor de ordem  $P$ , poderem ser calculados, recursivamente, a partir dos erros de predição futura e passada de preditores de ordem menor [12, 19]:

$$f_0(n) = b_0(n) = y(n) \quad (12a)$$

$$\hat{f}_{i+1}(n) = \hat{f}_i(n) - k_{i+1} b_i(n-1) \quad (12b)$$

$$b_{i+1}(n) = -k_{i+1} \hat{f}_i(n) + b_i(n-1) \quad (12c)$$

No método lattice a solução é calculada diretamente a partir das amostras do sinal de voz. Não existe a necessidade de janelamento e portanto,  $y_w(n) = y(n)$ . As derivações possíveis são:

### 5.2.1. Método "Forward" – Minimização do Erro de Predição Futura

Este método é a implementação lattice do método da autocorrelação e baseia-se, portanto, na minimização de  $\xi_f^p$ . Substituindo (12b) em (8a) e derivando em relação aos coeficientes de reflexão  $k_i$ , resulta:

$$k_i^f = \frac{\sum_{n=0}^{N-1} f_{i-1}(n) b_{i-1}(n-1)}{\sum_{n=0}^{N-1} b_{i-1}^2(n-1)} \quad (13)$$

### 5.2.2. Método "Backward" – Minimização do Erro de Predição Passada

Neste caso, minimiza-se  $\xi_b^p$ . Substituindo (12c) em (8b) e derivando em relação aos coeficientes de reflexão  $k_i$ , resulta:

$$k_i^b = \frac{\sum_{n=0}^{N-1} f_{i-1}(n) b_{i-1}(n-1)}{\sum_{n=0}^{N-1} f_{i-1}(n-1)} \quad (14)$$

Observa-se que  $k_i^f$  e  $k_i^b$  possuem o mesmo sinal.

### 5.2.3. Método de Itakura

Os coeficientes de reflexão calculados pelas expressões (13) e (14) não garantem, necessariamente, um filtro estável  $V(z)$  [19]. Itakura propõe tomar a média geométrica de  $k_i^f$  e  $k_i^b$  [14, 19]:

$$k_i^l = \text{Sinal}(k_i^f) \sqrt{k_i^f k_i^b} \quad (15)$$

#### 5.2.4. Método do Mínimo

Neste caso, o mínimo, em valor absoluto, entre  $k_i^f$  e  $k_i^b$  é escolhido:

$$k_i^M = \text{Sinal}(k_i^f) \text{ mínimo } \{ |k_i^f|, |k_i^b| \} \quad (16)$$

#### 5.2.5. Método de Burg

A solução proposta por Burg minimiza a *soma* dos erros de predição futura e de predição passada, para cada segmento do sinal de voz e resulta sempre, em sistemas  $V(z)$  estáveis [14, 19]:

$$\xi_T^i = \xi_f^i + \xi_b^i \quad (17a)$$

Substituindo-se (8b) e (8c) em (17a) e derivando-se em relação a  $k_i$ , resulta [14]:

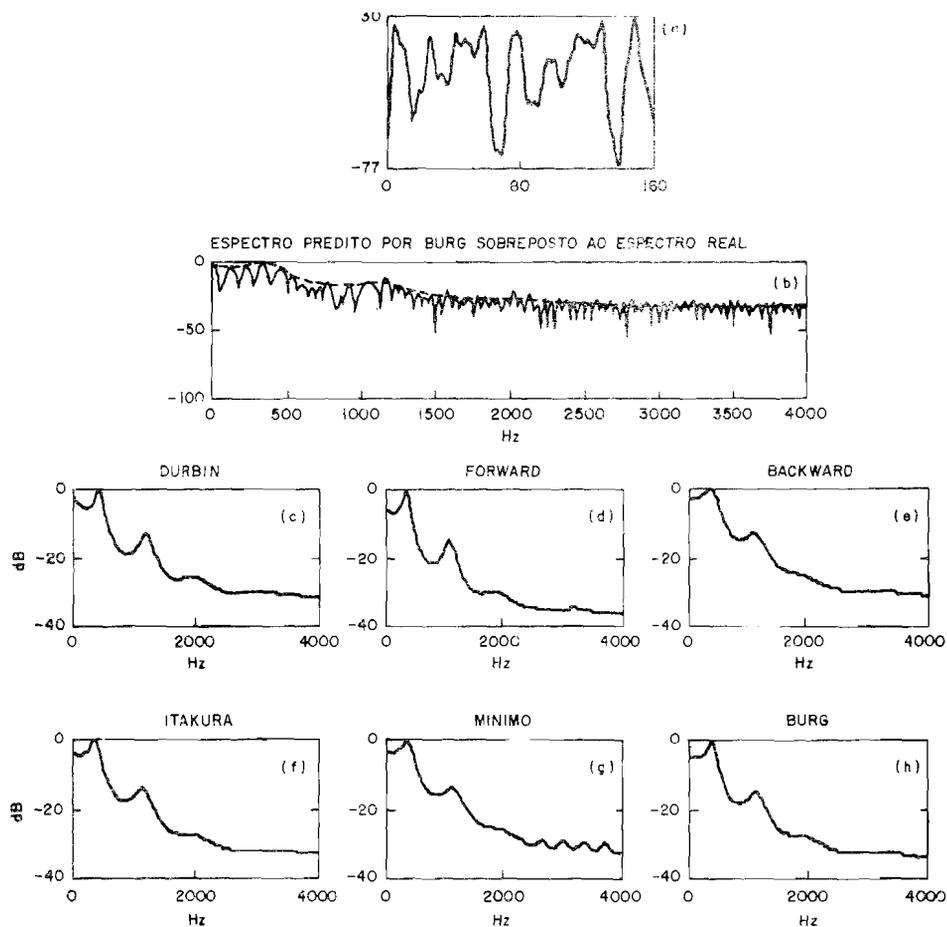
$$k_i^B = \frac{2 k_i^f k_i^b}{k_i^f + k_i^b} \quad (17b)$$

### 5.3. Ordem da Análise LPC

Atal e Hanauer [13] e Markel e Gray [14] apresentam uma relação entre a ordem  $P$  da análise LPC, a frequência de amostragem  $F_s$ , o comprimento do trato vocálico  $T_v$  e a velocidade do som no ar  $c$ :

$$F_s = \frac{P c}{2 T_v} \quad (18)$$

O simulador SIR PI permite escolher o valor de  $P$ . Na prática são utilizados valores entre 8 e 14 [12, 13, 14].



**Figura 8.** Segmento de 160 amostras (20ms) do som "oi" do dígito "oito" (a), o seu espectro de frequência (b) e os espectros de  $V(z)$  obtidos com os métodos: da autocorrelação (c), "Forward" (d), "Backward" (e), Itakura (f), Mínimo (g) e Burg (h).  $P = 12$ .

## 6. MEDIDAS DE SEMELHANÇA

As medidas de semelhança permitem comparar os parâmetros de dois sinais de voz com o intuito de verificar se podem ser considerados como representantes da mesma palavra. O simulador SIR PI permite escolher entre várias alternativas. Considerando dois segmentos de voz, um de teste,  $t$ , e outro de referência,  $r$ , tem-se:

### 6.1. Medida Euclideana

$$d^2 = \sum_{k=1}^P (\bar{a}_k^t - \bar{a}_k^r)^2 \quad (19)$$

### 6.2. Medida Absoluta

$$d_a = \sum_{k=1}^P |a_k^t - a_k^r| \quad (20)$$

### 6.3. Medida Cepstral

$$d_c^2 = \sum_{k=1}^L (c_k^t - c_k^r)^2 \quad (21)$$

onde L é o número desejado de coeficientes cepstrais  $\{c_k\}$ , que podem ser obtidos facilmente a partir dos coeficientes LPC [20].

### 6.4. Medida Cepstral Ponderada

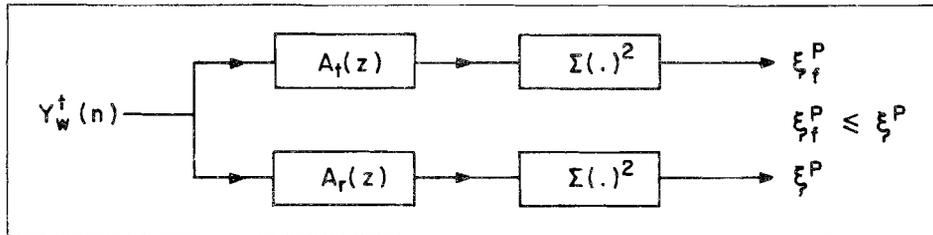
$$d_{cp}^2 = \sum_{k=1}^L q(k) (c_k^t - c_k^r)^2 \quad (22)$$

O simulador SIR PI permite programar a ponderação  $q(k)$  e a ordem L.

### 6.5. Medida da Razão de Verossimilhança

Esta medida, proposta por Itakura [4], é juntamente com as medidas cepstrais, uma das medidas mais bem sucedidas. A sua idéia é simples e baseia-se na comparação das energias dos erros de predição futura  $f_p(n)$ , nas saídas dos

filtros inversos  $A_t(z)$  e  $A_r(z)$ , de teste e de referência respectivamente, quando o segmento de teste é aplicado a ambos, conforme figura 9:



**Figura 9.** Medida da razão de verossimilhança de Itakura

A medida de distância é dada pela expressão abaixo, onde o índice  $t$  indica que os erros correspondem à aplicação do segmento de teste nas entradas dos filtros inversos:

$$d_{IV}^t = 1n \left[ \frac{\xi_f^P}{\xi_f^P} \right] \quad (23)$$

Percebe-se que a medida proposta por Itakura não é uma medida simétrica ( $d_{IV}^t \neq d_{IV}^r$ )

### 6.6. Medida de Itakura-Saito

A distância de Itakura-Saito é definida pela expressão seguinte:

$$d_{IS}^t = \left[ \frac{G_t}{G_r} \right]^2 \left[ \frac{\xi_f^P}{\xi_f^P} \right]^i - 2 \ln \left[ \frac{G_t}{G_r} \right] - 1 \quad (24)$$

$G_t$  e  $G_r$  são os fatores de ganho dos segmentos de teste e referência, respectivamente (ver expressão (11e)).

Percebe-se, também, que a medida de Itakura-Saito não é simétrica.

## 6.7. Medida COSH

O objetivo da medida COSH é resolver o problema de assimetria da medida da razão de verossimilhança. A medida COSH é definida por:

$$d_{\text{cosh}} = \ln [ 1 + \Omega + \sqrt{\Omega (2 + \Omega)} ] \quad (25)$$

onde  $\Omega$  é a medida de  $d_{\text{ic}}^t$  e  $d_{\text{ic}}$ .

## 6.8. Medida COSH Mínima

Considerando a razão entre os fatores de ganho  $(G_p/G_r)^2$  como variável e minimizando  $\Omega$  em relação a esta variável, resulta [20]:

$$d_{\Omega \text{min}} = \sqrt{\frac{(\xi^p/\xi_f^p)^t}{(\xi^p/\xi_f^p)^r}} - 1 \quad (26)$$

## 7. ALINHAMENTO TEMPORAL DINÂMICO

O principal elemento de um sistema reconhecedor de palavras isoladas é o bloco responsável pela comparação da palavra pronunciada com as palavras do dicionário do sistema (palavra de referência). É fato conhecido que o falante não consegue, geralmente, repetir a pronúncia de uma mesma palavra, à mesma taxa e com a mesma duração. Esta variação na pronúncia da palavra provoca flutuações *não lineares* ao longo do eixo do tempo [8, 22]. A solução deste problema sugere realizar o *alinhamento temporal dinâmico* das duas palavras ("Dynamic Time Warping – DTW"). O algoritmo geral de alinhamento temporal dinâmico considera duas palavras, uma de referência e outra de teste e determina a função  $\phi(n)$  que mapeia a palavra de referência na palavra de teste ou vice-versa. Deve-se escolher a função que realiza o mapeamento com a *menor distância total*  $D_T$ , entre as duas palavras [21, 22, 23]. Em termos gerais, a *distância total* é a soma das *distâncias locais* ao longo da trajetória.

Para tal, a cada ponto  $(i, j)$ , do plano de mapeamento, atribui-se uma *soma parcial*  $S_{ij}$ , que mede a distância acumulada até o ponto  $(i, j)$ :

$$S_i = d_i + \text{mínimo} \{ S_{pq} \}, \text{ para } p \leq i \text{ e } q \leq j \quad (27a)$$

$$S_{11} = d_{11} \quad (27b)$$

$$D_T = \text{mínimo} \{ S_{pq} \}, \text{ para } p = \text{última coluna} \quad (28)$$

onde  $d_{ij}$  representa a distância local entre os segmentos  $i$  (eixo horizontal) e  $j$  (eixo vertical) do plano  $(i, j)$  e  $S_{pq}$  representa a distância acumulada nos pontos  $(p, q)$  à esquerda e abaixo de  $(i, j)$ . Para garantir que não ocorram expansões ou compressões excessivas, a inclinação de  $\phi(n)$  deve situar-se, preferencialmente, na faixa  $[\frac{1}{2}, 2]$  [22]. *Restrições locais* são ainda, impostas para especificar quais são os pontos  $(p, q)$  que devem ser considerados na minimização de  $S_{pq}$ . Existem vários tipos de restrições locais, admitidas pelo SIR PI, conforme figura 10 [4, 22, 23].

Outra restrição geralmente imposta, é o alinhamento dos segmentos extremos das duas palavras. Supondo, sem perda de generalidade, que os segmentos das palavras dos eixos horizontal e vertical estão indexados de 1 a  $N_h$  e de 1 a  $N_v$ , respectivamente, então o alinhamento dos extremos implica nas seguintes restrições [21]:

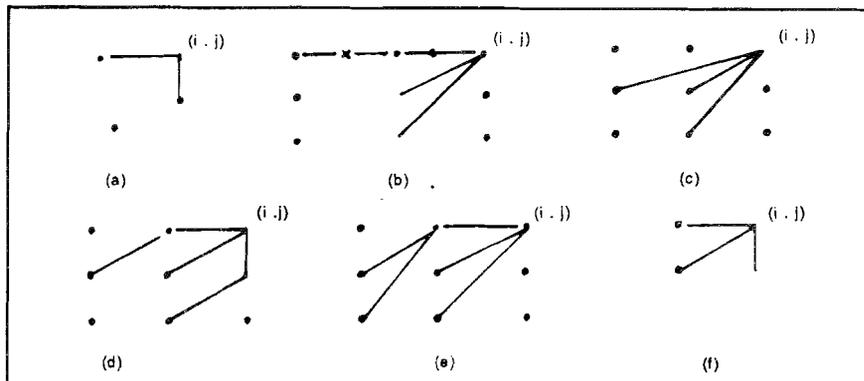
$$1 \leq \Phi(1) \leq \delta + 1 \quad (29a)$$

$$N_v - \delta \leq \Phi(N_h) \leq N_v \quad (29b)$$

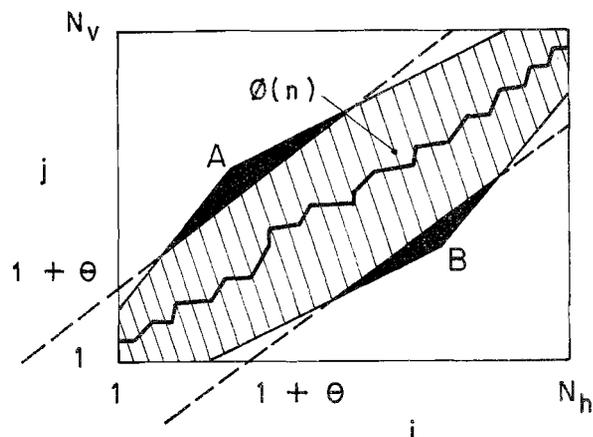
As condições (29), em conjunto com a restrição de inclinação da função de mapeamento, restringem a área de procura da trajetória ótima à região hachurada da figura 11. As duas retas paralelas que reduzem a área de procura são uma imposição adicional para diminuir o tempo de processamento necessário.

O fator  $\theta$ , denominado pelo SIR PI de *fator global*, representa a máxima diferença absoluta permitida entre os segmentos de teste e de referência.

$$|i - j| \leq \theta \quad (30)$$



**Figura 10.** Restrições locais admitidas pelo simulador. Horizontal-Vertical (HV) (a), Itakura (b) 3 Diagonais (c), Horizontal-Vertical-3 Diagonais (HV3D) (d), Horizontal-4 Diagonais (H4D) (e) e Horizontal-Diagonal-Vertical (HV1D) (f).



**Figura 11.** Região de procura da função  $\phi(n)$

Myers e Rabiner [23] mostram que a redução da área de procura torna-se vantajosa se os comprimentos das duas palavras forem normalizados para um mesmo valor, antes da aplicação do algoritmo de alinhamento temporal dinâmico. Esta normalização pode ser feita por *interpolação* ou por *dizimização*. Outro ponto importante a ser mencionado, refere-se à opção de se alinhar a palavra de teste ao longo do eixo horizontal ou ao longo do eixo

vertical. Sabe-se que a escolha influi no resultado final. Existe, então, a necessidade de se normalizar a distância total com relação ao número de segmentos da palavra que está ao longo do eixo horizontal, para que a distância total represente uma distância média ao longo da trajetória [22, 23]. Esta normalização depende do tipo da função de *ponderação* das condições locais, que se está empregando. Em outras palavras, pode-se atribuir pesos aos ramos de transição das condições locais da **Figura 10**. Existem várias funções de ponderação. O peso de um ramo  $r$ ,  $\Lambda^r$ , pode ser dado por [22, 23]:

$$\text{Mínimo } (\Delta x, \Delta y) : \Lambda^r = \text{mínimo } (\Delta x^r, \Delta y^r) \quad (31a)$$

$$\text{Máximo } (\Delta x, \Delta y) : \Lambda^r = \text{máximo } (\Delta x^r, \Delta y^r) \quad (31b)$$

$$\Delta x : \Lambda^r = \Delta x^r \quad (31c)$$

$$\Delta x + \Delta y : \Lambda^r = \Delta x^r + \Delta y^r \quad (31d)$$

Os termos  $\Delta x^r$  e  $\Delta y^r$  representam a variação das coordenadas  $x$  e  $y$  ao longo do ramo  $r$ . Costuma-se adotar os seguintes valores para o fator de normalização,  $NR$ , em função da função de ponderação:

$$\text{Mínimo } (\Delta x, \Delta y) : NR = N_q \quad (32a)$$

$$\text{Máximo } (\Delta x, \Delta y) : NR = N_q \quad (32b)$$

$$\Delta x : NR = N_q \quad (32c)$$

$$\Delta x + \Delta y : NR = N_q + N_v \quad (32d)$$

onde  $N_q$  é o ponto onde a função de mapeamento atinge o valor máximo  $N_v$  ( $N_q \leq N_h$ ) [21], isto é:

$$\phi(N_q) = N_v \quad (33)$$

Com isso, a expressão geral da distância total torna-se:

$$D_T = \frac{\sum d_{ij} \Lambda^r}{NR(\Lambda)}, \text{ para } (i, j) \text{ e } \phi(n) \quad (34)$$

O simulador SIR PI permite controlar o bloco de alinhamento temporal dinâmico e programar todos os parâmetros de interesse.

## 8. REGRAS DE DECISÃO

O último passo no sistema de reconhecimento de palavras isoladas é o processo de decisão. Este passo encarrega-se de analisar as distâncias totais, calculadas pelo bloco de DTW, entre a palavra de teste e as palavras de referência, e decidir qual a palavra do dicionário que mais se aproxima do comando falado. As regras de decisão mais populares são a regra NN ("Nearest Neighbour") e a regra KNN ("K Nearest Neighbour") [1, 8, 24]. As duas regras estão implementadas no SIR PI.

## 9. VISÃO GLOBAL DO RECONHECEDOR

A Figura 12 apresenta o diagrama em blocos do sistema reconhecedor de palavras isoladas. Todos os blocos foram discutidos nos itens anteriores.

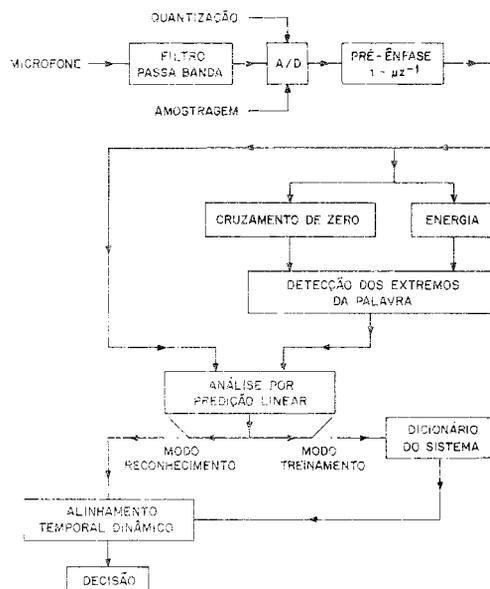


Figura 12. Diagrama em blocos do reconhecedor

Deve-se mencionar, neste ponto, que o reconhecedor possui dois modos de operação: o modo de *treinamento* e o modo de *reconhecimento*. No modo de treinamento, as palavras de referência são pronunciadas e analisadas e os seus coeficientes LPC são gerados e armazenados. No modo de reconhecimento, os coeficientes LPC da palavra pronunciada são gerados e o processo de análise continua até o passo de decisão.

## 10. TESTE DO SIMULADOR

Neste item, são apresentados os resultados obtidos durante a simulação de *uma configuração* freqüente na literatura. Os parâmetros da configuração testada estão listados a seguir:

LPC: Método de Durbin, janela de Hamming com  $N = 160$ ,  $D = 80$  e  $p = 8$

DTW: Distância cepstral com  $L = 8$ , restrição de Itakura com ponderação  $\Delta x$ , regra NN ou KNN de decisão, palavra de teste ao longo do eixo horizontal, limitação global desativada, pontos extremos vinculados ( $\delta = 0$ ), e normalização de comprimentos ativada.

"Energia": Medida absoluta, janela retangular com  $N = 80$  e  $D = 80$ , e fator de pré-ênfase  $\mu = 0,95$ .

O sinal de voz é filtrado entre 300 e 3400 Hz, amostrado a 8000 Hz e quantizado em 12 bits. As palavras de teste e de referência foram levantadas com o auxílio de 8 falantes designados A, B, C, X1, X2, X3, X4 e X5. Os falantes A, B, X1, X2 e X3 são masculinos, enquanto os falantes C, X4 e X5 são femininos. As palavras utilizadas nos testes são os dígitos de ZERO a NOVE e as palavras MEIA, AJUDA, CANCELE e TERMINE. Cada falante do grupo { A, B, C } pronunciou cada palavra 6 vezes. Portanto, a cada falante A, B ou C correspondem 6 conjuntos de 14 pronúncias, designadas  $A_i$ ,  $B_i$ , e  $C_i$ ,  $i = 1, 2, \dots, 6$ .

Cada falante do grupo { X1, X2, X3, X4, X5 } pronunciou cada palavra uma vez. Os testes foram realizados em um microcomputador compatível com o PC da IBM<sup>1</sup> (8 MHz, microprocessador 286 da Intel<sup>2</sup> e com coprocessador). O tempo

1. IBM é marca registrada da International Business Machines Corporation.

2. intel é marca registrada da Intel Corporation.

médio gasto na análise de uma palavra de teste (pré-ênfase, detecção dos pontos extremos e cálculo dos parâmetros LPC) foi de 20 segundos. O tempo médio gasto para alinhar dinamicamente duas palavras foi de 22 segundos. Em média, foram necessários 6 Kbytes de memória, em disco, por palavra de referência. A seguir são apresentados os resultados obtidos:

Dicionários I.A, I.B e I.C:

Os conjuntos  $A_6$ ,  $B_6$  e  $C_6$  foram escolhidos como referência para gerar três dicionários I.A, I.B e I.C, respectivamente. Os 5 conjuntos restantes, de cada falante, foram utilizados para testar o dicionário correspondente. Os resultados estão listados na tabela 1:

Dicionário	Número de palavras não reconhecidas	Taxa de acerto
I. A	0	100%
I. B	4	94%
I. C	3	95%

**Tabela 1.** Testes dos dicionários I

Portanto a taxa média de acerto é da ordem de 96%.

Dicionário II:

Os conjuntos  $A_6$ ,  $B_6$  e  $C_6$  foram escolhidos como referência para gerar o dicionário II. Os 5 conjuntos restantes, de cada falante, foram utilizados para testar o dicionário. (210 palavras de teste). Apenas quatro palavras de teste não foram reconhecidas corretamente, o que indica uma taxa de acerto de 98%. Percebe-se que a taxa de acerto aumentou de 96% para 98% devido ao número maior de referências por comando.

Dicionário III:

Os conjuntos  $A_6$ ,  $B_6$ ,  $C_6$ ,  $A_4$ ,  $B_4$  e  $C_4$  foram escolhidos como referência para gerar o dicionário III. As pronúncias dos falantes X1 a X5 foram utilizadas nos

testes do dicionário (70 palavras de teste, no total). Foram realizados dois testes: um teste com a regra NN e outro teste com a regra KNN (K=3). Para ambos os casos apenas três palavras de teste não foram reconhecidas corretamente, o que indica uma taxa de acerto da ordem de 95%.

Os testes realizados mostram que a configuração testada fornece bons índices de reconhecimento e confirmam os resultados obtidos por vários pesquisadores [4, 5, 6, 7, 9, 10].

Convém ressaltar que os resultados apresentados neste item referem-se ao teste de *uma* configuração. Outras configurações podem também ser programadas e testadas.

## 11. INTERFACE DO SIMULADOR COM O USUÁRIO

A operação do simulador é bastante simples e a sua programação é totalmente controlada por janelas ou menus. O simulador [1] foi desenvolvido em um microcomputador compatível com o PC da IBM<sup>1</sup> e escrito em linguagem C (Microsoft<sup>2</sup> versão 5.10). O simulador possui aproximadamente 10.000 linhas de código.

## 12. CONCLUSÕES E COMENTÁRIOS

Neste trabalho foi discutido o desenvolvimento de um simulador de reconhecedores de comandos da fala. Os parâmetros que controlam a operação do sistema são facilmente programados pelo usuário e a configuração escolhida pode ser facilmente simulada e avaliada. A nova versão do simulador se encontra em desenvolvimento e deverá incluir a geração de dicionários independentes de falantes [6, 8, 25, 26, 27].

O simulador desenvolvido [1] permite testar muitos dos algoritmos apresentados na literatura e representa, portanto, uma contribuição na área de reconhecimento de voz.

1. IBM é marca registrada da International Business Machines

2. Microsoft é marca registrada da Microsoft Corporation

## AGRADECIMENTOS

Ao Prof. Dr. Zsolt L. Kovacs pelo incentivo e discussões, ao Prof. Edgard José Casaes pela colaboração na área de linguística, ao Eng. Ivandro Sanches pela troca de idéias e aos engenheiros Wander O. Cesário, Alex D. Zyrianoff e Roberto Martinelli pela colaboração.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] A.H. Sayed, "Simulador de Reconhecedores de Palavras Isoladas – Sir PI," *Dissertação de Mestrado. Departamento de Engenharia de Eletricidade da EPUSP*, Julho 1989.
- [2] D.R. Reddy, "Speech recognition by Machine: A Review" *Proceedings of the IEEE*, vol. 64, pp. 501-531, April 1976.
- [3] G.M.White, "Speech Recognition: A Tutorial Overview", *Computer*, vol. 9, pp. 40-53, May 1976.
- [4] F. Itakura, "Minimum Prediction Residual Principle Applied to Speech Recognition", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-23, n 1, pp. 67-72, February 1975.
- [5] M.R. Sambur and L.R. Rabiner, "A Speaker Independent Digit Recognition System", *The Bell System Technical Journal*, vol. 54, n 1, pp. 91-103, January 1976.
- [6] L.R. Rabiner, "On creating Reference Templates for Speaker Independent Recognition of Isolated Words", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-26, n 1, pp. 34-41, February 1978.
- [7] L.R. Rabiner, J.G. Wilpon and A.E. Rosenberg, "A Voice Controlled Repertory Dialer System", *The Bell System Technical Journal*, vol. 59, pp. 1153-1163, September 1980.
- [8] L.R. Rabiner and S.E. Levinson, "Isolated and Connected Word Recognition – Theory and Selected Applications", *IEEE Transactions on Communications*, vol. COM-29, n 8, pp. 621-658, May 1981.
- [9] Y.Tohkura, "A Weighted Cepstral Distance Measure for Speech Recognition", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-35, n 10, pp.1414-1422, October 1987.

- [10] J. G. Wilpon, L.R. Rabiner and A. Bergh, "Speaker Independent Isolated Word Recognition Using a 129-Word Airline Vocabulary", *The Journal of the Acoustical Society of America*, vol. 72, n 2, pp. 390-396, August 1982.
- [11] J.L. Flanagan, *Speech Analysis, Synthesis and Perception*, Springer-Verlag, New York, 1972.
- [12] L.R. Rabiner and R.W. Schafer, *Digital Processing of Speech Signals*, Prentice Hall, New Jersey, 1978.
- [13] B.S. Atal and S.L. Hanauer, "Speech Analysis and Synthesis by Linear Prediction of the Speech Wave", *The Journal of the Acoustical Society of America*, vol. 50, n 2, part 2, pp. 637-655, April 1971.
- [14] J.D. Markel and A.H. Gray, Jr. *Linear Prediction of Speech*, Springer Verlag, New York, 1976.
- [15] R.W. Schafer and L.R. Rabiner, "Digital Representations of Speech Signals", *Proceedings of the IEEE*, vol. 63, pp. 662-677, April 1975.
- [16] A.V. Oppenheim and R.W. Schafer, *Digital Signal Processing*, Prentice-Hall, New Jersey, 1975.
- [17] A.H. Sayed A. Ferrara e E.T. Taniguchi, "Sistema Reconhecedor de Voz Humana – Programável e com Capacidade de Processamento", Projeto de Formatura, *Departamento de Engenharia de Eletricidade da EPUSP*, 1987.
- [18] L.R. Rabiner and M. R. Sambur, "An Algorithm for Determining the Endpoints of Isolated Utterances", *The Bell System Technical Journal*, vol. 54, n 2, pp. 297-315, February 1975.
- [19] J. Makhoul, "Stable and Efficient Lattice Methods for Linear Prediction", *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. ASSP-25, n 5, pp. 423-428, October 1977.
- [20] A.H. Gray, Jr. and J.D. Markel, "Distance Measures for Speech Processing", *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. ASSP-24, n 5, pp. 380-391, October 1976.
- [21] L. Rabiner, A.E. Rosenberg and S.E. Levinson, "Considerations in Dynamic Time Algorithms for Discrete Word Recognition", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-26, n6, pp. 676-692, December 1978.

- [22] H. Sakoe and S. Chiba, "Dynamic Programming Algorithm Optimization for Spoken Word Recognition", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-26, pp. 43-49, February 1978.
- [23] C. Myers, L.R. Rabiner and A.E. Rosenberg, "Performance Tradeoffs in Dynamic Time Warping Algorithms for Isolated Word Recognition", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-29, n 6, pp. 623-635, December 1980.
- [24] V.N. Gupta, J.K. Bryan and J.N. Gowdy, "A Speaker-Independent Speech Recognition System Based on Linear Prediction". *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-26, n 1, pp. 27-33, February 1978.
- [25] B.H. Juang, D.Y. Wong and A.H. Gray, Jr., "Distortion Performance of Vector Quantization for LPC Voice Coding", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-30, n 2, pp. 294-303, April 1982.
- [26] Y. Linde, A. Buzo and R. M. Gray, "An Algorithm for Vector Quantizer Design", *IEEE Transactions on Communications*, vol. COM-28, n 1, pp. 84-95, January 1980.
- [27] A. Buzo, A.H. Gray, Jr., R.M. Gray and J.D. Markel, "Speech Coding Based Upon Vector Quantization", *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. ASSP-28, n 5, pp. 562-573, October 1980.