

الجمهورية الجزائرية الديمقراطية الشعبية  
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة الجامعات  
Ministère aux Universités

المدرسة الوطنية المتعددة التقنيات  
BIBLIOTHEQUE — المكتبة  
Ecole Nationale Polytechnique

# ECOLE NATIONALE POLYTECHNIQUE

DEPARTEMENT ELECTRONIQUE

## PROJET DE FIN D'ETUDES

SUJET

RECONNAISSANCE  
DE MOTS ISOLÉS  
EN MODE MULTILOCUTEUR

Proposé par :  
Mr N. Beniddir

Etudié par :  
B. Khène  
M. Tounsi

Dirigé par :  
Mr N. Beniddir

PROMOTION JUIN 92

# REMERCIEMENTS

Nous tenons à remercier vivement Mr Beniddir et Mr Derras pour leurs conseils et leur aide .

Que Mrs Kertous , Benali , Abismaïl ainsi que tous ceux qui ont contribué de près ou de loin à la finition de ce document , trouvent ici l'expression et l'assurance de nos remerciements .

# Dedicaces

A la mémoire de mon père ;  
à ma mère , mes frères et toute ma famille ;  
à mon oncle , sa femme et tous ses enfants ;  
à tous (tes) mes amis (es) et mes proches ;

"" Ma teylim lliy                      tellam mara ylliy ""

Med TOUNSI .

A ma mère qui a toujours veillé sur moi ;  
à mon père qui m'a toujours soutenu ;  
à mes frères , mes soeurs et toute ma famille ;  
à tous mes amis et mes proches ;

Brahim KHENE .

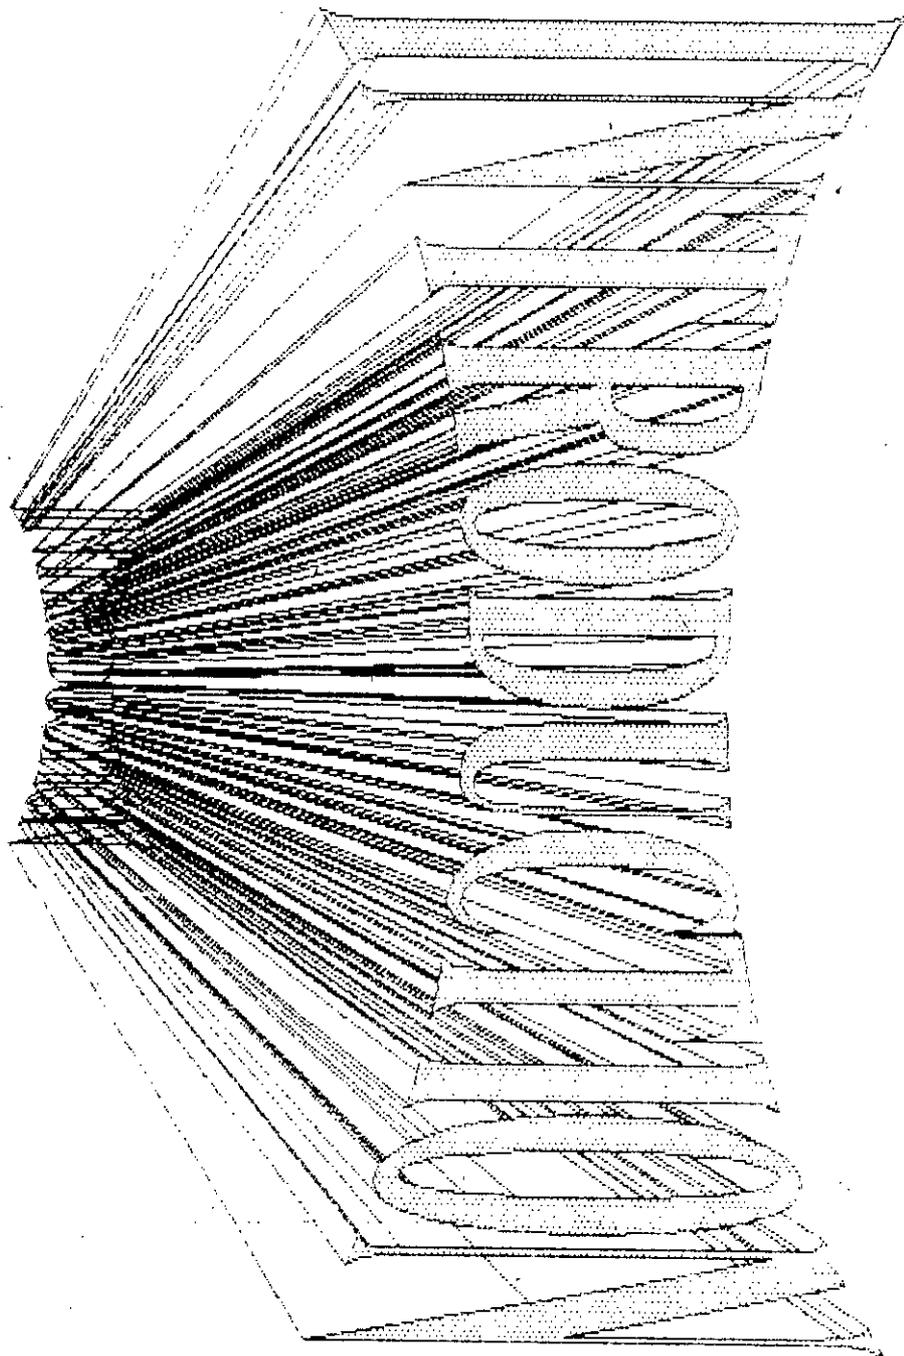
Nous dédions ce mémoire .

SOMMAIRE

--REMERCIEMENTS	0
--DEDICACES	00
--INTRODUCTION	1
-chap I) ANALYSE DE LA PAROLE	5
I-A-INTRODUCTION AU SIGNAL VOCAL	5
I-B)-ANALYSE ACOUSTIQUE	7
B-1 / PRETRAITEMENT DU SIGNAL	7
B-2 / ANALYSE CEPSTRALE	10
B-3 / ANALYSE LPC	15
-chap II) COMPARAISON DYNAMIQUE DES MOTS (DTW)	
II-1 / INTRODUCTION	23
II-2 / FENETRE D'AJUSTEMENT	23
II-3 / DEFINITIONS GENERALES DE LA DISTANCE NORMALISEE DANS LE TEMPS	24
II-4 / RESTRICTIONS SUR LA FONCTION DE DEFORMATION	26
II-5 / COEFFICIENTS DE PONDERATIONS	29
II-6 / ALGORITHMES DE COMPARAISON PAR P.D.	30
-chap III) CLASSIFICATION	
III-1 / INTRODUCTION	33
III-2 / TYPES DE CLASSIFICATIONS	34
III-3 / RAPPELS MATHEMATIQUES	34
III-4 / CLASSIFICATION	36
III-5 / CONCLUSION	42
-CHAP IV) DECISION	
IV-1 / INTRODUCTION	43
IV-2 / TECHNIQUES DES KNN	43
IV-3 / REJETS	43
IV-4 / ALGORITHME	44
-chap V) SIMMULATION DES VOYELES	
V-1 / INTRODUCTION	45

V-2 / METHODES DE SIMULATION . . . . .	45
V-3 / CONCLUSION . . . . .	52
-CHAP VI) TESTS ET RESULTATS	
VI-A TESTS MONOLOCUTEURS . . . . .	53
A-1 / TESTS SUR L'AMPLITUDE . . . . .	53
A-2 / TESTS SUR LA DUREE . . . . .	56
A-3 / TESTS SUR LES FORMANTS . . . . .	61
A-4 / TESTS SUR LE NOMBRE DE COEFFICIENTS . . . . .	65
A-5 / TESTS SUR LA FENETRE D'AJUSTEMENT . . . . .	68
A-6 / TESTS SUR LES DISTANCES LOCALES . . . . .	70
A-7 / CONCLUSIONS . . . . .	72
VI-B / RESULTATS DE LA CLASSIFICATION . . . . .	73
B-1 / INTRODUCTION . . . . .	73
B-2 / GROUPEMENT EN CHAINE . . . . .	74
B-3 / CLASSIFICATION . . . . .	74
B-4 / CONCLUSIONS . . . . .	79
VI-C / TESTS MULTILOCUTEURS . . . . .	79
C-1 / TESTS . . . . .	79
C-2 / CONCLUSIONS . . . . .	82
-chap VII) CONCLUSIONS GENERALES . . . . .	84
-ANNEXE : ORGANIGRAMMES . . . . .	85
-BIBLIOGRAPHIE . . . . .	91

المدرسة الوطنية المتعددة التقنيات  
BIBLIOTHEQUE — المكتبة  
Ecole Nationale Polytechnique



A )- GENERALITES :

"LA PAROLE EST LA FACULTE DE COMMUNIQUER LA PENSEE PAR UN SYSTEME DE SONS ARTICULES " [1] . C'est le moyen de communication privilégié chez les humains qui sont les seuls êtres vivants à utiliser un tel système structuré . Cependant , nous assistons ces dernières années à une énorme profusion de machines multiples sans lesquelles , tout exploit technique ou scientifique est désormais impossible à l'homme moderne .

Le principal problème qui reste un inconvénient pour concrétiser les larges services de ces machines est celui de la " la communication Homme-Machine " qui s'est toujours faite à travers des boites à commande ,des claviers , des écrans de visualisation ....etc .

C'est pourquoi , plusieurs chercheurs et laboratoires du monde ne cessent ,actuellement ,de développer des techniques nouvelles dans l'espérance de rendre ces machines plus "intelligentes".

Parmi ces techniques , nous trouvons Le traitement automatique de la parole qui reste un objectif futuriste englobant :

---La Synthèse Automatique de la parole aboutissant à des machines qui "parlent" ;

---La Compréhension et la Reconnaissance de la parole aboutissant à des machines qui "entendent" et "comprennent"...

Les premières tentatives en reconnaissance de la parole remontent à 1939 avec le vocodeur de Mr.Duilly aux USA . Depuis , l'intérêt économique de certaines entreprises commerciales s'est joint à l'intérêt purement scientifique surtout avec l'avènement des circuits intégrés et le développement considérable de la micro-électronique et de l'informatique . Cela a mené à l'un des projets les plus ambitieux du 21<sup>ème</sup> siècle : Le projet A.R.P.A lancé par le ministère de la défense Américain pour la réalisation d'un système

-----introduction  
de compréhension de la parole de 15 millions \$ avec un vocabulaire  
de 1000 mots .

Les difficultés à résoudre pour la concrétisation de ces projets  
sont considérables à cause de la complexité du signal acoustique de  
la parole , de sa richesse en informations phonétiques, de sa forte  
variabilité , de son aspect aléatoire et coarticulatoire .

La compréhension de la parole est actuellement abordée suivant  
les méthodes suivantes :

--Les méthodes globales :

Les mots y sont considérés comme des entités entières et codés  
comme telles et un silence suffisant doit nécessairement séparer  
deux mots consécutifs . Le système compare le mot à un ensemble  
d'empreintes vocales préenregistrées pour reconnaître la plus  
proche . Le principal désavantage de ces méthodes est que le nombre  
de mots à reconnaître reste encore très limité .

--Les méthodes analytiques :

Ces méthodes sont plus difficiles mais plus intéressantes que  
les précédentes car elles sont utilisées pour reconnaître de la  
parole continue . Les difficultés viennent du fait que la parole  
est divisée en segments et chaque segment doit représenter  
l'emplacement probable de l'entité phonétique choisie . Une analyse  
performante est ensuite appliquée pour extraire les paramètres  
pertinents de chaque segment dans le but de les comparer aux  
entités du dictionnaire établi . Les résultats de cette analyse  
ou plus exactement les probabilités correspondantes à chaque entité  
phonétique sont ensuite affinées en utilisant des informations  
syntaxiques , sémantiques et contextuelles . Ces méthodes sont très  
prometteuses surtout avec l'arrivée des systèmes experts .

Par ailleurs , d'autres méthodes telles que les chaînes de

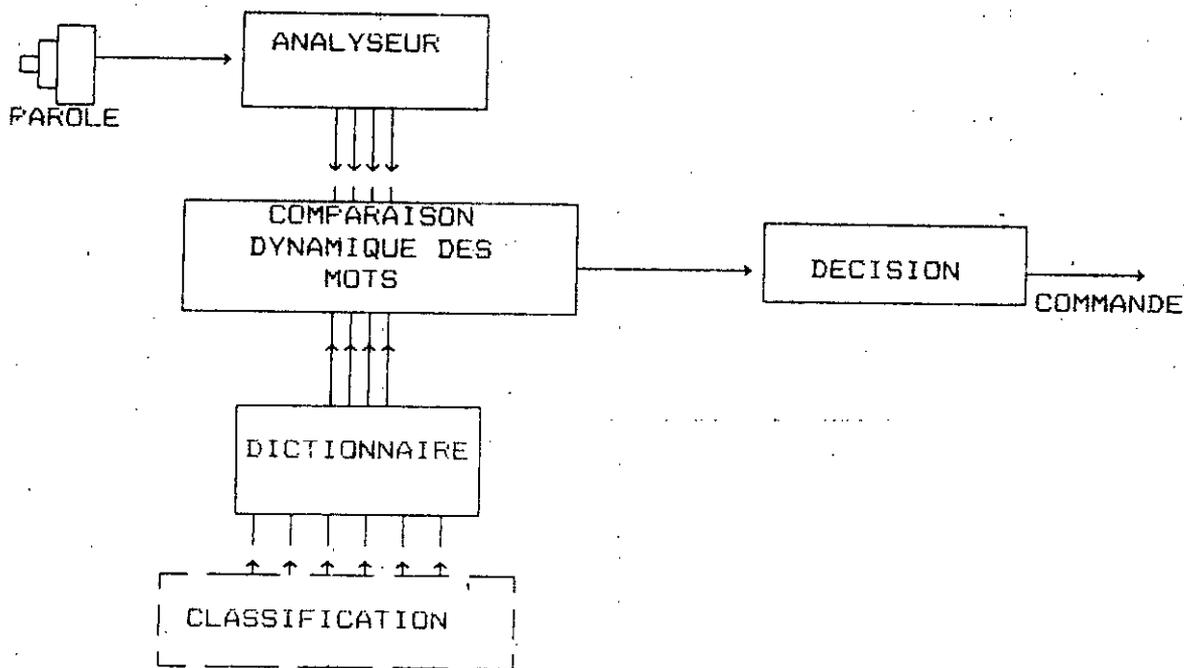
-----introduction  
Markov et l'intelligence artificielle commencent à s'imposer de nos jours avec de grandes performances .

Notons que les systèmes disponibles en reconnaissance de la parole sont soit monolocuteurs ie que tout utilisateur étranger au système serait non reconnu , soit multilocuteurs ie une tentative de généralisation des premiers , qui prennent en considération la variabilité des mots d'un locuteur à un autre .

**B )- PRESENTATION DU TRAVAIL :**

L'objectif de notre travail est l'étude d'un système de reconnaissance de la parole par les méthodes globales en mode multilocuteurs pour une éventuelle implantation sur le micro-procésseur TMS 320 .

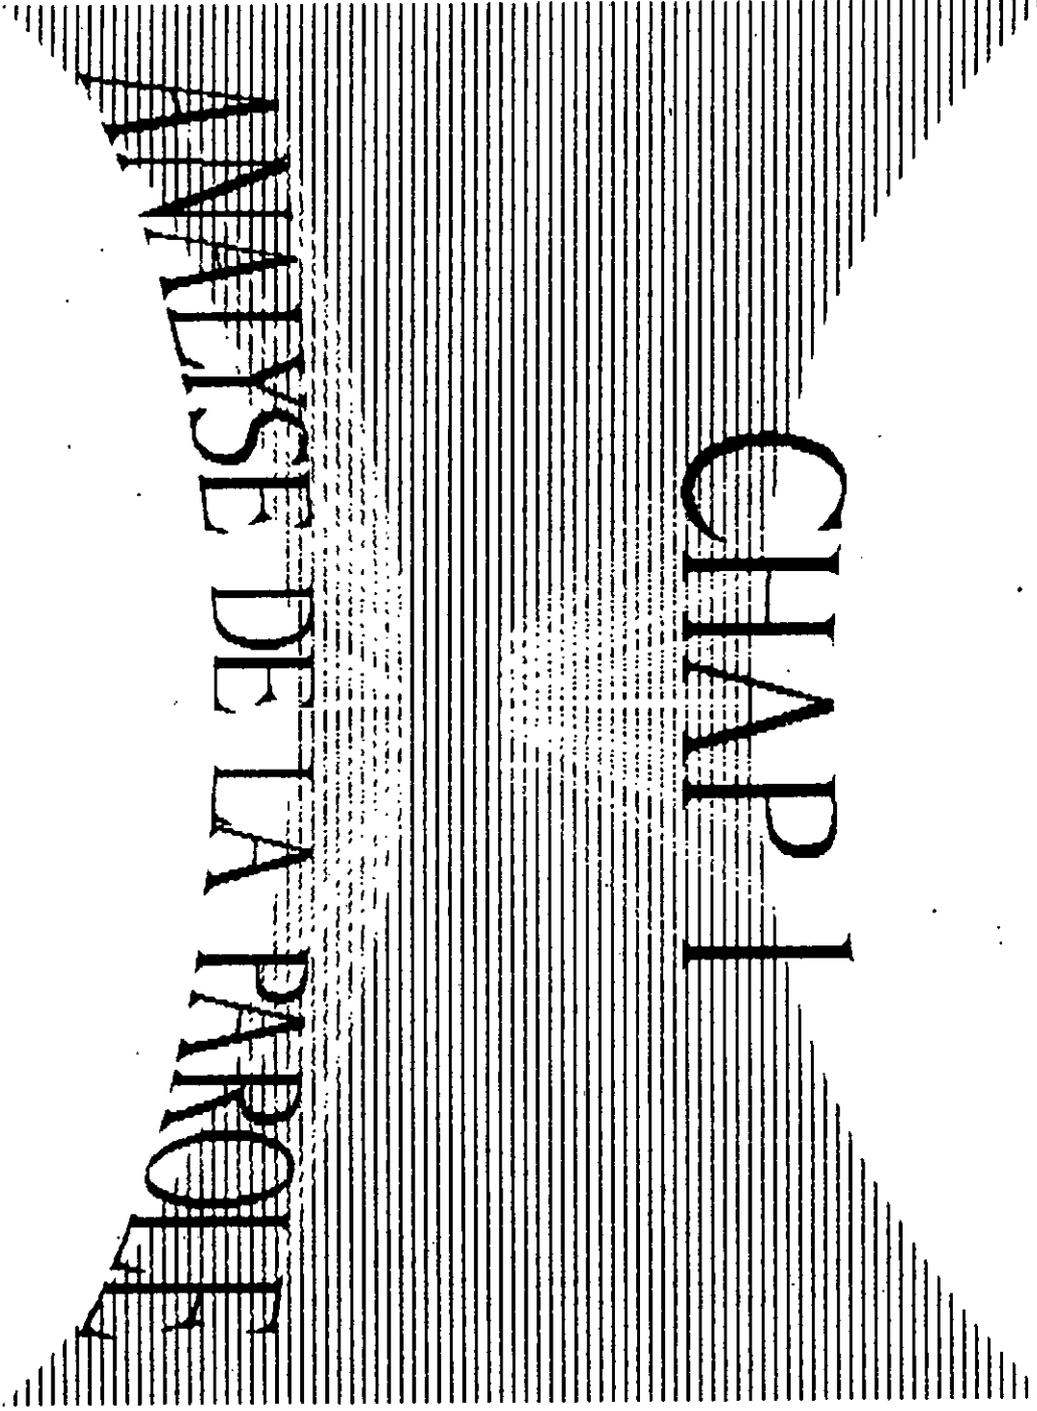
SYNOPTIQUE DU SYSTEME DE RECONNAISSANCE DE LA PAROLE :



Notre mémoire est élaboré de la façon suivante :

- Le chapitre I décrit les méthodes d'analyse que nous appliquons aux voyelles orales de la langue Française ;
- Le chapitre II explique la comparaison dynamique des mots avec ses différents algorithmes ;
- Dans le chapitre III , nous étalons l'apprentissage et les méthodes de reconnaissances que nous avons retenus pour le système ;
- Suit ensuite le chapitre IV où est décrite l'étape de décision sur la reconnaissance des mots ;
- Dans le chapitre V , nous faisons la simulation des voyelles pour nous servir de fichiers pour les tests ;
- Le chapitre VI regroupe les résultats de la classification ie les les différentes configurations des échantillons de nos voyelles qui vont constituer le dictionnaire , ainsi que plusieurs tests que nous avons traités en mode monolocuteurs et d'autres pour finaliser notre reconnaissance en mode multilocuteurs ;
- Enfin , le dernier chapitre (VII) donne nos conclusions générales .

N.B : Les organigrammes sont donnés en annexe .



# CHAP I

## ANALYSE DE LA PAROLE

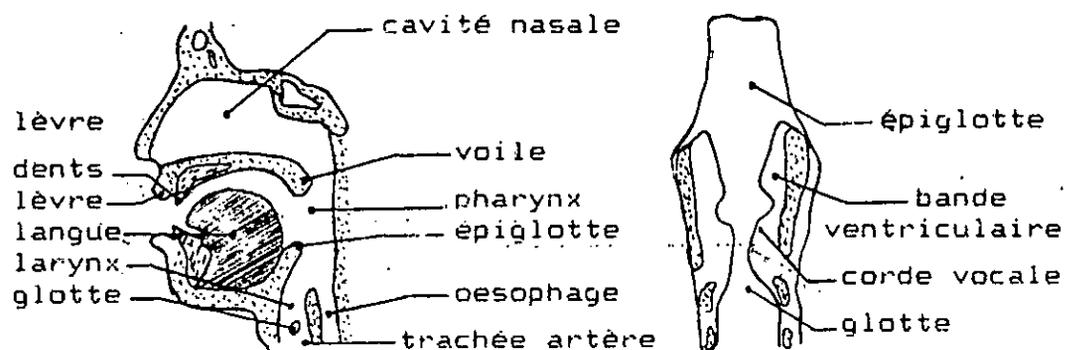
II-A / INTRODUCTION AU SIGNAL VOCAL :

Le contenu d'un message vocal , au sens strict , est simplement son intelligibilité ; au sens large , ce message est très complexe car contenant une quantité importante d'informations imbriquées entre elles , donc d'extraction très difficile . Ce message est aussi caractérisé par une très grande redondance et ce , pour résister aux perturbations du milieu ambiant .

La parole est aussi un phénomène sonore produit par le système phonatoire ( *fig-1-1* ) . L'énergie provient de l'air envoyé par les poumons ( muscles thoraciques et abdominaux ) et rarement de l'air aspiré par la bouche .

II-A-1°/ MECANISME DE PHONATION :

A-1-a / Le conduit vocal :



*fig-1-1) a) appareil phonatoire b) section du larynx*

Le signal vocal est le résultat de l'action volontaire et coordonnée des appareils respiratoires et masticatoires . Cette action se déroule sous le contrôle du système nerveux central qui reçoit en permanence des informations par rétroaction auditive et par des sensations cénesthésiques .

Le conduit vocal est une suite de cavités : pharyngienne , nasale

et buccale qui servent de résonnateurs car selon leurs formes , nous obtenons des résonnances à des fréquences variables appelées FORMANTS . La cavité nasale est soit inutilisée , soit mise en parallèle sur la cavité buccale . La forme de ces cavités est affectée par des articulateurs tels que la langue , les lèvres , les mâchoires ...etc . La combinaison de ces divers éléments permet plusieurs modes de production sonore et d'émission de sons variés .

A-1-b ) l'excitation du système phonatoire :

Elle peut être causée par :

- une brusque variation de pression ;
- la mise en vibration des cordes vocales ;
- ou par un flot d'air crée en certains points de ressèrement du conduit vocal .

11-A-2 / SONS VOISÉS et SONS NON-VOISÉS :

Quand le conduit vocal est excité par une suite d'impulsions périodiques liées aux vibrations des cordes vocales , l'ouverture brusque de la glotte libère la pression accumulée en aval et nous obtenons des sons voisés . Si par contre les cordes vocales s'écartent du chemin de l'air envoyé par les poumons , nous obtenons des sons non-voisés .

11-A-3 / PITCH et FORMANTS :

L'intensité du son émis est liée à la pression de l'air en amont du larynx , sa hauteur est fixée par la fréquence de vibration des cordes vocales , appelées fréquence du fondamental ou Pitch ( $F_0$ ) Cette fréquence peut varier :

- de 80 à 200 Hz pour une voix d'homme ;
- de 150 à 450 Hz pour une voix de femme ;
- de 200 à 600 Hz pour une voix d'enfant .

Sur le spectre d'un son voisé, nous pouvons observer des raies qui correspondent aux harmoniques du pitch. L'enveloppe de ces raies, présente des maximums aux fréquences propres  $F_i$  du conduit vocal ( $i = 1, 2, \dots$ ); ces fréquences sont *Formants*.

## II-B / ANALYSE ACOUSTIQUE :

### II-B-1°) INTRODUCTION :

L'analyse acoustique est la partie essentielle du traitement du signal vocal en vue de réaliser un système de reconnaissance de parole. En effet, cette analyse nous permet d'extraire les paramètres et les coefficients pertinents qui modélisent correctement les caractéristiques du signal vocal.

Initialement, les chercheurs considéraient le signal de parole, pour le traiter, comme tout autre signal. Puis, ils ont développé des techniques très fines spécialement conçues pour le signal vocal, parmi lesquelles nous citons :

- le prétraitement de la parole;
- l'analyse cepstrale ;
- l'analyse prédictive (LPC);
- analyse par banc de filtres .

### II-B-2°) ANALYSES CLASSIQUES :

#### B-2°-A) PRETRAITEMENT DU SIGNAL VOCAL : [2]

Avant d'entamer l'analyse du signal vocal par les techniques LPC et cepstrales, nous lui effectuons un prétraitement pour rendre plus exploitable son contenu .

#### 2°-A-1) Echantillonnage :

Puisque nous adoptons dans notre étude des méthodes numériques ,

le traitement, que nous allons faire, ne s'effectuera pas directement sur les signaux analogiques à temps continu ; ces signaux doivent être échantillonnés, codés puis rangés dans une mémoire pour être traités par la suite. Notons bien, que par traitement du signal de parole, nous entendons dans notre thèse, le traitement de l'information qui y est contenue et l'extraction des paramètres essentiels. Notre objectif étant sa reconnaissance et beaucoup moins sa synthèse.

D'après le théorème de SHANON [2], un signal analogique ayant une largeur de bande finie, limitée à  $F_m$ , ne peut être reconstitué fidèlement à partir de ses échantillons ( $n T_e$ ) que si ceux-ci ont été prélevés avec une période  $T_e$  telle que :

$$(T_e \leq 1/(2 F_m)) \quad \text{ou} \quad (F_e \geq 2 F_m) \quad (I-1)$$

Dans notre cas, le signal de parole est limité à  $F_m = 6 \text{ KHz}$  tout en conservant ses caractéristiques ; par suite, le théorème de SHANON nous permet de choisir :

$$F_e = 1/T_e = 12.8 \text{ KHz} \geq 2 F_m \quad (I-2)$$

où :  $F_e$  : fréquence d'échantillonnage ;

$F_m$  : fréquence maximale du signal de parole .

## 2°-A-2) Préaccentuation :

Le signal sonore diffuse de la bouche vers l'extérieur ; le son étant la transmission d'une onde dans un milieu mécanique (l'air) défini par son impédance mécanique. En débouchant des lèvres, l'onde (son) doit attaquer un milieu mécanique plus important que celui présent dans le conduit vocal. Il y a donc désadaptation des impédances mécaniques au niveau des lèvres. Par suite, le rayonnement du son à l'extérieur s'accompagne d'une baisse d'énergie et d'une distorsion assimilée à une désaccentuation de 6dB/Octave sur tout le spectre [2].

Rétablir le signal tel qu'il était, est un fait très important surtout que les chercheurs désirent par transformation inverse estimer l'évolution de la forme du conduit vocal, les lieux d'articulation et en déduire ainsi la parole prononcée.

Soient  $S(n)$  les échantillons du signal et  $S_u(n)$  ceux du signal préaccentué. La préaccentuation de  $\delta$ dB/Oct que nous faisons, n'est autre n'est qu'une dérivation numérique [2] :

$$S_u(n+1) = S(n+1) - S(n) \quad (I-3)$$

### 2°-A-3) Fenêtrage :

Les variables temps/fréquence sont conjuguées, liées par une relation d'incertitude du type :  $\Delta T \Delta F = 1/\pi$  où  $\Delta T$  est la largeur de la fenêtre d'analyse du signal et  $\Delta F$  le plus petit détail que nous puissions espérer observer dans son spectre. Autrement dit, l'analyse temporelle d'un signal sinusoïdal pur sur une fenêtre temporelle fournit un spectre de largeur  $\Delta F$  au lieu d'une seule raie. Le fenêtrage que nous devons effectuer sur le signal de parole parcequ'il limite l'amplitude des rebonds fréquentiels dus à la limitation temporelle du signal, provoque deux inconvénients :

- les raies s'élargissent d'une part ;
- d'autre part apparaissent, autour des raies centrales, des rebonds dont les niveaux maximaux peuvent être importants, donc pratiquement une résonance (formant) peut influencer très loin du lieu où elle se trouve et perturber certaines régions peu énergétiques.

En somme, la forme de la fenêtre influence l'allure générale de la réponse spectrale.

Plusieurs fenêtres sont envisageables :

----- ( Rectangulaires, triangulaires, de Hanning ).

La plus appropriée reste la fenêtre de HAMMING (cas particulier de la fenêtre de Hanning) quoique donnant une largeur du pic central plus grande que dans le cas de la fenêtre rectangulaire, elle ne

provoque que l'apparition du lobe central (99.96% de l'énergie du signal) et des raies secondaires peu énergétiques (40 dB au dessous du lobe principal).

Cette fenêtre est définie par son expression :

$$W_H(n) = \begin{cases} 0.54 - 0.46 \cos(2\pi(n-1)/N) & \text{pour } 0 \leq n \leq N-1 \\ 0 & \text{sinon} \end{cases} \quad (I-4)$$

Par ailleurs, notons que réduire la durée de la fenêtre temporelle du signal à analyser, revient à accepter une incertitude sur la position des formants. Mais en pratique cette dégradation est acceptée pour pouvoir discerner même approximativement les évolutions rapides du signal.

Dans notre cas, avec  $F_e = 12.8$  KHz nous fixons la largeur de la fenêtre de HANNING à 20ms chacune sur toute la durée d'observations. Cette durée est choisie de façon à assurer la stationnarité de notre signal pour que ses paramètres restent inchangés.

## B-2°-B) ANALYSE CEPSTRALE ; [5]

### 2°-B-1) introduction :

Nous savons déjà que le signal vocal est très complexe vu sa richesse considérable en informations. Son spectre contient les informations phonétiques tandis que les informations prosodiques sont contenues dans le pitch (fréquence du fondamental).

Lorsque, comme dans le cas de nos voyelles, les sons sont voisés, la vibration des cordes vocales (ou source d'excitation) fournit un signal pulsé que le conduit vocal module dans sa totalité. Les cordes vocales et le conduit vocal sont alors combinés par une convolution comme deux filtres. Une déconvolution s'avère nécessaire pour retrouver les informations phonétiques contenues dans les deux spectres. Il nous faut donc séparer le

spectre du signal de celui de la source d'excitation .

L'opération de "déconvolution" obtenue par filtrage inverse est très délicate . Cependant, il existe un moyen simple pour déconvoluer les deux spectres [2] :

L'examen du spectre d'un signal voisé montre que les des ondulations provenant des cordes vocales, modulent la forme du spectre du son prononcé . L'idée est de séparer les deux composantes , superposées par un produit de convolution naturel, en une somme des deux composantes dans un domaine particulier . Ceci est obtenu par des traitements homomorphiques :

Soit  $h(n)$  le signal issu de la source d'excitation et  $x(n)$  la fonction de transfert du conduit vocal indépendante de  $h(n)$ . L'expression du signal sonore  $y(n)$ , obtenu par convolution de  $h(n)$  et  $x(n)$  échantillonnés, s'écrit :

$$y(n) = h(n) * x(n) = \sum_{k=-\infty}^{k=+\infty} h(n-k) \cdot x(k) \quad (I-5)$$

où  $*$  représente le produit de convolution.

Soit  $D$  l'opération de déconvolution qui vérifie les relations suivantes :

$$\begin{aligned} D(n) &= D( h(n) * x(n) ) \\ &= D( h(n) ) + D(x(n)) \end{aligned} \quad (I-6)$$

que nous noterons :

$$y'(n) = h'(n) + x'(n) \quad (I-7)$$

Nous savons que mathématiquement, le produit de convolution (I-5) se transforme avec les transformées en "Z" en une multiplication :

$$Y(Z) = H(Z) \cdot X(Z) \quad (I-8)$$

## 2°-B-2) Déconvolution homomorphiques :

Le traitement homomorphique suggère simplement d'utiliser les

propriétés du logarithme sur la transformée en "Z" pour obtenir la somme désirée :

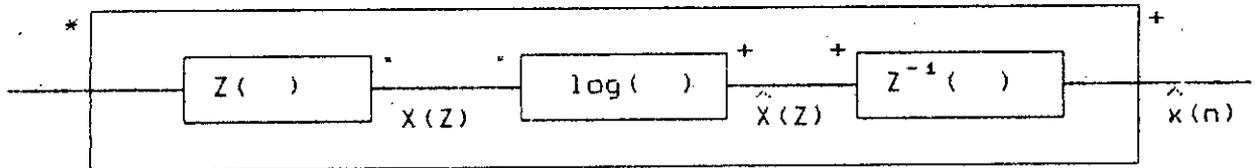


fig. I. 2. Déconvolution homomorphique.

Nous trouvons alors :

$$\begin{aligned}
 Y'(Z) &= \log [Y(Z)] = \log [H(z) \cdot X(Z)] \\
 &= \log [H(z)] + \log [X(Z)] \quad (I-9) \\
 &= H'(Z) + X'(Z)
 \end{aligned}$$

la transformation ci-dessus n'est pas applicable en règle générale car le logarithme d'un nombre complexe a une partie imaginaire indéfinie:

$$Y'(Z) = \log [Y(Z)] = \log |Y(Z)| + j \arg [Y(Z)] \quad (I-10)$$

la transformée de Fourier inverse du logarithme du spectre de notre signal nous donne son cepstre complexe :

$$y'(n) = \frac{1}{2\pi} \int_{-\pi}^{+\pi} Y'(e^{j\nu}) e^{j\nu n} d\nu \quad (I-11)$$

dans notre cas, seule la partie réelle est utilisée, donc le problème d'unicité ne se pose pas dans nos calculs; le cepstre vaut alors :

$$c(n) = \frac{1}{2\pi} \int_{-\pi}^{+\pi} \log |Y(e^{j\nu})| e^{j\nu n} d\nu \quad (I-12)$$

Les expressions (IV-10) et (IV-12) nous donnent la relation :

$$c(n) = \frac{y'(n) + y'(n)}{2} \quad (I-13)$$

combinée à l'expression (II-11) :

$$c(n) = \frac{1}{2\pi} \int_{-\pi}^{+\pi} \log [Y(e^{jv})] \cos(vn) dv \quad (I-14)$$

Cette dernière relation nous montre que le cepstre peut être calculé par la transformée en cosinus du logarithme du spectre complexe du signal considéré.

#### 2°-B-3) Quelques propriétés des coefficients cepstraux :

L'examen des relations (I-11,12,14) montre que les coefficients cepstraux sont normalisés en énergie et sont insensibles à des modifications en amplitude du signal. Ces coefficients décroissent en  $1/n$  où  $n$  est leur rang [2]. Par suite peu de coefficients sont utilisés en pratique, et beaucoup d'ouvrages fixent leur nombre à 12.

#### 2°-B-4) Echelle MEL :

Des études physiologiques et perceptives de l'oreille ont montré qu'elle est sensible à une échelle presque logarithmique en fréquence. Ceci veut dire implicitement que les informations phonétiques sont réparties dans des zones croissantes de façon exponentielle en fonction de la hauteur de la fréquence.

Une échelle quasilogarithmique du spectre [2] appelée échelle MEL, a montré son efficacité pour le calcul cepstral mieux que l'échelle linéaire.

L'échelle MEL est linéaire sur le premier Khz et logarithmique au dessus. Sur toute la longueur de cette échelle, sont répartis des filtres triangulaires de largeurs uniformes sur le premier Khz et

-----chap I  
 variable au dessus. Ces filtres sont décalés, les uns des autres, de la moitié de leurs largeurs. leurs débuts sont obtenus, au delà du 1<sup>er</sup> Khz, en appliquant une raison géométrique supérieure à l'unité car leurs largeurs sont croissantes de façon exponentielle.

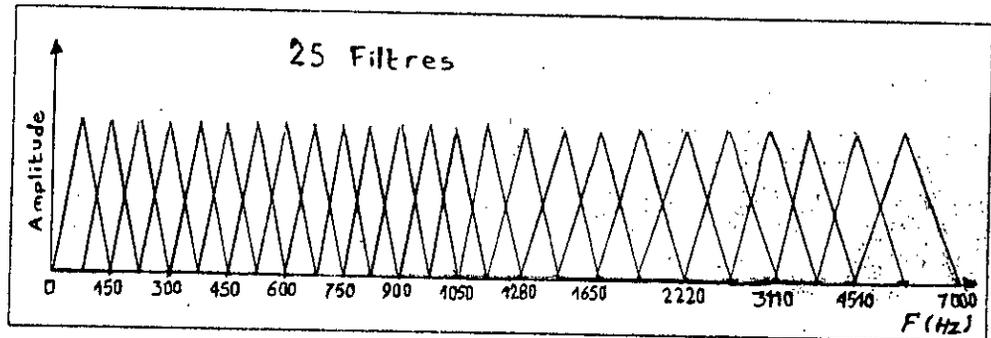


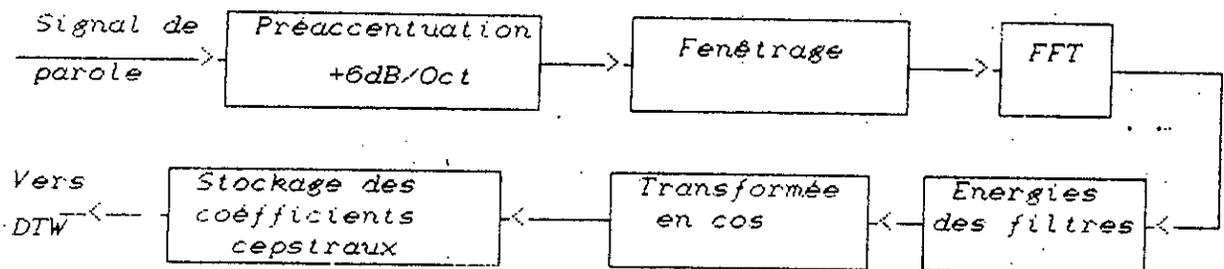
fig I -3- Echelle MEL

Avec la série des filtres, l'expression du cepstre est donnée [2] comme suit :

$$c(n) = \frac{1}{N_f} \left\{ \sum_{k=1}^{N_f} \log [ E(k) ] \cos [ n(k-1)/N_f ] \right\} \quad (I-15)$$

où:  $N_f$  est le nombre de filtres utilisés;  
 $n$  est le rang du coefficient cepstral;  
 $k$  est le numéro du filtre d'énergie  $E(k)$ .

2°-B-5) Etapes d'analyse :



La FFT sert pour le calcul du spectre du signal de parole.

2°-B-7) Organigramme : voir l'annexe .

2°-C ) ANALYSE PAR PREDICTION LINEAIRE (LPC):

2°-C-1 ) Introduction :

La prédiction linéaire est l'une des techniques les plus appropriées au traitement de la parole. Elle nous permet d'estimer certains paramètres comme le pitch, les formants et avec une grande précision et rapidité dans les calculs. Cette prédiction peut être :

progrressive ou rétrograde.

La *prédiction progressive* (ou *prédiction avant*) est celle qui nous permet de prédire une valeur future d'un signal échantillonné  $x(n)$  à partir :

des  $p$  échantillons précédents  $x(n-i)$  ,  $i = 1..p$  .

La *prédiction rétrograde* (ou *prédiction arrière*) est celle qui, au lieu de prédire, vérifie une valeur passée  $x(n-p-1)$  à partir des mêmes échantillons.

2°-C-2 ) Modélisation du signal vocal :

L'étude du mécanisme de la phonation (3) a montré que le signal vocal est produit par un système autorégressif (AR) qui serait soumis à une excitation idéalisée  $u(n)$  sous forme d'un bruit blanc pour les sons non voisés; et pour les sons voisés d'un train d'impulsions périodiques d'amplitude unité. Cette excitation est idéalisée car la forme réelle de l'impulsion glottique et la radiance des lèvres sont comprises dans l'expression de la transmittance de notre système AR pour les sons voisés ( puisque les voyelles orales que nous étudions le sont ).

L'excitation  $u(n)$  est donnée par :

$$u(n) = \sum_K \delta(n-kP) \quad (I-16)$$

où  $P$  est la période du pitch exprimée en nombre de périodes

d'échantillonnage.

Dans ce modèle de production, un échantillon quelconque  $x(n)$  d'un signal est une combinaison linéaire des  $p$  échantillons qui le précèdent en ajoutant le terme  $u(n)$  d'excitation pour avoir la récurrence linéaire suivante :

$$x(n) + \sum_{i=1}^p a(i) x(n-i) = \sigma u(n) \quad (I-17)$$

où les coefficients  $a(i)$  sont dits coefficients de prédiction et  $\sigma$  est le gain du système .

### 2°-C-3 ) Estimation du modèle :

Nous considérons que notre signal  $x$  est à priori engendré par un système autorégressif (AR). L'excitation de ce système est inaccessible donc l'estimation des paramètres du modèle sera basée exclusivement sur l'observation du signal.

Comme la récurrence linéaire (I-17) reste vérifiée, nous pouvons définir une prédiction ou estimation  $\hat{x}(n)$  à partir des  $p$  échantillons qui le précèdent :

$$\hat{x}(n) = - \sum_{i=1}^p \hat{a}(i) x(n-i) \quad (I-18)$$

Les coefficients  $\hat{a}(i)$  étant les estimés des coefficients  $a(i)$  .

L'erreur commise par la prédiction vaut :

$$\begin{aligned} e(n) &= x(n) - \hat{x}(n) \\ &= \sum_{i=1}^p \hat{a}(i) x(n-i) \quad ; \quad \hat{a}(0) = 1 \end{aligned} \quad (I-19)$$

Si nous comparons les expressions (I-17) et (I-18) avec  $\hat{a}(i)$  égal à  $a(i)$  pour  $i = 1..p$ , nous trouvons :

$$e(n) = \sigma u(n) \quad (I-20)$$

Dans notre suite, nous abandonons l'indice " $\hat{\phantom{a}}$ " pour désigner un coefficient estimé.

2°-C-4 ) Modélisation autorégressive du signal vocal :

C-4-a ) Formalisme LPC :

L'analyse LPC suppose que le signal vocal traité est approximé par un polynôme d'ordre  $p$ , lequel ordre est choisi entre 10 et 30. Un échantillon du signal  $y$  est représenté par les  $p$  échantillons qui le précèdent par la combinaison linéaire

$$s_p(n) = \sum_{k=1}^p a(k) s(n-k) \quad (I-21)$$

où  $n=1..N$  (indice d'échantillons par fenêtre) ;  
et  $p$  l'ordre de prédiction.

C-4-b ) Problème de la non-stationnarité :

Le signal vocal étant très chaotique, ne peut être considéré quasi stationnaire que sur des intervalles de temps très limités.

Nous sommes donc amenés à considérer des tranches successives et à estimer un modèle AR pour chacune d'elles. La procédure usuelle consiste donc à effectuer notre analyse successivement sur nos fenêtres de 20ms avec extraction des paramètres désirés au cours de chacune d'elles.

C-4-c ) Energie résiduelle de prédiction :

Elle est définie comme étant la variance à court terme de l'erreur de prédiction (3):

$$E_p = \sum_{n=\text{inf}}^{\text{sup}} e^2(n) \quad (I-22)$$

Les limites inf et sup étant les bornes à définir sur chaque fenêtre et selon la méthode utilisée pour l'estimation des coefficients LPC

C-4-d ) Critère d'estimation des coefficients LPC :

Le critère usuel reste la minimisation de l'erreur de prédiction ou plus exactement de l'énergie résiduelle  $E_p$  ie la somme des carrés des échantillons .

Ce critère peut être justifié par le fait que lorsque l'excitation est un train d'impulsions comme dans notre cas (voyelles orales : sons voisés), elle est nulle entre deux impulsions ; or l'erreur de prédiction représente l'excitation à un facteur près ( $\sigma$ ) . Il est donc bien justifié d'en minimiser l'erreur.

C-4-e ) Méthode d'autocorrélation :

Dans cette méthode , nous écrivons :

$$\text{inf} = 1 \quad \text{et} \quad \text{sup} = N+p ;$$

N est le nombre d'échantillons par fenêtre

$$\begin{aligned} E_p &= \sum_{n=1}^{N+p} e^2(n) = \sum_{n=1}^{N+p} \left[ S(n) - S_p(n) \right]^2 \\ &= \sum_{n=1}^{N+p} \left[ S(n) - \sum_{k=1}^p a(k) S(n-k) \right]^2 \end{aligned} \quad (I-23)$$

Minimiser  $E_p$  revient à annuler sa dérivée par rapport aux coefficients  $a(k)$ , soit :

$$\frac{\partial E_p}{\partial a(i)} = 0 \quad \text{pour } i=1..p \quad (I-24)$$

ie:

$$\sum_{n=1}^{N+p} 2 \left[ S(n) - \sum_{k=1}^p a(k) S(n-k) \right] S(n-i) = 0$$

d'où:

$$\sum_{n=1}^{N+p} S(n) S(n-i) = \sum_{n=1}^{N+p} S(n) \left[ \sum_{k=1}^p a(k) S(n-i) \right]$$

soit:  $\begin{matrix} N+p & & N+p \\ & P & N+p \end{matrix}$

$$\sum_{n=1} S(n-1) S(n) = \sum_{k=1} a(k) \left[ \sum_{n=1} S(n-i) S(n-k) \right] \quad (I-25)$$

Définissons la quantité  $\phi(i,k)$  telle que :

$$\phi = \sum_{n=1}^{N+p} S(n-i) S(n-k)$$

par suite, l'équation (I-25) s'écrit plus compactement:

$$\sum_{k=1}^p a(k) \phi(i,k) = \phi(i,0) \quad (I-26)$$

Vu que notre signal est nul en dehors de l'intervale  $[1, N]$ , la quantité  $\phi(i,k)$  peut s'écrire encore :

$$\begin{aligned} \phi(i,k) &= \sum_{n=1}^{N+p} S(n-i) S(n-k) \\ &= \sum_{n=1}^{N-(i-k)} S(n) S(n+i-k) = \sum_{n=1}^{N-i+k} S(n) S(n+i-k) \end{aligned} \quad (I-27)$$

Nous reconnaissons alors l'expression de la fonction d'autocorrelation  $R(\tau)$  du signal,  $S(n)$  évaluée pour  $\tau = i-k$ .

En utilisant la parité de cette fonction, nous écrivons :

$$\phi(i, k) = R(|i-k|) \quad \text{et} \quad \phi(i, 0) = R(|i|) = R(i)$$

La relation (II-26) devient alors :

$$\sum_{k=1}^p a(k) R(|i-k|) = R(i) \quad (I-29)$$

avec :  $i=1..p$  et  $R(i) = \sum_{k=1}^{N-i} S(n) S(n+i)$

Cette équation est réellement une formulation matricielle tq :

$$(S) \begin{bmatrix} R(0) & R(1) & \dots & R(p-1) \\ R(1) & R(0) & \dots & R(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ R(p-1) & R(p-2) & \dots & R(0) \end{bmatrix} \begin{bmatrix} a(1) \\ a(2) \\ \vdots \\ a(p) \end{bmatrix} = \begin{bmatrix} R(1) \\ R(2) \\ \vdots \\ R(p) \end{bmatrix}$$

La matrice ci-dessus est une matrice "TOEPLITZ" symétrique car les éléments de chaque diagonale parallèle à la diagonale principale sont égaux.

C-4-f ) Résolution du système d'équations linéaires (S) :

De nombreuses méthodes permettent de résoudre le système d'équations d'autocorrélation (S), telles que :

- la méthode de Gauss-Seidel;
- la méthode de Jaccobi;
- la méthode de Gauss-Jordan;
- la méthode de Durbin;

Compte-tenu de la rapidité d'exécution et de la réduction de l'occupation mémoire, nous avons choisi, pour la résolution de notre système d'équations d'autocorrélation, la méthode de DURBIN.

Méthode de Durbin :

cette méthode permet de résoudre notre système par une

récursion sur l'ordre de la prédiction en considérant que la fonction d'autocorrélation est connue pour  $n=0..N$ .

Algorithme : (4)

Nous fixons l'ordre de prédiction à  $p = 12$

$$D(i) = \frac{1}{E(i-1)} \left\{ R(i) - \sum_{j=1}^{i-1} [a(j, i-1) R(i-j)] \right\}$$

$$a(i, i) = D(i)$$

$$a(j, i) = a(j, i-1) - D(i) a(i-j ; i-1)$$

$$E(i) = [1 - D^2(i)] E(i-1)$$

avec :  $i = 1..p$  ; et  $j = 1..p$

et où :  $E(i)$  : erreur quadratique;  
 $D(i)$  : coefficient de reflexion;  
 $a(j, i)$  : coefficient de prédiction;  
 $R(j)$  : coefficient d'autocorrélation .

Conditions initiales :

$$E(0) = R(0) ; D(1) = R(1)/R(0)$$

$$a(1, 1) = D(1) ; E(1) = [1 - D^2(1)] R(0)$$

SOLUTIONS FINALES :  $a(j) = a(j, p)$  ,  $j = 1, p$

C-4-g ) Remarques :

a) La dénomination 'autocorrélation' utilisée dans cette analyse ne correspond pas nécessairement à la signification qui lui est attribuée en statistique .

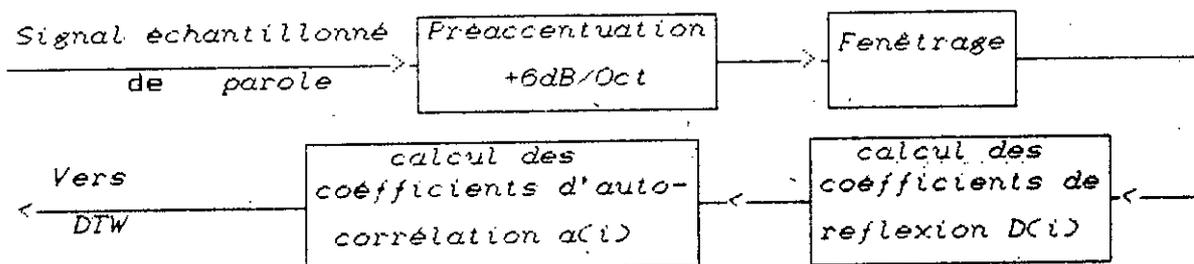
b) La méthode d'autocorrélation est parfois appelée méthode stationnaire, en effet nous étions amenés à considérer que :  
 $\phi(i, k) = R(i, k) = R(j)$  , ce qui constitue une propriété spécifique des signaux stationnaires.

c) l'erreur de prédiction doit présenter des valeurs exagérées en

début d'intervalle car la prédiction porte alors sur un nombre insuffisant d'échantillons, idem en fin d'intervalle où nous tentons de prédire des valeurs nulles pour  $S(n)$ . Cependant, cet effet se trouve minimisé du fait que les échantillons du signal vocal ont déjà été pondérés par une fonction fenêtre .[3].

2°-C-5 ) Etapes d'analyse :

Le synoptique suivant décrit les étapes de l'analyse LPC



2°-C-6 ) Organigramme : Voir l'annexe .

WINDY  
DIPLOMA

## II-1°) INTRODUCTION :

Le taux de variation de la parole produit nécessairement des fluctuations dans l'axe temporel des échantillons ou modèle considéré. Un même mot prononcé par une seule personne voit sa durée varier suivant le contexte, l'intonation, et son état personnel. L'élimination de ces fluctuations, dite Normalisation temporelle, a été l'un des problèmes principaux dans la recherche sur la reconnaissance de la parole.

Parmi les techniques utilisées nous trouvons :

-La Normalisation Linéaire où les différences temporelles entre les échantillons sont éliminées par transformation linéaire de l'axe des temps;

-La Normalisation Non-Linéaire: plus conseillée que la précédente car elle consiste à moduler approximativement les fluctuations de l'axe des temps par une fonction de déformation non linéaire dotée de propriétés bien spécifiques. La différence temporelle entre deux échantillons de la parole est éliminée en déformant l'axe temporel de l'un d'entre eux de sorte que leurs maximums coïncident. La distance dans le temps sera donnée par la distance résiduelle, entre eux, minimisée. La procédure de minimisation prouve son efficacité avec l'utilisation de la programmation dynamique.

La comparaison des mots sera faite globalement sur leurs trames, si les mots sont différents, la distance qui les sépare sera plus grande que celle qui découlera de la comparaison de mots identiques.

## II-2°) FENETRES D'AJUSTEMENT :

La comparaison des mots se fait sur un espace de recherche restreint formé d'un rectangle dont chaque côté sera bordé par l'un des mots à comparer. Chaque mot est représenté par une suite

de trames dont le nombre dépend de sa longueur, et chaque trame est définie par un ensemble de coefficients cepstraux et/ou LPC.

Pour optimiser les calculs, le champ de recherche de la fonction de déformation est limité par des contraintes qui éliminent les zones très improbables dans lesquelles toute comparaison n'a aucun sens. Les chercheurs ont donné deux fenêtres dites 'fenêtres d'ajustement' :

- l'une est parallépipédique (fig-II-3a) ;
- l'autre est de forme losange (fig-II-3b) .

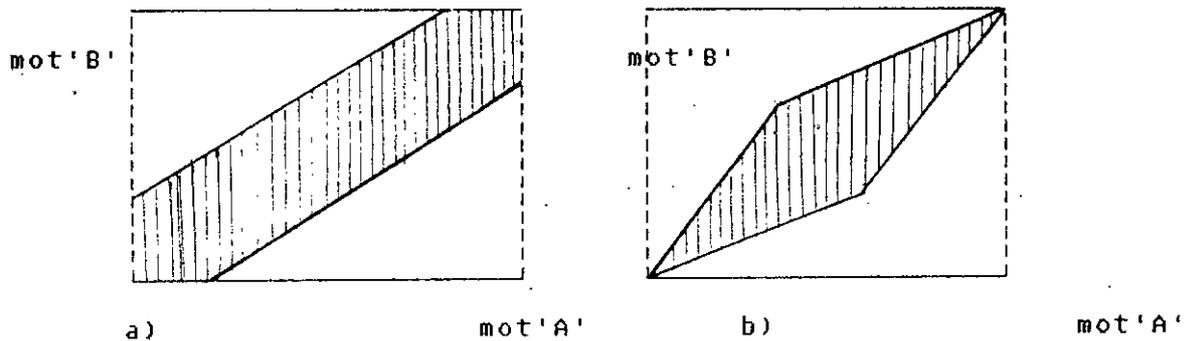


fig-V-1) Fenêtres d'ajustement

II-3°) DEFINITIONS GÉNÉRALES DE LA DISTANCE NORMALISÉE DANS LE TEMPS

Sient deux vecteurs (acoustiques) A et B tq :

$$A = a_1, a_2, \dots, a_i, \dots, a_I \quad \text{et} \quad B = b_1, b_2, \dots, b_j, \dots, b_J$$

où  $a_i$  et  $b_j$  sont les trames d'indices  $i$  et  $j$  respectivement des mots A et B. Ces deux vecteurs représentent deux échantillons de la parole à comparer.

Considérons un plan (i-j) où A serait développé sur l'axe i et B sur l'axe j. La distance temporelle entre A et B est représentée par une séquence de points C(i,j) pouvant donner une fonction qui réalise une correspondance approximative entre les axes temporels des échantillons A et B :

$$F = C(1), C(2), \dots, C(k), \dots, C(K) \quad (II-1)$$

où  $C(k) = C(i(k), j(k))$

Cette fonction est appelée *fonction de déformation*. Elle coïncide avec la diagonale si A et B sont identiques, et s'en éloigne de d'autant plus que que la différence entre A et B augmente.

3° 1 ) Distance locale :

La mesure de la dissemblance ou de la distorsion entre les deux vecteurs A et B, est représentée par une distance  $D(A, B)$  tq:

$$\begin{aligned} D(A, B) &= \sum_{k=1}^K d(C(k)) \\ &= \sum_{k=1}^K d(C_i(k), C_j(k)) \end{aligned} \quad (II-2)$$

où  $d(C_i(k), C_j(k))$  est la distance locale où la dissemblance entre les trames  $a_i$  et  $b_j$ , représentées par un nombre p de coefficients cepstraux et/ou LPC  $C_i(k)$  et  $C_j(k)$ .

Plusieurs formules de la distance locale sont envisageables :

-Distance de Tchebychef :

$$d_{Tch}(a_i, b_j) = \sum_{k=1}^P \left| |C_i(k) - C_j(k)| \right|$$

-distance cepstrale :

$$d_{cep}(a_i, b_j) = [C_i(0) - C_j(0)]^2 + 2 \sum_{k=1}^P [C_i(k) - C_j(k)]^2$$

-Distance d'Itakura :

$$d_{Ita}(a, b) = \text{Log} \left[ \frac{a_i V_i a_i'}{b_j V_j b_j'} \right]$$

Où V est la matrice d'autocorrélation

-Distance cepstrale pondérée :

$$d_{cp}(a_i, b_j) = \sum_{k=1}^P k^2 [C_i(k) - C_j(k)]^2$$

3° 2 ) Distance Globale :

La somme pondérée des distances sur la fonction de déformation F s'écrit :

$$E(F) = \sum_{k=1}^p d(C(k)) \cdot w(k) \quad (w(k) \geq 0)$$

Les coefficients de pondération  $w(k)$  ont été introduits pour permettre une meilleure flexibilité dans la mesure de  $E(F)$ . Cette dernière atteint son minimum quand  $F$  est déterminée avec un ajustement optimal de la différence temporelle

La valeur de la distance résiduelle minimum peut être considérée comme la distance entre les échantillons A et B. Cette distance devrait montrer une stabilité vis à vis des fluctuations des axes des temps. Par suite, la distance globale entre A et B est donnée par :

$$D(A,B) = \min_F \left\{ \frac{\sum_{k=1}^K d(C(k)) \cdot w(k)}{\sum_{k=1}^K w(k)} \right\} \quad (II-3)$$

Les caractéristiques effectives de cette distance dépendent largement des spécifications de la fonction de déformation et de la définition des coefficients de pondérations ainsi que des propriétés des échantillons considérés d'où deux conditions à satisfaire :

- les échantillons sont obtenus avec une période d'échantillonnage commune et constante ;
- les échantillons A et B sont supposés contenir la même quantité d'informations phonétiques .

#### II-4°) RESTRICTIONS SUR LA FONCTION DE DEFORMATION :

La fonction  $F$  est un modèle des fluctuations de l'axe des temps dans un échantillon de parole. Les caractéristiques essentielles des échantillons de parole sont la continuité, la monotonie, la limitation sur la vitesse de transition des

parametres acoustiques....etc.

Ces conditions sont considérées comme des restrictions sur la fonction F

1) condition de monotonicit  :

$$\begin{cases} i(k-1) \leq i(k) \\ j(k-1) \leq j(k) \end{cases}$$

2) condition de continuit  :

$$\begin{cases} i(k) - i(k-1) \leq 1 \\ j(k) - j(k-1) \leq 1 \end{cases}$$

Ces deux restrictions nous permettent d' crire :

$$C(k-1) = \begin{cases} (i(k), j(k)-1) \\ \text{ou } (i(k)-1, j(k)-1) \\ \text{ou } (i(k)-1, j(k)) \end{cases}$$

3) conditions aux limites :

$$\begin{cases} i(1)=1; j(1)=1 \\ i(K)=I; j(K)=J \end{cases}$$

4) condition sur l'ajustement de la fen tre :

$$\left| i(k) - j(k) \right| \leq r \quad ; \text{ largeur de la fen tre } r > 0$$

5) condition sur la contrainte de pente :

La pente de la fonction de d formation F ne doit  tre ni trop raide ni trop douce car de telles d viations peuvent causer des d formations ind sirables de l'axe temporel. Cette contrainte a  t  introduite pour que sa premi re d riv e soit de forme discr te

Par ailleurs, la condition sur la contrainte de pente est repr sent e comme une restriction sur les configurations possibles des points cons cutifs de la fonction F .

L'intensit  effective de cette contrainte (fig-II-4) peut  tre  valu e par :

$$p = n / m$$

o  : n est le nombre de d placements sur la diagonale ;

et m le nombre de d placements sur l'axe i ou l'axe j .

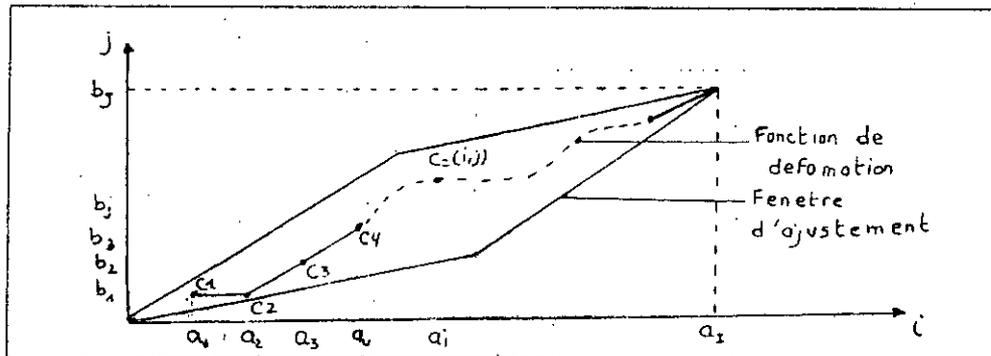


fig II-3 fonction de déformation F .

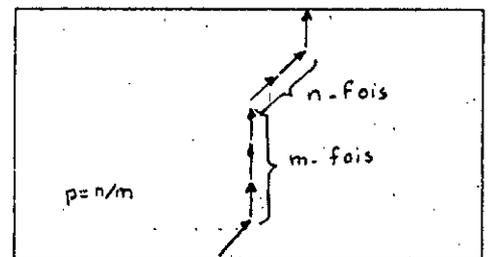
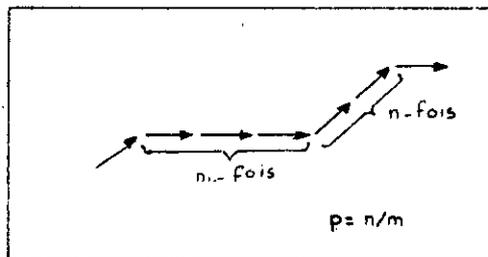


fig II-4 Intensité effective p de F ,

Discussion sur l'intensité p :

- si  $p = 0$  : il n'ya pas de restrictions sur F ;
- si p est infinie : F est restreinte à la diagonale  $i=j$  ;
- si p est sévère (grande) : la normalisation ne se fait pas correctement ;
- si p est douce (petite) : la discrimination entre les différentes catégories des échantillons de parole sera dégradée .

Donc p ne doit être ni trop douce ni trop sévère :  $0 \leq p \leq 2$

Chemins possibles des points C(k) :

Soit une pente:  $p = 1$

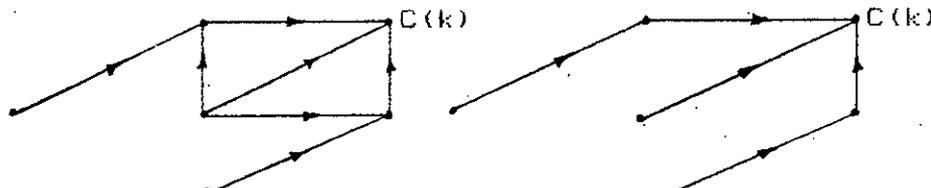


fig-II-5)- a) chemin original

b) chemin simplifié

Le chemin simplifié (b) répond à une nouvelle contrainte qui est : la deuxième dérivée de F doit satisfaire la restriction que le chemin du point C(k) ne doit pas changer de direction orthogonalement. Cette nouvelle restriction réduit donc le nombre de chemins à chercher.

#### II-5° ) LES COEFFICIENTS DE PONDERATIONS :

Soit N le dénominateur de l'expression de D(A,B) (II-3):

$$N = \sum_{k=1}^K w(k)$$

Si N est indépendant de la fonction F de déformation, D(A,B) sera:

$$D(A,B) = \frac{1}{N} \text{Min} \left[ \sum_F d(C(k)) \cdot w(k) \right] \quad (\text{II-4})$$

Le problème de comparaison serait, alors, simplifié et facilement résolvable par la P.D. Il y a deux définitions typiques des coefficients de pondération qui permettent cette simplification.

#### 5°-1 ) Forme symétrique :

$$w(k) = (i(k) - i(k-1)) + (j(k) - j(k-1))$$

$$\text{avec : } N = I + J$$

#### 5°-2) Forme assymétrique :

$$w(k) = \begin{cases} (i(k) - i(k-1)) & \text{avec : } N = I \\ \text{ou} \\ (j(k) - j(k-1)) & \text{avec : } N = J \end{cases}$$

Le concept de ces deux formes a été défini à l'origine par SAKOE et CHIBA. S'il est assuré que les axes du temps sont tous deux continus alors, dans la forme symétrique, la sommation dans l'expression de D(A,B) est une intégration le long de l'axe temporel :  $l = i + j$ . Par contre dans la forme assymétrique, cette sommation est une intégration le long de l'axe i ou j.

Comme résultat de cette différence, la distance normalisée dans

le temps est symétrique [  $D(A,B) = D(B,A)$  ] pour la forme symétrique mais pas pour la forme assymétrique .

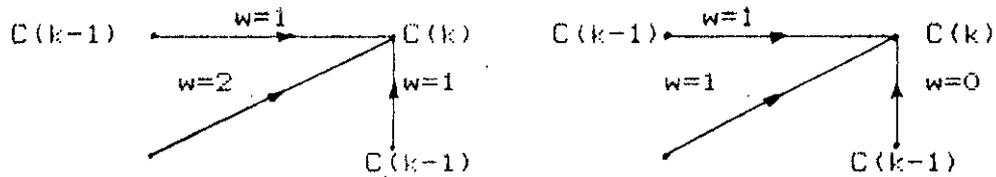


fig II-6) a) forme symétrique

b) forme assymétrique

Un autre résultat plus important dans la différence dans les axes d'intégration est que le coefficient de pondération  $w(k)$  est réduit à zéro dans la forme assymétrique quand le point de la fonction  $F$  se déplace dans la direction de l'axe  $j$  où :  $C(k) = C(k-1) + (0,1)$  ie que quelques vecteurs  $b_j$  peuvent être exclus de l'intégration . Par contre , dans la forme symétrique , aucune exclusion n'est faite puisque :  $\text{Min}( w(k) ) = 1$  Par suite, la forme symétrique donne de meilleurs résultats lors d'un même traitement des échantillons .

11°-6) ALGORITHME DE COMPARAISON PAR P.D : [6]

L'algorithme de base de  $D(A,B)$  s'écrit :

---condition initiale :

$$g_1( C(1) ) = d( C(1) . w(1) )$$

---Equation de P.D:

$$g_k( C(k) ) = \text{Min}_{C(k-1)} \left[ g_{(k-1)}( C(k-1) ) + d( C(k) ) . w(k) \right]$$

---Distance normalisée dans le temps :

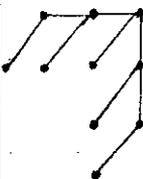
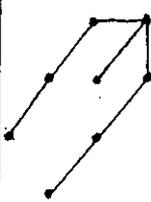
$$D(A, B) = \frac{1}{N} g_k( C(k) )$$

---Suppositions implicites:

$$C(0,0) = 0 \quad \text{et } w(1) = \begin{cases} 2 & \text{pour forme symétrique} \\ 1 & \text{pour forme assymétrique} \end{cases}$$

Dréssons un tableau qui donne les équations de la P.D pour les différentes pentes et pour les deux formes proposées par SAÏOË et

CHIBA .

penne	chemins	forme	Equation de P.D : $g(i,j)=\text{Min}.....$
p=0		symé- trique	$\begin{cases} g(i, j-1)+d(i, j) \\ g(i-1, j-1)+2d(i, j) \\ g(i-1, j)+d(i, j) \end{cases}$
		assymé- trique	$\begin{cases} g(i, j-1) \\ g(i-1, j-1)+d(i, j) \\ g(i-1, j)+d(i, j) \end{cases}$
p=1/2		symé- trique	$\begin{cases} g(i-1, j-2)+2d(i, j-1)+d(i, j) \\ g(i-1, j-1)+2d(i, j) \\ g(i-2, j-1)+2d(i-1, j)+d(i, j) \\ g(i-2, j-1)+2d(i-2, j)+d(i-1, j)+d(i, j) \end{cases}$
		assymé- trique	$\begin{cases} g(i-1, j-2)+[d(i, j-1)+d(i, j)] \cdot \frac{1}{2} \\ g(i-1, j-1)+d(i, j) \\ g(i-2, j-1)+d(i-1, j)+d(i, j) \\ g(i-2, j-1)+d(i-2, j)+d(i-1, j)+d(i, j) \end{cases}$
p=1		symé- trique	$\begin{cases} g(i-1, j-2)+2d(i, j-1)+d(i, j) \\ g(i-1, j-1)+2d(i, j) \\ g(i-2, j-1)+2d(i-1, j)+d(i, j) \end{cases}$
		assymé- trique	$\begin{cases} g(i-1, j-2)+[d(i, j-1)+d(i, j)] \cdot \frac{1}{2} \\ g(i-1, j-1)+d(i, j) \\ g(i-2, j-1)+d(i-1, j)+d(i, j) \end{cases}$
p=2		symé- trique	$\begin{cases} g(i-2, j-2)+2d(i-1, j-1)+2d(i, j-1)+d(i, j) \\ g(i-1, j-1)+2d(i, j) \\ g(i-2, j-1)+2d(i-2, j-1)+2d(i-1, j)+d(i, j) \end{cases}$
		assymé- trique	$\begin{cases} g(i-2, j-2)+\frac{d(i-1, j-1)+d(i, j-1)+d(i, j)}{2} \\ g(i-1, j-1)+d(i, j) \\ g(i-2, j-1)+d(i-2, j-1)+d(i-1, j)+d(i, j) \end{cases}$

Autres algorithmes pour la F.D :

Algorithme	condition initiale	N	Equation de F.D : $g(i, j) =$
Vélichko et Zagoruyko		$\text{Max}(I, J)$	$\text{Max} \begin{cases} g(i, j-1) \\ g(i-1, j-1) + a(i, j) \\ g(i-1, j) \end{cases}$ avec : $a(i, j) = 1 - d(i, j)$
White et Neely	$d(i, j)$	$I * J$	$\text{Min} \begin{cases} g(i-1, j) + d(i, j) \\ g(i-1, j-1) + d(i, j) \\ g(i, j-1) + d(i, j) \end{cases}$
Itakura	$d(1, 1)$	I	$\text{Min} \begin{cases} g(i-1, j) + \alpha d(i, j) \\ g(i-1, j-1) + d(i, j) \\ d(i-1, j-2) + d(i, j) \end{cases}$ avec : $\begin{cases} \infty & \text{si } i(k-1) = i(k-2) \\ 1 & \text{sinon} \end{cases}$

Exemple le plus simple :

Pente :  $p = 0$  ;

Forme : symétrique ;

Ajustement de fenêtre :  $r = 4$  ,  $j-r \leq i \leq j+r$  ;

Equation de F.D : algorithme de Sakoe et Chiba

$$g(1, 1) = 2 d(1, 1)$$

$$g(i, i) = \text{Min} \begin{cases} g(i, j-1) + d(i, j) \\ g(i-1, j-1) + 2d(i, j) \\ g(i-1, j) + d(i, j) \end{cases}$$

Distance  $D(A, B)$ :  $D(A, B) = \frac{1}{N} g(I, J)$  avec  $N = I + J$ .

II°-7 ) ORGANIGRAMME : Voir l'annexe .

NOBILISSIMA

CHAP. III

III-1 / INTRODUCTION :

Notre système de reconnaissance de la parole a pour but d'identifier une locution prononcée par n'importe quel locuteur . Le dictionnaire , que nous lui associons , aura pour données les résultats des méthodes d'analyse que nous aurons déjà effectuées pour chaque locution issue de notre population de référence .

Plusieurs travaux en Reconnaissance de la parole dont nous citons celui de A.Mokkedem [7], ont montré qu'au sein d'une population il existe un certain nombre de classes de prononciations d'une locution donnée ; chaque classe est caractéristique d'une fraction de la population . Nous en faisons une hypothèse justifiée et nous la vérifierons lors de nos tests .

La classification que nous faisons est un ensemble d'algorithmes dont le but est , partant d'un espace totalement inconnu , de définir des classes à partir de l'ensemble des éléments qui composent cet espace [2] .

Mais pourquoi , utilisons - nous la classification ?  
Tout simplement pour la simplification de l'ensemble initial des données . La classification , en effet , s'attache à recouvrir la structure profonde de nos données qui sont complexes et en quantité importante donc difficiles à cerner . Par contre , une structure sous-jacente de ces données peut être très simple , donc intéressante à découvrir . C'est le but que nous recherchons .

Nous exposons ci-après plusieurs algorithmes de classification que nous exploiterons pour la détermination de nos classes et le choix du représentant de chacune d'elles . Parmi ces algorithmes, nous citons :

- Algorithme de Groupement en ( CHAINMAP ) .
- Algorithme des K-Moyennes .
- Algorithme ISODATA .

### III-2 / TYPES DE CLASSIFICATION :

La première étape de la classification dite " d'Apprentissage " permet de choisir un représentant pour chaque classe . Ces représentants de classes constitueront le dictionnaire de référence .

On distingue 3 types de techniques d'Apprentissage [8]:

#### 2-1 / Classification supervisée :

Dans cette technique , le nombre et la nature des classes sont connus ainsi que la répartition des échantillons . On distingue deux méthodes :

- Méthodes statistiques .
- Méthodes géométriques .

#### 2-2 / Classification non-supervisée :

Dans cette technique , le nombre et la nature des classes sont inconnus . Les échantillons sont alors classés essentiellement suivant trois méthodes que nous développerons plus tard et qui sont:

- Méthodes des centroïdes .
- Méthodes des groupements en chaînes ( Chainmap ) .
- Méthodes du SNN ( Shared Nearest Neighbor ) .

#### 2-3 / Classification adaptative :

Une Classification est dite adaptative quand des paramètres ou la structure de l'algorithme sont modifiés pour optimiser la classification , comme dans le cas de l'algorithme ISODATA qui sera détaillé plus loin .

### III-3 / RAPPELS MATHÉMATIQUES :

Soit  $\Omega$  l'ensemble des  $N$  locutions d'un Mot  $X$  tel que :

$$\Omega = \{x_1, x_2, x_3, \dots, x_L, \dots, x_j, \dots, x_N\} \quad (\text{III-1})$$

où les  $x_i$  ( $i=1..N$ ) sont les  $N$  locutions différentes du Mot  $X$  .

Nous pouvons former une matrice D carrée (NxN), où l'élément  $d_{ij}$  de rang ij est une mesure de dissimilarité entre les locutions  $x_i$  et  $x_j$ , définie par :

$$d_{ij} = \delta(x_i, x_j) = \underset{F}{\text{Min}} \left[ \frac{\sum_{k=1}^K d(c(k)) \cdot w(k)}{\sum_{k=1}^K w(k)} \right] \quad (\text{III-2})$$

où : K est le nombre de points de la fonction de déformation F ;

w(k): Fonction de pondération dans la k<sup>lème</sup> fenêtre .

avec :

$$d(c(k)) \cdot w(k) = d(c) = d(i, j) = \| a_i - a_j \| \quad (\text{III-3})$$

où  $a_i$  et  $a_j$  sont les vecteurs LPC ou Cepstraux dans la k<sup>lème</sup> fenêtre .

L'ensemble  $\Omega$  est formé de M classes  $\{w_i\}$  pas nécessairement disjointes, de locutions du Mot X .

donc :

$$\Omega = \bigcup_{i=1}^M w_i \quad (\text{III-4})$$

Notons  $m_i$  : le cardinal de la classe  $w_i$  et  $x_p^{(i)}$ , le centre ou le prototype de cette même classe . Le k<sup>lème</sup> plus proche voisin de x est noté  $x_{(k)}^{(i)}$  avec la relation :

$$\delta(x, x_{(1)}^{(i)}) \leq \delta(x, x_{(2)}^{(i)}) \leq \dots \leq \delta(x, x_{(k)}^{(i)}) \leq \dots \leq \delta(x, x_{(N)}^{(i)}) \quad (\text{III-5})$$

La qualité de mesure  $\sigma$  est donnée par le rapport de la moyenne des distances inter-classes sur la moyenne des distances intra-classes, Soit :

$$\sigma = \frac{\frac{1}{M(M-1)} \sum_{i=1}^M \sum_{j=1}^M \delta(x_p^{(i)}, x_p^{(j)})}{\frac{1}{M} \sum_{i=1}^M \frac{1}{m_i(m_i-1)} \sum_{j=1}^{m_i} \sum_{k=1}^{m_i} \delta(x_j^{(i)}, x_k^{(i)})} \quad (\text{III-6})$$

Si pour deux classes,  $\sigma > 2$ , cela signifie que ces deux classes ne se recouvrent pas et sont bien disjointes .

III- 4 / CLASSIFICATION :

4-1 / Choix du type de classification :

Ou que dans notre cas , nous n'avons à priori aucune information sur l'ensemble de nos locutions . Nous devons considérer et adopter la technique d'Apprentissage non supervisée .

Les méthodes utilisées par cette technique doivent être complémentaires pour donner de meilleurs résultats . En effet , dans la méthode des centroïdes , la connaissance au préalable du nombre réel de classes assurera une convergence rapide de l'algorithme . Ce nombre peut être estimé par la méthode du Chainmap et confirmé par la méthode du SNN . Cette dernière ( SNN ) exige , pour donner des résultats rapides , une bonne estimation du nombre de classes .

Ces trois méthodes peuvent être complétées par la méthode ISODATA ( Interactive Self Organizing Data Analysing Technique A) qui est une méthode adaptative servant à isoler les locutions "hors communs " ( the Outliers ) , à fusionner-ou à faire éclater des classes pour améliorer la configuration ( augmenter  $\sigma$  ) .

4-2 / Classification non-supervisée : [7]

4-2-1 / Méthode de groupement en chaîne ("CHAINMAP") : [9]

C'est une méthode d'analyse simple qui lorsqu'elle est représentée graphiquement en deux dimensions, peut donner beaucoup d'informations sur la distribution des différentes locutions du mot .

En première étape , nous désignons arbitrairement une locution  $x_2$  comme début de chaîne , la locution suivante est le voisin le plus proche  $x_{s(1)}$  de  $x_2$  . L'étape suivante est d'ordonner toutes les locutions dans l'ordre suivant :

$$x_2 \quad x_{s(1)} \quad \dots \quad x_{s(N-1)} \quad (III-7)$$

Au  $k^{ème}$  élément de cette chaîne , nous associons la distance  $d_k$

définie par :

$$d_k = \delta(x_{s(k-1)}, x_{s(k)}) \quad (\text{III-8})$$

Le chainmap ou graphe de d'ordonnance est la courbe de la fonction  $d_k = f(k)$ . Les pics très de cette courbe, représentent les limites entre classes qui souvent assez distinctementvisibles. Cette procédure est sensible au choix du point de commencement.

4-2-2 / Méthode du voisin comun le plus proche (SNN) : [9]

La procédure SNN est basée sur le fait que si deux locutions ont au moins  $k_s$  voisins communs les plus proches, alors elles appartiennent à une même classe.

Soit L la liste des voisins les plus proches tq :

$$L = \begin{bmatrix} x_1 & x_{1(1)} & \dots & \dots & x_{1(k)} \\ x_2 & x_{2(1)} & \dots & \dots & x_{2(k)} \\ \vdots & \vdots & & & \vdots \\ x_N & x_{N(1)} & \dots & \dots & x_{N(k)} \end{bmatrix} \quad (\text{III-9})$$

où les N lignes correspondent aux N locutions. La ligne  $L_i$  est la liste ordonnée des locutions qui sont les k voisins les plus proches de  $x_i$ .

Si on a 2 lignes  $L_i$  et  $L_j$  tel que :  $|L_i \cap L_j| > k_s$   $k_s$  est le seuil fixé, c.a.d que  $x_i$  et  $x_j$  partagent au moins  $k_s$  voisins, alors les deux listes sont assignées à une même classe.

Il est bien sûr possible qu'une "locution test" x partage  $k_i > k_s$  voisins avec  $x_i$ , et  $k_j > k_s$  voisins avec :  $k_i + k_j > k$  alors x aux deux classes  $w_i$  et  $w_j$ .

Par ailleurs, cette procédure peut être utilisée pour identifier les recouvrements de classes. En pratique, on définit une limite lmax de classes auxquelles peut appartenir la locution test. Il en est de même pour les valeurs de  $k_s$  et k.

4-2-3 / Méthode des K-moyennes ( the K-Means Itération ) : [9]

Cette méthode est une technique d'itération automatique qui peut trouver n'importe quel nombre spécifié de classes . Les itérations consistent en trois opérations de base :

- classification des locutions ;
- calcul des centres de classes ;
- test de convergence .

En assumant le souhait de trouver M classes  $w_i$  , nous choisissons M locutions  $x_i$  comme centres initiaux  $x_p^{(i)}$  de ces classes ie :

$$x_p^{(i)} = x_i \quad \text{pour } i = 1..M \quad \text{(III-10)}$$

-La classification est basée sur la méthode du voisin le plus proche soit pour k allant de 1 à M :

$$x_j \in w_i \quad \text{ssi} \quad \delta(x_j, x_p^{(i)}) < \delta(x_j, x_p^{(k)}) \quad \text{(III-11)}$$

-Après avoir appliqué ce critère pour toutes les locutions du mot référence , soit  $j = 1..M$  , nous recalculons les nouveaux centres des classes  $w_i$  avec le critère suivant :

$$x_p^{(i)} = x_j^{(i)} \quad \text{ssi} \quad \text{Max}_{k=1..M} \left\{ \delta(x_j^{(i)}, x_k^{(i)}) \right\} \text{ est minimal} \quad \text{(III-12)}$$

c.à.d que la distance de  $x_j$  à l'élément le plus éloigné de la classe  $w_i$  , est la plus faible parmi tous les éléments de  $w_i$  .

-Le test de convergence consiste à voir si les locutions choisies "arbitrairement" au début comme centres de classes, sont les mêmes que celles trouvées à la fin.

Si le test n'est pas vérifié, on refait les itérations précédentes avec les nouveaux centres jusqu'à la stabilité du processus itératif.

Notons que la convergence souhaitée, n'est pas toujours garantie surtout quand le nombre M de classes diffère de la réelle structure de l'ensemble des locutions . Pour donner alors de meilleures perfor-

mances , cette méthode est souvent accompagnée de l'ISODATA .

#### 4-2-4 / Méthode ISODATA : [19]

Cette méthode permet d'isoler les "locutions hors communs " et de déterminer le nombre réel  $M$  de classes et cela en fusionnant des paires de classes ou en faisant éclater certaines classes selon la valeur du rapport  $\sigma$  donnant la qualité de mesure .

La partie principale de l'ISODATA est la procédure des "k-Moyennes" avec ajustement progressif du nombre de classes au fil des itérations .

a / Fusion de classes : Des classes peuvent être fusionnées si l'un des trois critères suivants est vérifié :

--Le nombre présent  $M$  de classes dépasse la valeur seuil  $M_{max}$  : les classes les plus rapprochées seront alors fusionnées ;

--La dimension  $|w_i|$  de la  $i^{ème}$  classe est inférieure à une valeur seuil  $m_{min}$  soit : cette classe sera alors fusionnée avec la classe qui lui est la plus proche ;

--La distance  $\delta(x_p^{(i)}, x_p^{(j)})$  entre les centres de la  $i^{ème}$  et la  $j^{ème}$  classes est inférieure à une distance seuil  $e_{min}$  : ces deux classes seront fusionnées .

Lors d'une itération où il ya plus d'une fusion de classes , le dernier critère doit être constamment révérifié .

#### b / Réduction de classes :

Il ya principalement trois critères pour lesquels une classe peut être réduite ou " éclatée " :

--Le nombre présent  $M$  de classes est inférieur à une valeur  $M_{min}$  ;

--La dimension de la  $i^{ème}$  classe  $|w_i|$  dépasse une valeur seuil  $m_{max}$  ;

--La  $i^{ème}$  classe est trop dense relativement aux autres classes.

Les deux premiers critères sont similaires respectivement à ceux

-----chap III  
manances ,cette éthode est souvent accompagnée de l'ISODATA .

#### 4-2-4 / Méthode ISODATA : (9)

Cette méthode permet d'isoler les "locutions hors communs" et de déterminer le nombre réel M de classes et cela en fusionnant des paires de classes ou en faisant éclater certaines classes selon la valeur du rapport  $\rho$  donnant la qualité de mesure .

La partie principale de l'ISODATA est la procédure des "k-Moyennes" avec ajustement progressif du nombre de classes au fil des itérations .

a / Fusion de classes : Des classes peuvent être fusionnées si l'un des trois critères suivants est vérifié :

--Le nombre présent M de classes dépasse la valeur seuil  $M_{max}$  ; les classes les plus rapprochées seront alors fusionnées ;

--La dimension  $|w_i|$  de  $i^{ème}$  classe est inférieure à une valeur seuil  $m_{min}$  soit : cette classe sera alors fusionnée avec la classe qui lui est la plus proche ;

--La distance  $\delta(x_p^{(i)}, x_p^{(j)})$  entre les centres de la  $i^{ème}$  et la  $j^{ème}$  classes est inférieure à une distance seuil  $\theta_{min}$  : ces deux classes seront fusionnées .

Lors d'une itération où il ya plus d'une fusion de classes , le dernier critère doit être constamment revérifié .

#### b / Réduction de classes :

Il ya principalement trois critères pour lesquels une classe peut être réduite ou " éclatée " :

--Le nombre présent M de classes est inférieur à une valeur  $M_{min}$  ;

--La dimension de la  $i^{ème}$  classe  $|w_i|$  dépasse une valeur seuil  $m_{max}$  ;

--La  $i^{ème}$  classe est trop dense relativement aux autres classes.

Les deux premiers critères sont similaires respectivement à ceux

de la fusion. Le troisième qui est plus compliqué, fait intervenir certaines procédures:

Nous calculons les distances interclasses  $D_i$  :

$$D_i = \frac{1}{m_i - 1} \sum_{x \in w_i} \delta(x, x_p^{(i)}) \quad , \quad i = 1 \dots M \quad \text{(III-13)}$$

et nous faisons leur moyenne  $\bar{D}$  donnée par :

$$\bar{D} = \frac{1}{M} \sum_{i=1}^M m_i D_i \quad , \quad m_i = \dim(w_i) \quad \text{(III-14)}$$

Pour un seuil de réduction  $\theta_s$ ,  $w_i$  sera réduite ou décomposée :

$$D_i > \text{Max} \left\{ \bar{D}, \theta_s \right\}$$

Quand  $w_i$  est réduite, elle est divisée en deux nouvelles classes  $w_i^+$  et  $w_i^-$  telles que :

$$w_i = w_i^+ \cup w_i^-$$

Cette procédure s'est révélée peu commode pour la décomposition car nous ne connaissons que les distances entre locutions. A l'opposé, nous disposons de deux méthodes simples et plus rapides :  
 --La plus simple consiste à choisir deux locutions  $x^+$  et  $x^-$  dans  $w_i$  tels que la distance  $\delta(x^+, x^-)$  maximum. Puis, nous assignons aux classes  $w_i^+$  et  $w_i^-$  les locutions de la classe  $w_i$  selon que leurs distances à  $x^+$  et  $x^-$  sont plus petites mais ces deux derniers ne sont pas les vrais centroïdes des deux nouvelles classes.

--La seconde méthode donne une plus meilleure estimation des centres de classes. Comme précédemment, nous localisons  $x^+$  et  $x^-$  puis nous posons :

$$\begin{cases} r^+ = \delta(x^+, x_p^{(i)}) \\ r^- = \delta(x^-, x_p^{(i)}) \end{cases}$$

puis nous cherchons  $x_p^+$  et  $x_p^-$  de façon à minimiser :

$$\begin{cases} \varepsilon^+ = \delta(x^+, x_p^+) + \delta(x_p^+, x_p^{(i)}) - r^+ \\ \varepsilon^- = \delta(x^-, x_p^-) + \delta(x_p^-, x_p^{(i)}) - r^- \end{cases}$$

comme dans la première méthode, les éléments de  $w_i$  sont assignés aux classes  $w_p^+$  et  $w_p^-$  selon leur proximité de  $x_p^+$  et  $w_p^+$ , ces

deux derniers sont alors les vrais centroïdes des classes  $w_p^+$  et  $w_p^-$ .

### III-5 / CONCLUSION :

Les centres de nos classes sont calculés selon l'équation (III-12) et leurs délimitations sont faites selon la relation (III-11) ; ces deux étapes sont incluses dans la méthode des K-Moyennes. Leurs fusions et/ou réductions sont obtenues selon les critères précédemment cités.

Nous n'utiliserons pas la méthode des SNN car elle exige un nombre très grand de locutions, de l'ordre de 100, notre temps-machine ne nous permet pas cette possibilité.

A la fin, nous faisons nos tests de convergence selon la méthode des K-Moyennes, l'arrêt est quand la configuration présente de nos locutions a un rapport de qualité de mesure  $\sigma$  supérieur au seuil  $\sigma_{\text{seuil}}$  que nous définissons.

DEB  
NOIS  
SHAPIN

#### IV-1 / INTRODUCTION :

La décision est la dernière étape dans la reconnaissance de la parole .Elle consiste à prendre la décision sur le mot test en exploitant les résultats des distances globales ,issus de l'étape de comparaison dynamique où ces distances sont classées selon un ordre croissant .

Toutefois , l'ordre établi des distances globales peut ne pas être conforme à la disposition exacte c-à-d que le mot qui ,devrait être choisi pour la décision ,ne se trouve pas à la première position et ceci pour des raisons telles qu'une mauvaise extraction des mots , ou une ressemblance phonétique entre les mots du dictionnaire etc.

#### IV-2 / TECHNIQUE DES KNN (K-Nearest Neighbors ) :

Cette technique est utilisée pour remédier au problème cité ci-dessus en utilisant seulement les "K" premières références de chaque mot du dictionnaire pour établir leur classement et non plus un classement référence par référence .

Bien sûr cette technique est très coûteuse en temps de calcul et d'espace mémoire , c'est pourquoi nous devons veiller à optimiser ces deux contraintes surtout qu'en mode multilocuteur ,chaque mot référence est représenté par plusieurs locutions appelées prototypes et issues de la phase d'apprentissage .

Dans nos tests , nous avons opté pour la forme généralisée utilisée par Mrs Pan ,Song et Rabiner [10] .

#### IV-3 / REJETS :

Certains mots peuvent être "rejetés" par le système ie que ce dernier ne répond pas à l'ordre recherché lorsque la plus petite distance est plus grande qu'une distance seuil que nous lui fixons

d'avance . Cette procédure est donc utile et nécessaire puisqu'elle nous permet d'écartier une éventuelle détection de bruit ou mauvaise prononciation d'un mot étranger au dictionnaire .

IV-4 / ALGORITHME : [10]

Nous supposons que , dans le dictionnaire de références , nous disposons de J mots notés  $X_j$  ,  $j=1...J$  avec pour chacun d'eux Q locutions références ou prototypes , soit au total (Q x J) locutions .

Pour chaque mot  $X_j$  , nous faisons un ordonnancement croissant des distances globales issues de l'étape de DTW avec le mot test , soit :

$$D_{j(1)} \leq D_{j(2)} \leq \dots \leq D_{j(K)} \leq \dots \leq D_{j(Q)} \quad (IV-1)$$

Puis nous prenons la moyenne des K premières distances pour chaque mot ie ses K-voisins les plus proches . :

$$r_j = \frac{1}{K} \sum_{q=1}^K D_{j(q)} \quad , \quad j=1...J \text{ et } K \leq Q \quad (IV-2)$$

La décision finale sur la reconnaissance du mot test repose sur la recherche du mot  $X_j$  qui donne la plus faible valeur de r :

$$X_{\text{test}} = X_j \quad \text{ssi} \quad r_j = \text{Min}_j (r_j) \quad (IV-3)$$

N.B : Nos tests en mode multilocuteurs devraient nous renseigner sur le choix de la valeur de K pour un nombre J de prototypes donnés .

**AMUNITION DES VOLETTES**  
**CHIFFRE**  
**V**

V-1/ INTRODUCTION :

Le conduit vocal favorise certaines zones fréquentielles où l'on obtient des résonances . Ces zones sont les FORMANTS , et se caractérisent par un maximum de la fonction de transfert du conduit vocal . La richesse du signal vocal en formants d'intensités relatives détermine le timbre de la voix . En général , les trois premiers formants sont essentiels pour caractériser le spectre du signal parole . Dans le cas de nos voyelles , les deux premiers formants , que nous noterons F1 ET F2 , sont suffisants et peuvent déterminer à eux seuls le timbre de la voix . Notons que les positions des fréquences de ces formants peuvent varier pour un même son chez un même locuteur et encore plus quand on passe d'un locuteur à un autre .

Par ailleurs, le premier harmonique du spectre vocal , dit PITCH, ne présente pour nous aucun intérêt particulier puisque nous nous éloignons de la reconnaissance des locuteurs . Il est donc suffisant de représenter nos voyelles par les formants F1 et F2 .

V-2/ METHODES DE SIMULATIONS :

Les sons voisés tels que les voyelles orales, que nous étudions, sont dûs à une excitation pseudo-périodiques où les cordes vocales vibrent sous l'action de la pression du flux d'air envoyé par les poumons

Pour simuler nos voyelles , nous proposons deux méthodes où nous nous basons sur les valeurs moyennes de F1 et F2 [11] suivantes :

Voyelles	F1(Hz)	F2(Hz)
A	750	1350
E	400	2200
I	250	2500
O	375	750
U	250	600
Y	050	1800

### 2 / 1) Méthode 1 :

Cette méthode est basée sur une somme de sinusoides de fréquences  $F1-B1/2$ ,  $F1$ ,  $F1+B1/2$ ,  $F2-B2/2$ ,  $F2$ ,  $F2+B2/2$  où  $B1$  et  $B2$  sont respectivement les bandes à 3dB des formants  $F1$  et  $F2$  que nous prenons respectivement égales, ici, à 80 Hz et 90 Hz.

L'équation de génération de nos échantillons s'écrit :

$$\begin{aligned}
 S(k) = & A1 \sin 2\pi k \left( \frac{F1}{Fe} \right) + A2 \sin 2\pi k \left( \frac{F2}{Fe} \right) + \\
 & + \frac{A1}{\sqrt{2}} \left[ \sin 2\pi k \left( \frac{F1-40}{Fe} \right) + \sin 2\pi k \left( \frac{F1+40}{Fe} \right) \right] + \\
 & + \frac{A2}{\sqrt{2}} \left[ \sin 2\pi k \left( \frac{F2-45}{Fe} \right) + \sin 2\pi k \left( \frac{F2+45}{Fe} \right) \right]. \quad (V-1)
 \end{aligned}$$

avec :

$S(k)$  :  $k^{\text{ème}}$  échantillon de la locution considérée ( $1 \leq k \leq \text{Nech}$ );

$A1$  : amplitude du premier formant ;

$A2$  : amplitude du second formant ;

$Fe$  : fréquence d'échantillonnage ( $Fe = 12.8 \text{ KHz}$ );

$\text{Nech}$  : nombre total d'échantillons par locution.

Les limites de cette méthode se situent dans le fait que les échantillons générés sont des signaux déterministes alors que la parole réelle est un signal aléatoire et quasi-stationnaires sur de courtes durées.

Nous ne retiendrons pas alors cette méthode parce que le

Le spectre des signaux que nous obtenons est très différent de celui de la parole réelle et dès que nous faisons des variations en formants ou en durée temporelle, le signal devient altéré et totalement différent de celui duquel il dérive et que nous cherchons à reconnaître.

Tous nos tests seront alors faits avec la méthode de génération suivante.

2 / 2) Méthode 2 : [3]

Elle est basée sur le modèle autorégressif du signal de la parole. Pour les voyelles non nasales, ce modèle ne présente que des pôles. L'excitation  $U(Z)$  de ce système est une suite périodique d'impulsions de période  $P$  égale à la période du pitch.

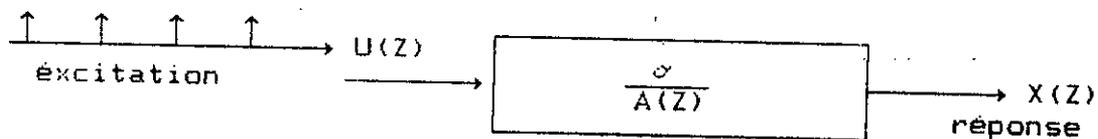


fig-V-1) Modèle autorégressif.

La fonction de transfert de ce modèle est :  $\frac{X(Z)}{U(Z)} = \frac{\sigma}{A(Z)}$

avec :  $A(Z) = \sum_{i=0}^P a(i) Z^{-i}$  et  $a(0) = 1$

d'où :  $\sigma U(Z) = X(Z) A(Z) = \sum_{i=0}^P a(i) X(Z) Z^{-i}$

soient  $u(n)$  et  $x(n)$  les transformées en Z inverses respectives de  $U(Z)$  et  $X(Z)$  tq :

$$u(n) = \sum_{k=1}^p \delta(n-k F)$$

par suite :

$$\sigma u(n) = \sum_{i=0}^p a(i) x(n-i) = x(n) + \sum_{i=1}^p a(i) x(n-i)$$

nous arrivons alors à :

$$x(n) = \sigma u(n) - \sum_{i=1}^p a(i) x(n-i) \quad (V-2)$$

Donc chaque échantillon peut être évalué par la différence de l'excitation et des p échantillons qui le précèdent. Les seules inconnues dans cette équation sont le gain  $\sigma$  et les pôles  $a(i)$  du modèle.

La fonction de transfert  $G(Z)$  du conduit vocal pour un modèle tous-pôles est donnée par :

$$G(Z) = \prod_{k=1}^k \frac{A_k}{(1 + b_{k,1} Z^{-1} + b_{k,2} Z^{-2})} \quad (V-3)$$

où  $k$  est le nombre de cellules de résonances du conduit vocal.

Nous prenons une seule cellule de résonance pour chaque formant soit :

$$g_k(Z) = \frac{A_k}{1 + b_{k,1} Z^{-1} + b_{k,2} Z^{-2}}$$

avec :

$$b_{k,2} = 1 - 2\pi \frac{B}{F_k}$$

$$b_{k,1} = -2 b_{k,2} \cos(2\pi F_k / F_e)$$

$$A_k = 1 + b_{k,1} + b_{k,2}$$

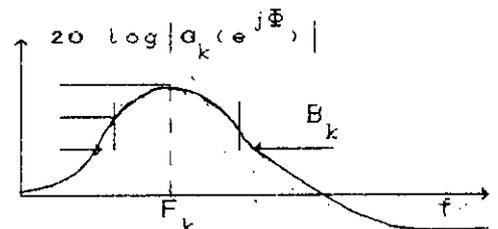


fig V-2) Module de  $g_k(Z)$

- $F_k$  : fréquence du  $k^{\text{ème}}$  formant ;  
 $B_k$  : bande de fréquence à 3 dB du  $k^{\text{ème}}$  formant ;  
 $A_k$  : amplitude (gain du modèle) du  $k^{\text{ème}}$  formant ;  
 $F_e$  : fréquence d'échantillonnage ;  
 $b_{k,1}$  et  $b_{k,2}$  : pôles de  $G(Z)$  .

Remarquons que dans cette méthode , c'est le modèle qui fixe l'amplitude des formants selon leurs fréquences et leurs bandes .

Puisque les deux premiers formants  $F_1$  et  $F_2$  suffisent pour caractériser nos voyelles , nous n'aurons besoin que de deux cellules de résonance pour la simulation , chacune pour un formant , soit :

$$\begin{aligned}
 G(Z) &= g_1(Z) + g_2(Z) && (V-4) \\
 &= \frac{A_1 A_2}{(1+b_{1,1} Z^{-1}+b_{1,2} Z^{-2})(1+b_{2,1} Z^{-1}+b_{2,2} Z^{-2})}
 \end{aligned}$$

$b_{1,1}$  ,  $b_{1,2}$  ,  $b_{2,1}$  et  $b_{2,2}$  ainsi que  $A_1$  et  $A_2$  sont donnés par les formules précédentes .

Par identification au modèle autorégressif , nous obtenons :

$$\sigma = A_1 A_2 ;$$

$$\begin{aligned}
 A(Z) &= (1 + b_{1,1} Z^{-1} + b_{1,2} Z^{-2}) (1 + b_{2,1} Z^{-1} + b_{2,2} Z^{-2}) \\
 &= 1 + (b_{1,1} + b_{2,1}) Z^{-1} + (b_{1,2} + b_{2,2} + b_{1,1} b_{2,1}) Z^{-2} + \\
 &\quad + (b_{1,1} b_{2,2} + b_{1,2} b_{2,1}) Z^{-3} + b_{1,2} b_{2,2} Z^{-4}
 \end{aligned}$$

Il en résulte que notre modèle est du quatrième ordre tq:

$$a(0) = 1 ;$$

$$a(1) = b_{1,1} + b_{2,1} ;$$

$$a(2) = b_{1,2} + b_{2,2} + b_{1,1} b_{2,1} ;$$

$$a(3) = b_{1,1} b_{2,2} + b_{1,2} b_{2,1} ;$$

$$a(4) = b_{1,2} b_{2,2} .$$

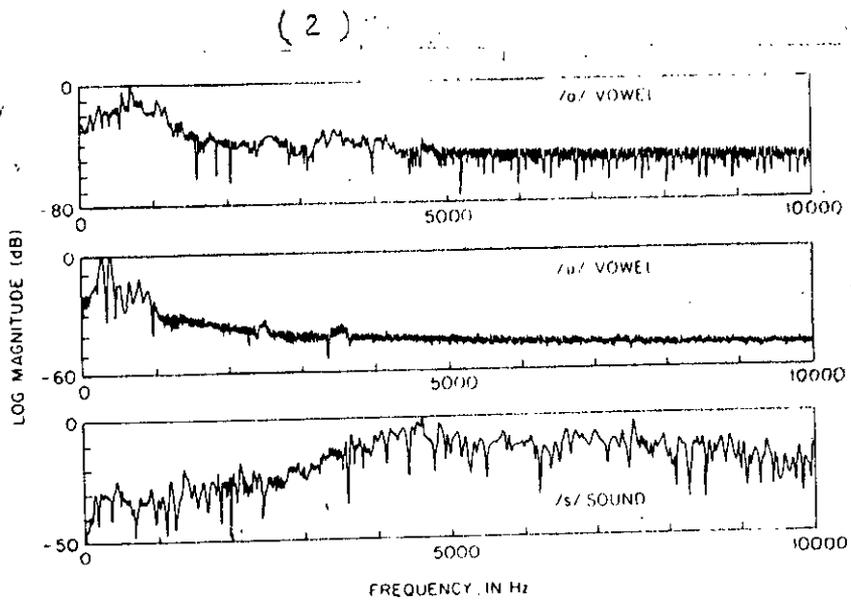
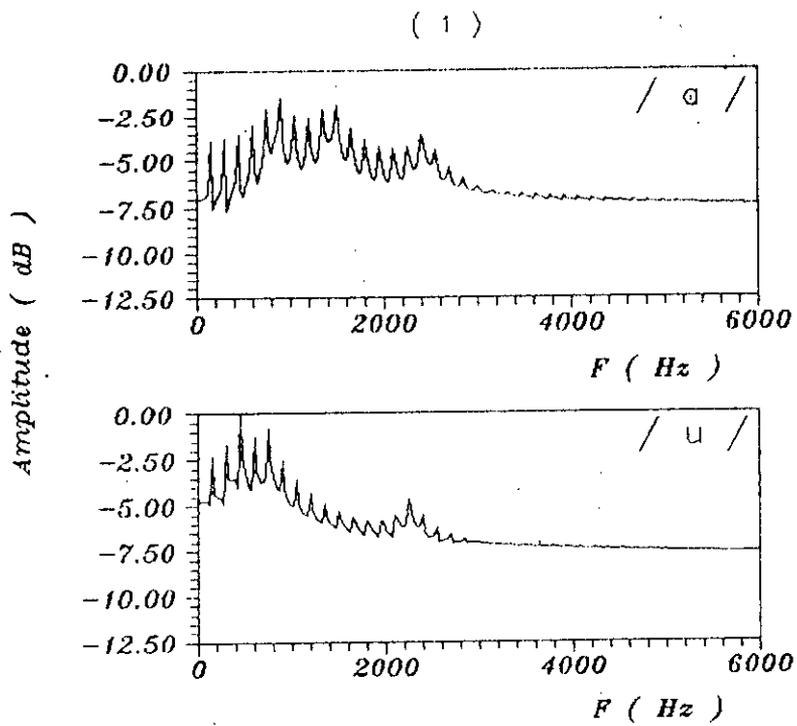
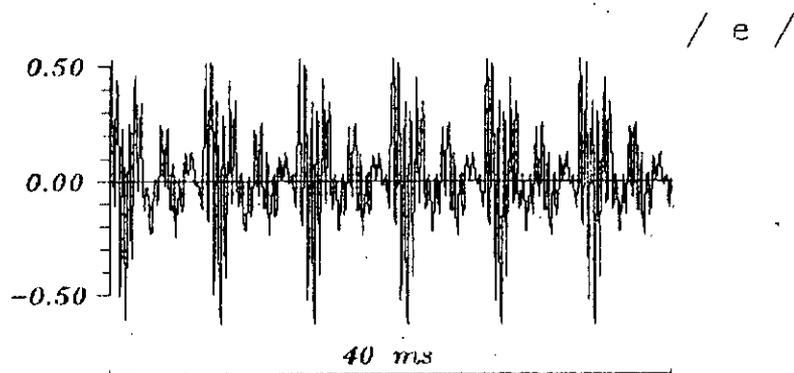
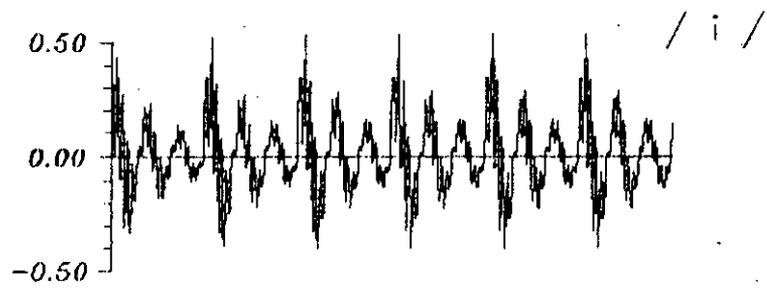
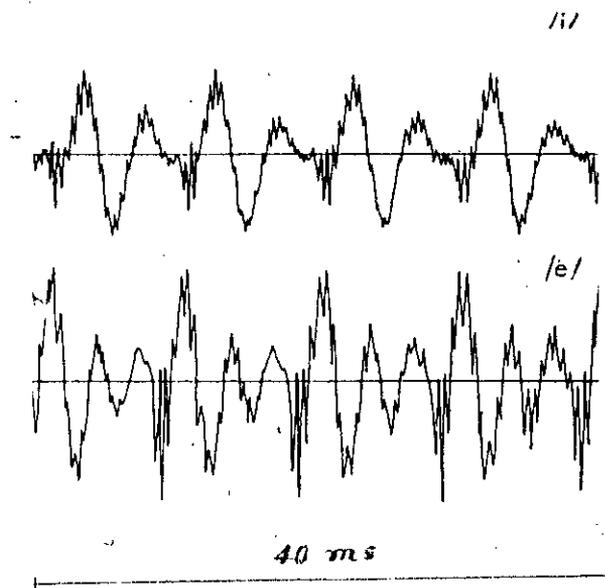


Fig V-3: Formes du spectre des voyelles (a,u)  
 ( 1 ) : generees par le modele AR  
 ( 2 ) : de la parole reelle [12]



( 1 )



( 2 )

Fig V-4: Formes d'onde acoustique des voyelles (i,e)  
 ( 1 ) : generees par le modele AR  
 ( 2 ) : de la parole reelle [12]

D'où l'équation de générations de nos échantillons :

$$x(n) = \sigma u(n) - \sum_{i=1}^4 a(i) x(n-i) \quad , \quad 0 \leq n \leq \text{Nech} \quad (\text{V-5})$$

ou encore

$$x(n) = \begin{cases} \sigma & , \quad n = 0 \\ \sigma u(n) - \sum_{i=1}^4 a(i) x(n-i) & , \quad n \leq 4 \\ \sigma u(n) - \sum_{i=1}^4 a(i) x(n-i) & , \quad 4 \leq n \leq \text{Nech} \end{cases}$$

L'excitation  $u(n)$  est donnée par :

$$u(n) = \begin{cases} 1 & \text{si } n \text{ est un multiple de } P ; \\ 0 & \text{sinon .} \end{cases}$$

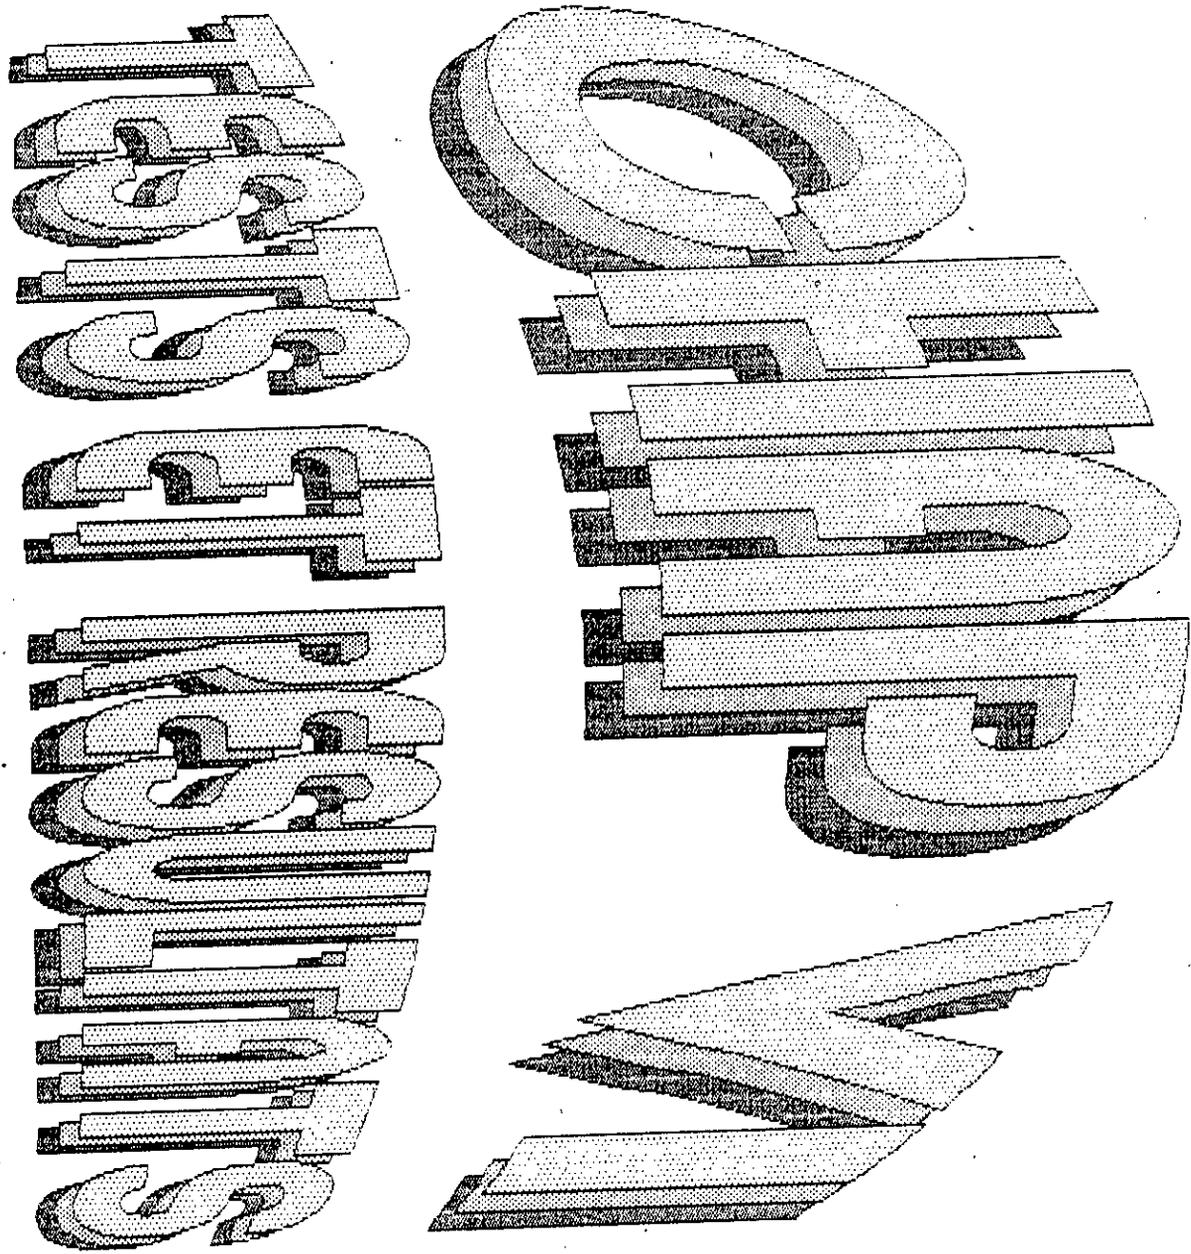
avec :

$$P = \frac{\text{période du pitch}}{\text{période d'échantillonnage}} = \frac{F \text{ échantillonnage } (F_e)}{F \text{ du pitch } (F_0)}$$

### V-3 / CONCLUSION :

La première méthode n'est pas retenue car comme nous l'avons déjà signalé , elle nous éloigne beaucoup trop de la parole réelle .

Tous nos tests seront alors faits avec la seconde méthode de génération qui nous donne des formes d'onde et des spectres de nos voyelles très proches de ceux de la parole réelle [12] conformément aux figures V-3 pour /a/ , /u/ et V-4 pour /e/ , /i/ .



IV-A / TESTS MONOLOCUTEURS :

Ces tests nous permettront de tester l'influence de beaucoup de paramètres pertinents dans nos analyses sur le taux de reconnaissance. Notre but essentiel est de choisir par la combinaison des résultats de ces tests la meilleure méthode d'analyse et l'algorithme le plus performant pour pouvoir entamer la classification avec le plus petit temps de calcul possible.

-----A-1 / Tests sur l'amplitude :

Les systèmes de reconnaissance de la parole doivent être peu sensibles aux variations énergétiques des signaux. En effet, un locuteur peut parler à plus ou moins haute voix sans cependant changer de timbre. C'est pourquoi, il y a nécessité d'une normalisation énergétique du signal de la parole avant la comparaison dynamique des mots. Cette normalisation doit être faite dans la phase d'analyse. Par ce fait, les tests que nous faisons sont destinés à comparer les performances de nos deux méthodes d'analyse (cepstrale et LPC) en sensibilité aux variations d'amplitude.

A-1-a / Données des tests :

--Paramètres de générations :

$F_{pitch} = 150 \text{ Hz}$  ;  $F_{ech} = 12800 \text{ Hz}$  ; durée = 200 ms ;

Nous générons six fichiers par voyelle où nous prenons des rapports 2, 3, 5, 10, 20 fois l'amplitude de référence ; les fréquences des formants sont les valeurs moyennes données dans le chapitre V.

--Paramètres d'analyse :

Préaccentuation éliminée car donnant des pics indésirables sur le spectre de nos voyelles ; la durée des fenêtres temporelles est 20 ms

nombre de coefficients : --cepstraux (8) ;

--prédicteurs (12).

--Paramètres de DTW :

Nombre de fichier dictionnaire par voyelle : 1 ;

Fenêtre d'ajustement : losange (symétrique et assymétrique) ;

Distance locale : distance Euclidienne .

A-1-b / Résultats des tests :

Dans le programme de DTW , nous avons choisi seulement les deux algorithmes SAKOE et CHIBA : pente  $p = 1$  , sur ses deux formes où nous calculons le taux de reconnaissance et la distance moyenne pour les voyelles reconnues pour nos deux méthodes d'analyse :LPC et cepstrale ( CPS ) .

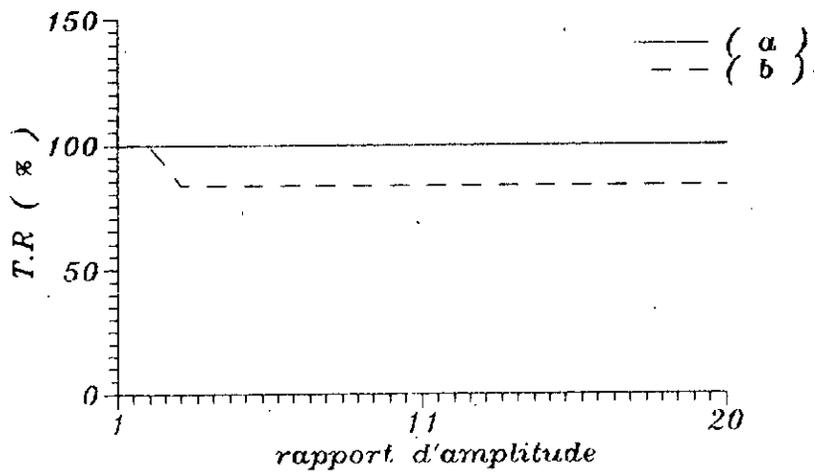
Ce choix est bien justifié car les tests portent sur les méthodes d'analyse que nous avons faites et non sur les algorithmes et les pentes .

Dans le tableau des résultats suivant ,  $\rho$  est le rapport d'amplitude

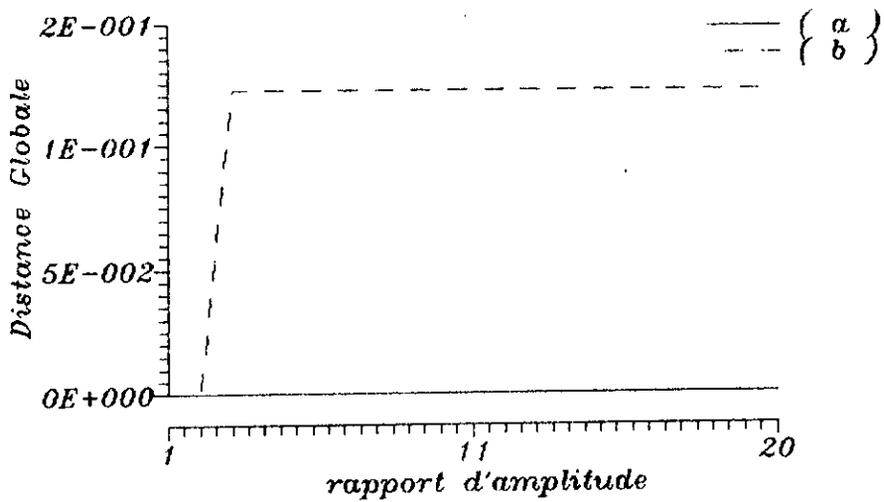
Rapport $\rho$	Algorithme de SAKOE et CHIBA ( $p = 1$ )			
	Forme symétrique		Forme assymétrique	
	CPS	LPC	CPS	LPC
2	100% $9.85346 \cdot 10^{-7}$	100% 0.0000	100% $9.85346 \cdot 10^{-7}$	100% 0.0000
3	100% $2.8054 \cdot 10^{-5}$	83.33% $1.226657 \cdot 10^{-1}$	100% $2.80540 \cdot 10^{-5}$	83.33% $1.22665 \cdot 10^{-1}$
5	100% $9.2976 \cdot 10^{-5}$	83.33% $1.229812 \cdot 10^{-1}$	100% $9.29760 \cdot 10^{-5}$	83.33% $1.52776 \cdot 10^{-1}$
10	100% $9.9244 \cdot 10^{-5}$	83.33% $1.229810 \cdot 10^{-1}$	100% $9.92440 \cdot 10^{-5}$	83.33% $1.52776 \cdot 10^{-1}$
20	100% $9.9590 \cdot 10^{-5}$	83.33% $1.229816 \cdot 10^{-1}$	100% $9.9590 \cdot 10^{-5}$	83.33% $1.52776 \cdot 10^{-1}$

A-1-c / Interprétations :

Sur le tableau ci-dessus ou les courbes fig VI-1-1 et -2 , nous remarquons que l'analyse cepstrale (CPS) est insensible aux variations d'amplitude puisque gardant un taux de reconnaissance de 100% même pour  $\rho = 20$  , de plus la distance globale moyenne se



( 1 ) : Effets sur le taux de reconnaissance



( 2 ) : Effets sur la distance globale

Fig VI-7 : Resultats des tests sur l'amplitude  
 ( a ) : Analyse Cepstrale  
 ( b ) : Analyse LPC

nombre de coefficients :--ceptraux (8) ;  
spectre de nos voyelles ; la durée des fenêtres temporelles est 20 ms  
Préaccentuation éliminée car donnant des pics indésirables sur le

--Paramètres d'analyse :

sont les valeurs moyennes données dans le chapitre V .  
2.8 fois la durée de référence (100 ms) ; les fréquences des formants  
rapports 0.37 , 0.43 , 0.57 , 0.71 , 0.86 , 1.2 , 1.6 , 2 , 2.4 , 2.5 et  
Nous générons 12 fichiers par voyelle ou nous prenons des

Fpitch = 150 Hz ; Fecch = 12800 Hz ;

--Paramètres de générations :

A-2-a / Données des tests :

ce pour nos deux méthodes d'analyse .  
comparaison dynamique que nous avons définis dans le chapitre III et  
Les tests que nous faisons , portent sur tous les algorithmes de

entre deux mots ont pour but de réaliser cette condition .  
rythme . Les algorithmes de normalisation temporelle de la distance  
même locuteur ne prononce pas toujours un mot donné avec le même  
petites distorsions des axes temporels . En effet nous savons qu'un  
La distance entre deux locutions doit être peu sensible aux

-----A-2 / Tests sur la durée :

normalisation en énergie à l'opposé de la première (LFC) .  
conforme à la théorie puisque cette dernière (CFS) réalise une  
variations énergétique que l'analyse cepstrale . Ce résultat est  
Nous avons pu vérifier que l'analyse LFC est plus sensible aux

A-1-d / Conclusion :

globale moyenne varie entre  $1.2 \cdot 10^{-1}$  et  $1.5 \cdot 10^{-1}$  .  
de reconnaissance diminue et se stabilise à 83.33% , la distance  
Quant à l'analyse LFC , dès que le rapport  $\rho$  dépasse 2 , le taux

stabilise autour de  $3.3 \cdot 10^{-5}$  .

-----chap VI

--prédicteurs (12).

--Paramètres de DTW :

Nombre de fichier dictionnaire par voyelle : 1 ;

Fenêtre d'ajustement : losange ;

Distance locale : distance Euclidienne .

A-2-b / Résultats des tests :

Dans les programmes de DTW , nous calculons le taux de reconnaissance et la distance globale moyenne pour les voyelles reconnues pour nos deux méthodes d'analyse :LPC et cepstrale ( CPS ) .

Nous ne donnons pas les tableaux des résultats obtenus car ils sont très grands et très denses , nous préférons les remplacer par les courbes ci-après qui sont d'ailleurs plus explicites .

Le rapport de durée est noté :  $\alpha$

A-2-c / Interprétations :

Algorithme SAKOE et CHIBA :

--Courbe (VI-2-9) :  $p = 0$  (LPC ,CPS) pour les 2 formes :

Le taux de reconnaissance atteint 100% pour  $\alpha = 0.57$  et reste constant jusqu'à  $\alpha = 2$  au delà duquel il diminue pour s'annuler à 2.4 pour cette courbe les deux méthodes donnent donc les mêmes résultats.

--Courbes :  $p = 1/2$  ,CPS ( VI-2-3 les 2 formes ),

LPC (VI-2-3 f-sym- et -2-4 f-assym-) :

Pour la méthode CPS ,le taux de reconnaissance atteint 100% pour  $\alpha = 0.57$  et reste constant jusqu'à  $\alpha = 2.4$  au delà duquel il diminue pour s'annuler à 2.9 pour les deux formes de la fenêtre d'ajustement. Quant à la méthode LPC ,la forme assymétrique donne de meilleurs résultats mais le rapport de durée reste compris dans le même intervalle que pour la méthode CPS qui est encore la plus performante .

--Courbes :  $p = 1$  ,CPS (VI-2-5 f-sym et -2-6 f-assym )

LPC (VI-2-7 f-assym et -2-8 f-sym )

Pour la méthode CPS ,le taux de reconnaissance atteint 100% pour

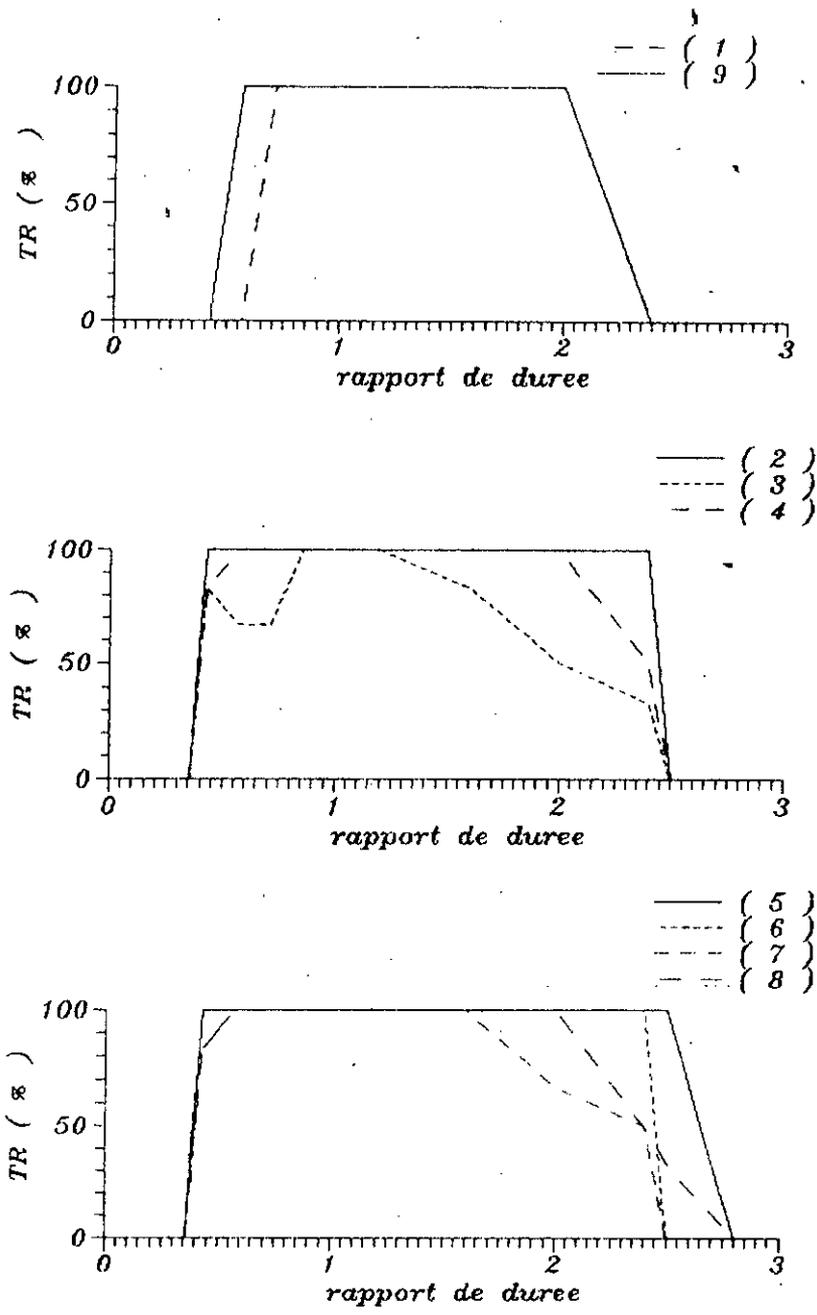


Fig VI-2: Resultats des tests sur la duree pour les algorithmes de SAKOE et CHIBA pente=(0,1/2,1,2), les deux formes pour les deux methodes d'analyse

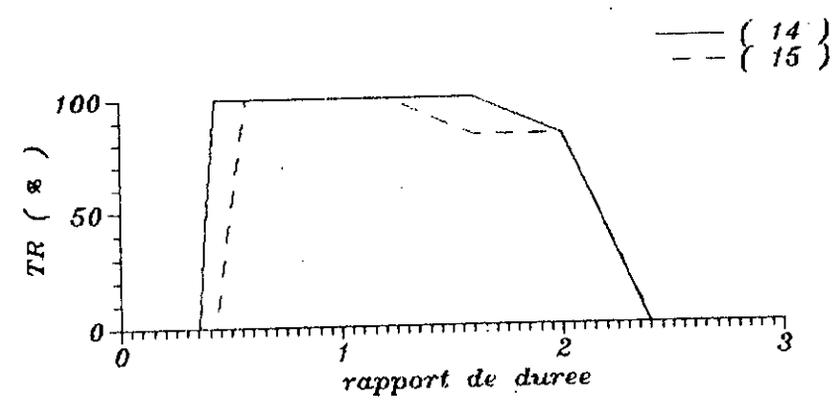
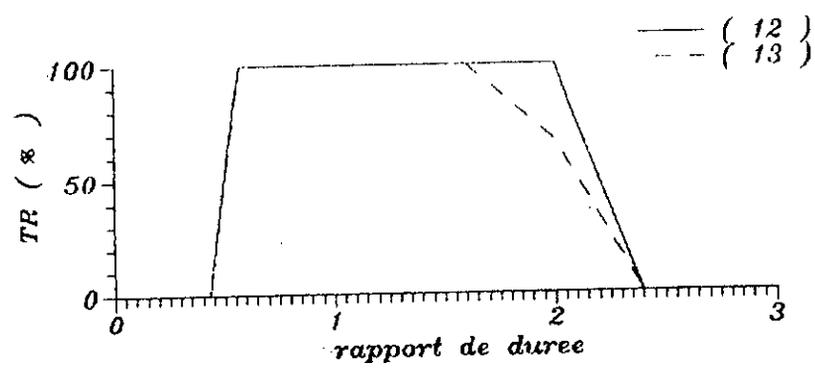
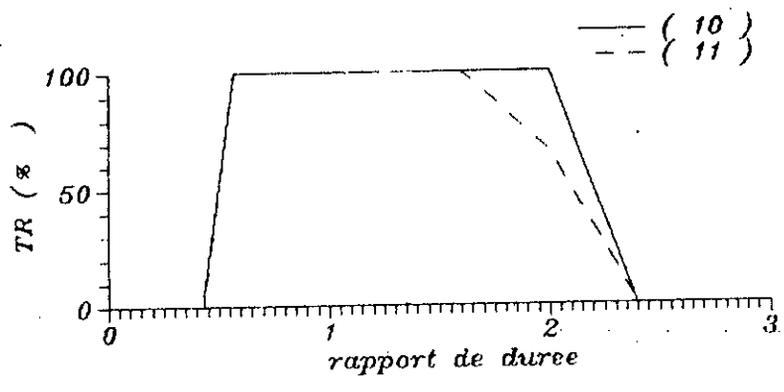


Fig VI-3: Resultats des tests sur la durée pour les algorithmes de :  
 ITAKURA, WHITE et NEELY  
 VELICHKO et ZAGORUYKO

-----chap VI  
 $\alpha = 0.43$  et reste constant jusqu'à  $\alpha = 2.4$  pour la forme  
assymétrique (nul à 2.5) et jusqu'à  $\alpha = 2.5$  pour la forme symétrique  
(nul à 2.8). Quant à la méthode LPC, la forme symétrique donne de  
meilleurs taux de reconnaissance sur un meilleur intervalle temporel  
( $\alpha = 0.43$  jusqu'à 2.8).

--Courbe (VI-2-1) :  $p = 2$  (LPC, CPS) pour les 2 formes :

Pour les deux méthodes et les deux formes, le taux de reconnai-  
ssance atteint 100% de  $\alpha = 0.7$  jusqu'à 2 et s'annule à 2.4.

Algorithme d'ITAKURA : Courbes (VI-3-10 et -11)

La méthode CPS donne de meilleures reconnaissances et sur un  
meilleur intervalle de temps (de 0.43 à 2.4), par contre la méthode  
LPC, le taux diminue et atteint parfois 66.66%. L'intervalle tempo-  
rel reste le même.

Algorithme de WHITE et NEELY : Courbes (VI-3-12 et -13)

Les deux méthodes donnent des reconnaissances sur un même inter-  
valle de temps (de 0.43 à 2.4) mais la méthode CPS est plus perfor-  
mante.

Algorithme de VELICHKO et ZAGORUYKO : Courbe (VI-3-14 et -15)

La méthode CPS est plus performante mais l'intervalle de temps  
est le même (de 0.32 à 2.4).

N.B : Le calcul des distances globales moyennes nous a servis ici à  
rejeter certaines valeurs incohérentes.

A-2-d / Conclusions :

Notre but étant d'obtenir une normalisation temporelle soit des  
taux de reconnaissance dans le plus grand intervalle de temps possi-  
ble, c'est pourquoi nous concluons que l'algorithme le plus perfo-  
rmant parmi ceux que nous'avons adoptés est celui de SAKOE et CHIBA  
obtenu pour une pente  $p = 1$  avec la forme symétrique et cela pour nos  
deux méthodes d'analyse.

Cette conclusion est obtenue après comparaison de nos courbes pour  
les différents algorithmes, pentes, et formes.

-----A-3 / Tests sur les formants .:

Nous savons que le spectre du signal de la parole n'a pas de forme fixe puisque le signal lui-même est aléatoire . Ce spectre varie d'une personne à une personne et aussi chez une même personne selon son état . Aussi, nous faisons des tests sur les fréquences des formants pour mesurer la sensibilité du système de reconnaissance de la parole à ces variations mais en mode monolocuteur ie chez une même personne .

Les résultats de nos tests nous permettront d'opter pour une méthode d'analyse et un algorithme de DTW .

A-3-a / Données des tests :

--Paramètres de générations :

Fpitch = 150 Hz ; Fecb = 12800 Hz ;

Nous générons cinq fichiers par voyelle où nous prenons les fréquences des formants , données dans le tableau suivant :

Voyelle et formants		Fichiers				
		XP1	XP2	XP3	XP4	XP5
A	F1	720	740	750	760	770
	F2	1280	1900	1950	1400	1420
E	F1	970	990	400	410	490
	F2	2120	2190	2200	2210	2280
I	F1	290	240	250	260	270
	F2	2450	2470	2500	2590	2550
O	F1	955	965	975	985	995
	F2	720	790	750	770	780
U	F1	290	240	250	260	270
	F2	570	580	600	620	690
Y	F1	290	240	250	260	270
	F2	1750	1770	1800	1890	1850

Notons que XP1....XP5 sont des fichiers générés avec les formants correspondants pour les six voyelles considérées .

--Paramètres d'analyse :

Préaccentuation éliminée car donnant des pics indésirables sur le spectre de nos voyelles ; la durée des fenêtres temporelles est 20 ms sans recouvrement ;

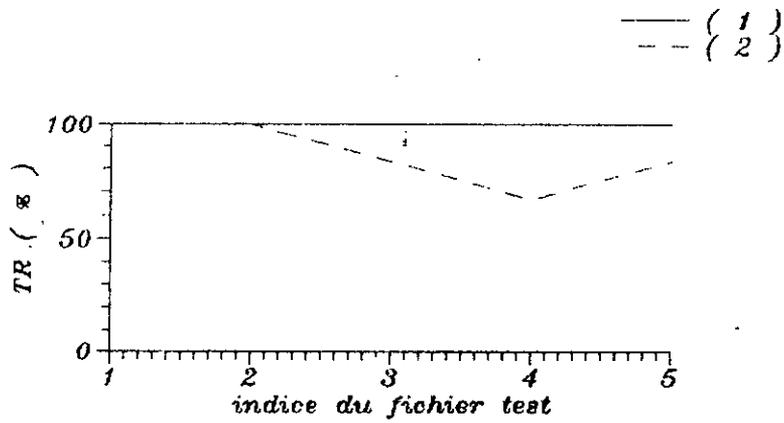


Fig VI-4: Resultats des tests sur les formants pour les algorithmes SAKOE et CHIBA analyse Cepstrale

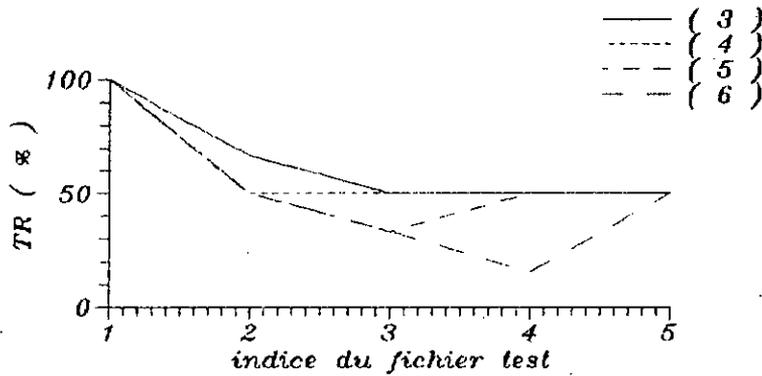


Fig VI-5: Resultats des test sur les formants pour les algorithmes SAKOE et CHIBA analyse LPC

nombre de coefficients :--cepstraux (8) ;

--prédicteurs (12).

--Paramètres de DTW :

Nombre de fichier dictionnaire par voyelle : 1 ;

Fenêtre d'ajustement : losange ;

Distance locale : distance Euclidienne .

#### A-3-b / Résultats des tests :

Dans les programmes de DTW , nous calculons le taux de reconnaissance et la distance globale moyenne pour les voyelles reconnues pour nos deux méthodes d'analyse :LPC et cepstrale (CPS) .

Nous ne donnons pas les tableaux des résultats obtenus car ils sont très grands et très denses , nous préférons les remplacer aussi par les courbes ci-après qui sont plus explicites .

#### A-3-c / Interprétations :

Algorithme SAKOE et CHIRA :

--Courbes VI-4: -1, -2, et VI-5: -3, -4, -5, -6 ) :

- Méthode CFS

Le taux de reconnaissance est de 100% pour les cinq fichiers sauf pour la pente  $p = 1/2$  forme assymétrique qui donne des taux de 83.33% et 66.67% .

- Méthode LPC

Le taux de reconnaissance ne dépasse pas 66.67% et atteint même 15.33% pour la pente  $p = 1/2$  forme assymétrique ; pour les autres pentes , ce taux est souvent de 50% pour les deux formes .

Les autres algorithmes :

--Courbes VI-6: -7 ITAK, -8 WeiN, -9 VelZ ) : Méthode CPS

Le taux de reconnaissance est de 100% pour l'algorithme d'ITAKURA pour les cinq fichiers mais pour les algorithmes de WHITE et NEELY et de VELICHKO et ZAGORUYKO ce taux atteint parfois 83.33% .

--Courbe (VI-7 : -10 ITAK , -11 WeiN , -12VelZ) : Méthode LPC

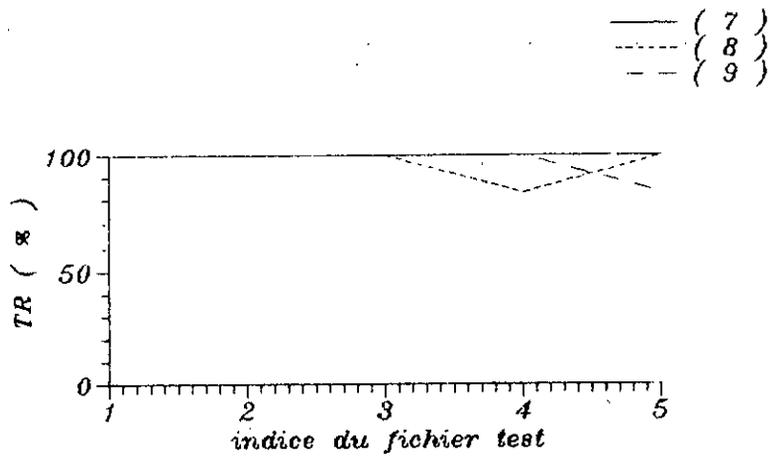


Fig VI-6: Resultats des tests sur les formants pour les algorithmes de ITAKURA, WHITE et NEELY VELICHKO et ZAGORUYKO analyse Cepstrale

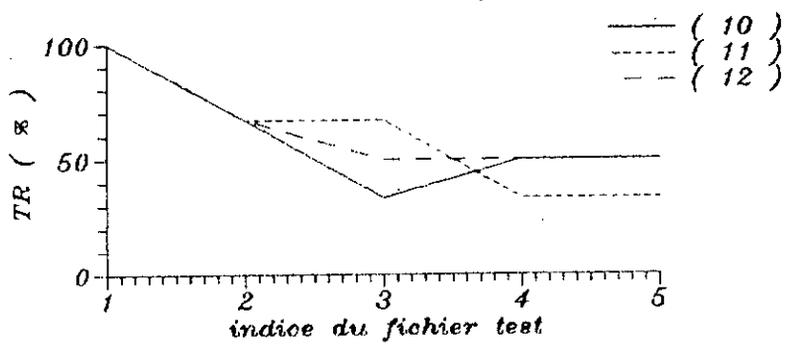


Fig VI-7: Resultats des tests sur les formants pour les algorithmes de ITAKURA, WHITE et NEELY VELICHKO et ZAGORUYKO analyse LPC

Pour cette méthode , l'algorithme de WHITE et NEELY donne des taux de reconnaissance relativement meilleurs sans atteindre toutefois 100% , le plus faible taux est obtenu avec l'algorithme d'ITAKURA (33.33% ) .

#### A-3-d / Conclusions :

D'après nos courbes , tous les algorithmes DTW , sauf celui de SAKOE et CHIBA pour la fore asymétrique et  $p = 1/2$  , donnent de très bons taux de reconnaissance pour la méthode cepstrale et des mauvais taux pour la méthode LPC (autour de 50% ) . Par conséquent nous ne pouvons pas , dans ce test , déceler le plus performant des algorithmes que nous avons utilisés . Par contre , nous constatons tout de même que la méthode LPC est plus sensible aux variations des formants que la méthode cepstrale . Cela est dû réellement à l'utilisation dans cette dernière d'une analyse spectrale et des filtres MEL qui prennent en considération les déplacements fréquentiels qui sont d'ailleurs inférieurs à la largeur des filtres que nous avons pris (150 Hz) . En effet si ces filtres contiennent les déplacements des formants , l'énergie du signal dans la bande de ces filtre est très peu sensible à ces variations

#### -----A-4 / Tests sur le nombre des coefficients :

Il a déjà été démontré [13] que le taux de reconnaissance de la parole dépend étroitement du nombre de paramètres pertinents d'analyse qui renseignent le système de reconnaissance sur la nature des mots . C'est pourquoi , nous faisons des tests pour évaluer , dans notre cas , le nombre optimal de coefficients cepstraux et LPC .

#### A-4-a / Données des tests :

--Paramètres de générations :

Fpitch = 150 Hz ; Fcch = 12800 Hz ; durée = 200 ms ;

Nous générons six fichiers par voyelle où nous prenons les différentes fréquences des formants données dans le test précédent

nous répétons cette opération cinq fois pour la méthode cepstrale en prenant successivement comme nombre  $N_c$  de coefficients : 6 , 8 , 10 , 13 et 18 . Pour la méthode LPC , les six fichiers sont régénérés avec les nombres  $N_p$  de coefficients suivants : 10 , 12 , 15 , 18 et 24 .

--Paramètres d'analyse :

Préaccentuation éliminée car donnant des pics indésirables sur le spectre de nos voyelles ; la durée des fenêtres temporelles est 20 ms

--Paramètres de DTW :

Nombre de fichier dictionnaire par voyelle : 1 pour chaque valeur de  $N_p$  ou  $N_c$ ;

Fenêtre d'ajustement : losange ;

Distance locale : distance Euclidienne .

#### A-4-b / Résultats des tests :

Dans le programme de DTW , nous avons choisi seulement un des algorithmes SAKOE et CHIBA ( pente  $p = 1$  , forme symétrique ) où nous calculons le taux de reconnaissance et la distance globale moyenne pour les voyelles reconnues .

Nos résultats sont regroupés dans les deux tableaux suivants:

Nbre de Coéff. $N_c$	ANALYSE CEPSTRALE			
	Reconnaissance par/ au fichier1 = fichier-référence			
	fichier2	fichier3	fichier4	fichier5
6	100% $2.28979 \cdot 10^{-1}$	100% $9.415416 \cdot 10^{-1}$	33.33% $2.048710$	100% $6.1717706 \cdot 10^{-1}$
8	100% $2.758098 \cdot 10^{-1}$	100% $4.196498 \cdot 10^{-1}$	100% $5.875295 \cdot 10^{-5}$	100% $7.079744 \cdot 10^{-1}$
10	100% $2.966696 \cdot 10^{-1}$	100% $4.4919864 \cdot 10^{-1}$	100% $6.955885 \cdot 10^{-1}$	100% $7.898694 \cdot 10^{-1}$
13	100% $9.701729 \cdot 10^{-1}$	100% $5.9888941 \cdot 10^{-1}$	100% $8.178472 \cdot 10^{-1}$	100% $9.782918 \cdot 10^{-1}$
18	100% $4.606299 \cdot 10^{-1}$	83.33% $7.9022007 \cdot 10^{-1}$	100% $9.650166 \cdot 10^{-1}$	83.33% $1.1859969$

Nbre de Coeff. Np	ANALYSE LFC			
	Reconnaissance par/ au fichier1 $\equiv$ fichier-référence			
	fichier2	fichier3	fichier4	fichier5
10	50% 6.36619 10 <sup>-1</sup>	50% 9.892454 10 <sup>-1</sup>	50% 1.1813231	50% 1.3667058
12	66.66% 6.683981 10 <sup>-1</sup>	50% 1.0463720	50% 1.1406252	50% 1.2411747
15	66.66% 8.905961 10 <sup>-1</sup>	50% 1.2422756	33.33% 9.955885 10 <sup>-1</sup>	50% 1.499187 10 <sup>-1</sup>
18	66.66% 9.9059612 10 <sup>-1</sup>	50% 1.3419981	50% 1.242818	33.33% 1.5475521
24	50% 8.124324 10 <sup>-1</sup>	50% 3.2568947 10 <sup>-1</sup>	50% 5.326411 10 <sup>-1</sup>	33.33% 1.4562839

A-4-c / Interprétations :

Sur nos deux tableaux , nous remarquons que l'analyse cepstrale donne toujours de meilleures reconnaissances , le taux est de 100% pour toutes les valeurs du nombre de coefficients sauf pour Nc =6 où il atteint 33.33% . Quant à la méthode LFC , les reconnaissances obtenues ne dépassent pas moyennement 50% pour toutes les valeurs du Np , le taux n'atteint 66.66% que très peu de fois .

A-4-d / Conclusion :

Si nous nous basons sur la comparaison des distances globales moyennes données dans nos tableaux , nous pouvons constater que le nombre optimal de coefficients est 8 pour l'analyse cepstrale et 12 pour l'analyse LFC . Cependant ce critère n'est pas très justifié puisque la comparaison devrait être faite sur le taux de reconnaissance lui-même surtout que nous avons plusieurs expressions pour les distances locales qui changeraient les résultats des distances globales moyennes .

Nous estimons que cela est dû au fait que nous ne travaillons pas sur de la parole réelle puisque nous ne faisons que la simuler .

SAKOE et CHIBA

Dans les programmes de DTW, nous faisons les mêmes calculs que pour les tests précédents avec la méthode LPC et les algorithmes de

A-5-b / Résultats des tests :

Distance locale : distance Euclidienne .

Forme symétrique :

Nombre de fichier dictionnaire par voyelle : 1 ;

--Paramètres de DTW :

--prédicteurs (12) .

nombre de coefficients : --ceptraux (8) ;

Préaccentuation éliminée ; la durée des fenêtres temporelles est 20ms

--Paramètres d'analyse :

fenêtre parallélogrammique pour les largeurs suivantes : 2, 4, 6 .

fréquences des formants . Nous répétons cette opération pour la

Nous générons quatre fichiers par voyelle où nous changeons les

Fpitch = 150 Hz ; Fcch = 12800 Hz ;

--Paramètres de générations :

A-5-a / Données des tests :

obtenus avec la méthode LPC

conclusions . Nous ne donnons alors que les résultats des tests

reconnaissance pas trop différents pour pouvoir tirer des

céder avec la méthode LPC puisque la cepstrale donne des taux de

changeant de forme et de largeur . Pour ce, nous avons préféré pro-

Pour trouver la fenêtre adéquate [14], nous faisons des tests en lui

de largeur  $n$  variable .

en forme de losange avec une largeur constante, ou de parallélogramme

de déformation est restreint à la fenêtre d'ajustement qui peut être

comparaison dynamique des mots ; le champ de recherche de la fonction

Nous avons déjà précisé que pour optimiser les calculs dans la

-----A-5 / Tests sur la fenêtre d'ajustement :

-----chap VI

La largeur de la fenêtre est notée : r

Algorithme Sakoe et Chiba (forme symétrique)					
Fenêtre		Parallépipède			Losange
Pente	Fichiers	r = 2	r = 4	r = 6	
p = 0	Fich2	66.66%	66.66%	66.66%	66.66%
	Fich3	50%	50%	50%	50%
	Fich4	50%	50%	50%	50%
p = 1/2	Fich2	66.66%	50%	50%	66.66%
	Fich3	50%	33.33%	33.33%	50%
	Fich4	50%	50%	50%	50%
p = 1	Fich2	66.66%	50%	50%	50%
	Fich3	50%	50%	50%	50%
	Fich4	50%	50%	50%	50%
p = 2	Fich2	66.66%	66.66%	66.66%	66.66%
	Fich3	50%	50%	50%	50%
	Fich4	50%	50%	50%	50%

A-5-c / Interprétations :

Nous remarquons qu'en élargissant la largeur de la fenêtre parallépipédique, le taux de reconnaissance diminue notamment pour les pentes p = 0 et p = 1 qui donnent, quand r = 2, les mêmes taux qu'avec la fenêtre losange. La seule différence entre ces deux fenêtres n'est perçue que pour la pente p = 1 où nous trouvons moins de reconnaissance avec la deuxième forme (losange).

A-5-d / Conclusions :

Nos tests nous prouvent qu'en réduisant l'espace de recherche de la fonction de déformation dans la comparaison dynamique des mots, le taux de reconnaissance augmente. Cela est évident puisque si des

-----chap VI  
locutions contiennent les mêmes quantités d'informations phonétiques  
les distances qui les séparent sont très réduites .Par suite , nous  
avons tout intérêt à contraindre notre fonction de déformation à ne  
pas s'éloigner de la diagonale du plan où sont développées nos  
locutions.

Par ailleurs , nous concluons que la fenêtre losange est moins  
performante pour nos tests de reconnaissance qu'une fenêtre parallé-  
pipédique de largeur  $r = 2$  .

#### -----A-6 / Tests sur les distances locales :

Dans le but d'affiner les résultats de nos tests , nous allons  
appliquer plusieurs formules pour le calcul des distances locales  
avec les algorithmes de Sakoe et Chiba , forme symétrique avec a  
méthode cepstrae puisque ce sont ces derniers qui nous ont donné les  
meilleurs reconnaissances .

##### A-6-a / Données des tests :

--Paramètres de générations :

Fpitch = 150 Hz ; Fch = 12800 Hz ;

Nous générons quatre fichiers par voyelle où nous changeons les  
fréquences des formants .Nous répétons cette opération pour  
chaque formule de la distance locale .

--Paramètres d'analyse :

Préaccentuation éliminée ; la durée des fenêtres temporelles est 20ms  
nombre de coefficients :--cepstraux (8) ;

--Paramètres de DTW :

Nombre de fichier dictionnaire par voyelle : 1 pour chaque formule  
de la distance locale ;

Forme symétrique ;

##### A-6-b / Résultats des tests :

Dans le tableau suivant , nous présentons les même calculs que

pour les tests précédents , la distance locale est notée Dloc .

Algorithme Sakoe et Chiba (forme symétrique)				
Pente	Dloc	Fichiers-test (fichier-référence : Fich1)		
		Fich2	Fich3	Fich4
p=0	Euclidienne	66.66% 0.62963291	50% 0.68137460	50% 0.87208771
	Tchebytchef	66.66% 0.16776743	50% 0.18801691	50% 0.22691955
	Cepstrale	66.66% 0.17091140	50% 0.20298499	50% 0.25921174
	Cepstrale pondérée	66.66% 3.717994	50% 4.662708	50% 4.845945
p=1/2	Euclidienne	66.66% 0.91867645	50% 1.146948160	50% 1.1496208
	Tchebytchef	66.66% 0.23714978	50% 0.90109247	50% 0.9071096
	Cepstrale	66.66% 0.2905199	33.33% 0.90557212	50% 0.49028622
	Cepstrale pondérée	66.66% 4.896574	33.33% 6.474652	50% 5.984176
p=1	Euclidienne	50% 0.68131981	50% 0.94095116	50% 1.0175998
	Tchebytchef	50% 0.19686461	50% 0.28803709	50% 0.90768615
	Cepstrale	50% 0.2853900	50% 0.97274708	50% 0.88400127
	Cepstrale pondérée	66.66% 5.378224	50% 6.904998	50% 5.675147
p=2	Euclidienne	66.66% 1.9127420	50% 1.5507787	50% 1.2444672
	Tchebytchef	50% 0.49295525	66.66% 0.697075967	33.33% 0.964789742
	Cepstrale	66.66% 1.0412438	50% 0.4228728	50% 0.42513751
	Cepstrale pondérée	66.66% 8.791913	66.66% 7.094692	50% 6.670096

A-6-c / Interprétations ;

Nous remarquons que les taux de reconnaissance sont presque les mêmes pour toutes les distances locales considérées . Néanmoins pour les pentes p=1 et p=2 , la distance cepstrale pondérée semble donner en moyenne c-à-d sur les trois fichiers (trois variations des

formants ) de meilleurs résultats que les autres .

Notons que le calcul des distances globales ne nous sert ici qu'à vérifier s'il y a des rejets .

#### A-6-d / Conclusions :

Malgré que nous ne travaillons pas sur de la parole réelle , nous avons pu approcher les résultats des travaux menés par Mr.S.Furui [15] qui a démontré que la distance locale cepstrale pondérée permet de meilleurs reconnaissances .

#### ----- A-7 / Conclusions générales des tests monolocuteurs :

La combinaison de nos résultats nous permettent de dire que :

- la meilleure méthode d'analyse dans la reconnaissance de la parole, dont nous ne faisons qu'une simulation , est la méthode cepstrale avec un nombre de coefficients égal à 8;
- si nous utilisons une fenêtre d'ajustement parallépipédique , sa largeur doit être très réduite ;
- la distance locale à utiliser est la distance cepstrale pondérée ;
- le meilleur algorithme pour la DTW est celui de Sakoe et Chiba forme symétrique pour les pentes  $p=1$  et  $p=1/2$  .

Par ailleurs , nous devons prendre en considération que la comparaison dynamique des mots est mieux accomplie dans une fenêtre losange car la fonction de déformation y est contrainte à arriver au point final ( $I_{max}, J_{max}$ ) des locutions considérées à l'opposé de la forme parallépipédique où la comparaison s'achève quand  $I_{max}$  ou  $J_{max}$  est atteint (selon leur ordre de grandeur ) ; de plus si nous comparons les deux pentes que nous avons retenues , la pente  $p=1$  nous a offert un meilleur temps de calcul et car elle exige beaucoup moins d'opérations dans la comparaison dynamique .

Nous choisissons alors pour l'étape de classification la méthode d'analyse cepstrale avec pour la DTW , l'algorithme de Sakoe et Chiba forme symétrique avec la pente  $p=1$  dans une fenêtre d'ajustement

de forme losange .

#### IV-B / RESULTATS DE LA CLASSIFICATION :

##### B-1 / INTRODUCTION :

La répartition des locutions d'un mot en différentes classes n'est pas aisée du tout à cause de la forte variabilité de prononciation interlocuteurs . Certaines fois ,il faut attendre plusieurs itérations pour espérer trouver une bonne classification surtout que nous devons ,à chaque fois , faire des fusions et/ou éclatements de classes pour une meilleure valeur de la qualité de mesure ( $\alpha \approx 2$ ) .

En pratique , les chercheurs travaillant sur la parole réelle préparent des centaines de locutions d'un même mot du vocabulaire du système de reconnaissance . Dans notre cas et pour essayer d'approcher le plus possible la parole réelle ,nous nous sommes basés pour la générations (simulation) des références multilocuteurs sur le graphe de distributions des voyelles (formant 2 en fonction du formant ---fig VI-8) donné par Shafer et Rabinner (14).

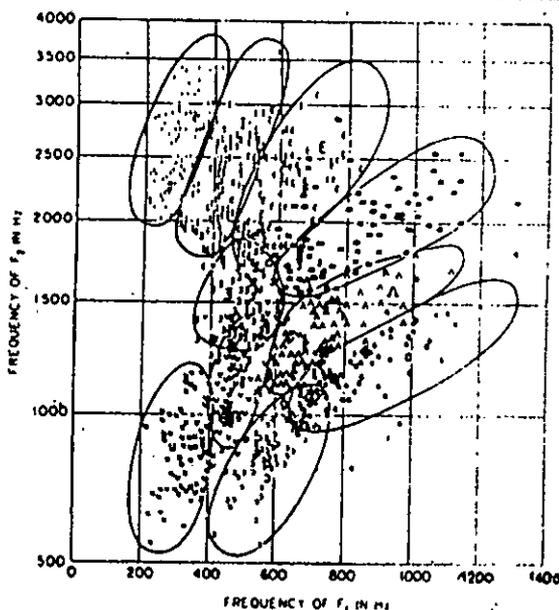


fig VI-8 formant F2 en f(F1) pour plusieurs locuteurs .  
 Nous faisons alors des variations des formants et du pitch mais

-----chap VI  
dans un nombre limité de locutions (26 pour chaque voyelle) faute de temps et de la panne du Micro Vax..

#### B-2 / GROUPEMENT EN CHAINE :

La méthode "CHAINMAP" nous permet de représenter graphiquement la distribution des différentes locutions d'un mot .Les pics obtenus sur nos graphes d'ordonnement (voir *fig VI-9* ) permettent de délimiter les classes de locutions . Notons que c'est à cause de l'aspect 'simulation' de la parole que les limites des classes ne sont pas très nettes . Néanmoins , nous pouvons compter le nombre de locutions "hors-communs" ou "outliers" et estimer plus ou moins le nombre de classes .

#### B-3 /CLASSIFICATION :

Les fichiers de chaque voyelle sont numérotés de 1 à 26 .Pour une bonne classification , nous donnons dans les tableaux de résultats la distance moyenne maximale intraclasse notée  $D_{icmax}$  , la distance minimale entre les prototypes notée  $D_{icmin}$  , le facteur de qualité de mesure  $\alpha$  , le nombre  $N_c$  de classes , ainsi que la dimension  $Dim$  de chaque classe et dans le même ordre le numéro  $N^o_p$  de sa locution prototype.

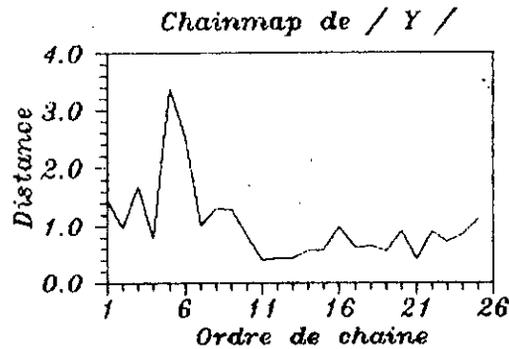
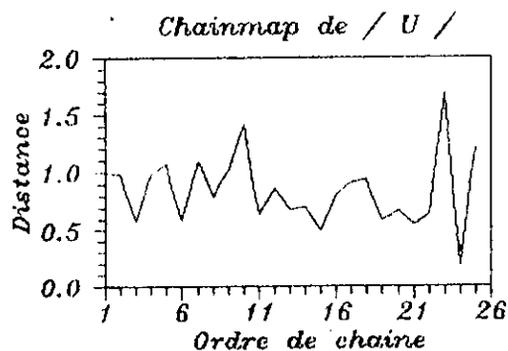
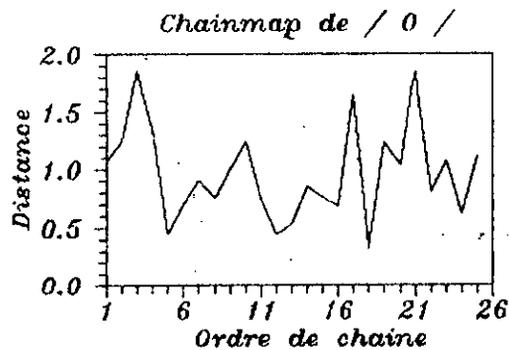
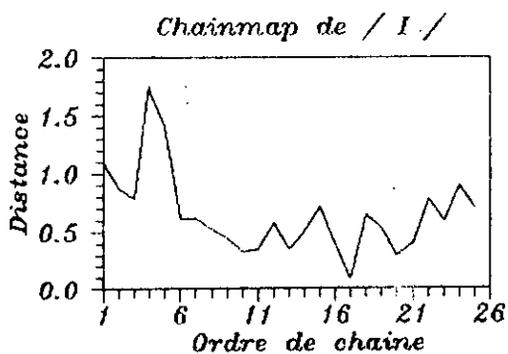
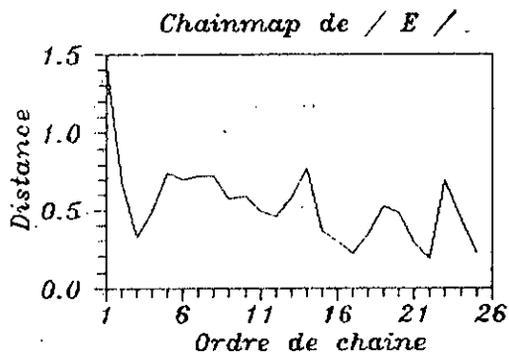
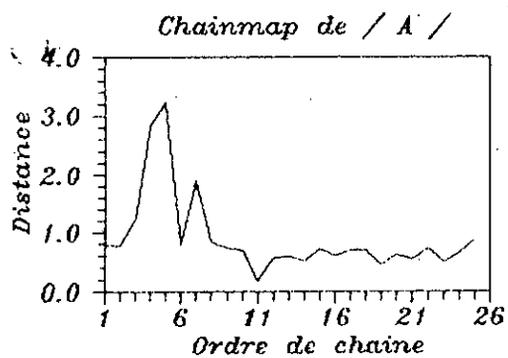


Fig VI.9: Graphes des Groupements en chaîne des voyelles ( a,e,i,o,u,y ), avec 26 locutions pour chaque voyelle

VOYELLE "A"					
Nc	Dim	N°p	$\sigma$	Dicmax	Dicmin
2	11 ; 15	29 ; 01	3.5281	1.3023	3.5850
3	7 ; 11 ; 08	21 ; 13 ; 01	2.3802	1.0997	1.5452
4	7 ; 9 ; 4 ; 6	23 ; 17 ; 01 ; 10	2.5744	0.8965	0.9653
5	5 ; 6 ; 9 ; 10 ; 2	23 ; 17 ; 01 ; 15 ; 26	2.6996	0.9657	0.6263
6	4 ; 5 ; 9 ; 3 ; 2 ; 9	24 ; 16 ; 1 ; 18 26 ; 10	2.5601	0.7717	0.7960
7	4 ; 5 ; 9 ; 3 ; 2 ; 7 ; 2	24 ; 16 ; 01 ; 18 26 ; 10 ; 09	2.4035	0.7717	0.1675
8	4 ; 5 ; 9 ; 3 ; 1 ; 7 ; 2 ; 1	24 ; 16 ; 01 ; 18 26 ; 10 ; 09 ; 25	3.4206	0.7321	0.1675

Interprétations :

Nous remarquons qu'une bonne répartition des échantillons de la voyelle "A" n'est obtenue qu'avec 8 classes avec une qualité de mesure  $\sigma = 3.42$  et l'apparition de 2 locutions "outliers" (hors-communs) .

VOYELLE "E"					
Nc	Dim	N°p	$\sigma$	Dicmax	Dicmin
2	11 ; 15	26 ; 05	2.4733	0.7052	1.4568
3	5 ; 18 ; 09	25 ; 15 ; 26	1.8220	0.5811	0.6881
4	4 ; 14 ; 9 ; 5	25 ; 01 ; 26 ; 17	2.7443	0.9480	0.6881
5	6 ; 14 ; 9 ; 5 ; 1	25 ; 01 ; 26 ; 17 ; 20	3.2093	0.5480	0.6327
6	9 ; 9 ; 1 ; 4 ; 14 ; 1	26 ; 25 ; 20 ; 15 01 ; 21	3.6241	0.4691	0.6327
7	9 ; 9 ; 9 ; 1 ; 1 ; 14 ; 1	18 ; 26 ; 25 ; 21 20 ; 01 ; 17	4.1881	0.4585	0.5568

Interprétations :

Il faut au moins 5 classes ( $\sigma = 3.20$ ) pour pouvoir bien répartir

les échantillons de la voyelle "E"; encore mieux avec 7 classes car donnant 3 "outliers" et  $\sigma = 4.2$ .

VOYELLE "U"					
Nc	Dim	N°p	$\sigma$	Dicmax	Dicmin
2	18 ; 12	12 ; 24	1.7252	0.7767	1.4926
3	6 ; 9 ; 17	2 ; 29 ; 19	1.7057	0.7316	0.8095
4	5 ; 8 ; 9 ; 9	22 ; 29 ; 5 ; 15	1.6921	0.7081	0.7787
5	4 ; 2 ; 9 ; 2 ; 9	25 ; 29 ; 5 ; 26 ; 17	1.7835	0.7845	0.6971
6	5 ; 2 ; 5 ; 6 ; 2 ; 6	25 ; 29 ; 9 ; 15 26 ; 17	1.9616	0.6637	0.6188
7	2 ; 2 ; 4 ; 5 5 ; 1 ; 7	26 ; 29 ; 25 ; 17 10 ; 18 ; 05	2.4933	0.6201	0.6971
8	2 ; 1 ; 4 ; 8 5 ; 1 ; 4 ; 1	26 ; 29 ; 25 ; 17 10 ; 18 ; 9 ; 20	3.2392	0.6131	0.6620

Interprétatifs :

La qualité de mesure n'est bonne qu'au delà de Nc=6 ( $\sigma < 2$ ) et il faut 8 classes pour trouver un très bon  $\sigma$  (3.23) et faire apparaître 3 locutions "outliers".

VOYELLE "I"					
Nc	Dim	N°p	$\sigma$	Dicmax	Dicmin
2	14 ; 12	24 ; 10	2.0326	0.6365	1.1681
3	2 ; 12 ; 12	26 ; 01 ; 20	1.9330	0.8654	1.2154
4	1 ; 4 ; 10 ; 11	25 ; 25 ; 20 ; 01	2.7269	0.9601	0.8054
5	8 ; 1 ; 1 ; 08 ; 08	20 ; 26 ; 25 ; 17 ; 01	3.9578	0.5896	0.8654
6	03 ; 1 ; 1 ; 9 ; 9 ; 9	24 ; 26 ; 25 ; 01 22 ; 14	3.4110	0.6428	0.5476

Interprétation :

Il faut 5 classes pour avoir la plus bonne configuration des

échantillons avec  $\sigma = 3.95$  et l'apparition de 2 locutions "outliers".

VOYELLE "O"					
Nc	Dim	N°p	$\sigma$	Dicmax	Dicmin
2	19 ; 19	22 ; 01	2.0026	0.9508	1.9033
3	10 ; 11 ; 05	22 ; 01 ; 19	2.1008	0.9005	1.1357
4	2 ; 11 ; 15 ; 8	26 ; 01 ; 19 ; 22	2.1298	0.8845	1.0701
5	2 ; 5 ; 11 ; 5 ; 3	26 ; 19 ; 01 ; 19 ; 22	2.1768	0.8821	0.8644
6	2 ; 5 ; 4 ; 4 ; 9 ; 8	26 ; 21 ; 01 ; 03 25 ; 09	2.1532	0.6328	0.7227
7	2 ; 5 ; 4 ; 5 ; 9 ; 6 ; 1	26 ; 21 ; 12 ; 19 22 ; 11 ; 01	2.3347	0.6623	0.7369
8	2 ; 5 ; 4 ; 4 9 ; 5 ; 1 ; 2	26 ; 21 ; 12 ; 03 25 ; 15 ; 01 ; 09	2.4779	0.6563	0.6164
9	2 ; 5 ; 4 ; 4 ; 5 1 ; 1 ; 9 ; 9	26 ; 21 ; 12 ; 03 25 ; 15 ; 1 ; 11 ; 9	2.5885	0.6098	0.4462

Interprétation :

Il est difficile d'obtenir une bonne répartition des échantillons de la voyelle "O", même avec 9 classe la qualité de mesure n'atteint pas 3 .

VOYELLE "Y"					
Nc	Dim	N°p	$\sigma$	Dicmax	Dicmin
2	16 ; 10	01 ; 22	2.3977	1.4091	3.0323
3	14 ; 06 ; 06	01 ; 26 ; 10	2.4799	1.2597	1.9989
4	12 ; 6 ; 5 ; 3	01 ; 17 ; 22 ; 26	2.4573	1.1450	1.4456
5	2 ; 4 ; 5 ; 09 ; 12	01 ; 17 ; 22 ; 26 ; 12	2.6268	0.8855	1.4456
6	10 ; 9 ; 3 ; 3 ; 4 ; 3	01 ; 19 ; 22 ; 25 12 ; 15	2.6802	1.0449	0.9785
7	9 ; 3 ; 9 ; 1 ; 11 ; 3 ; 2	24 ; 16 ; 01 ; 18 26 ; 10 ; 09	3.3777	0.8855	0.9667

Interprétations :

Il faut arriver à 7 classes pour avoir une très bonne valeur de  $\sigma$  (3.37) où apparaît 1 locution "outlier".

B-4 / CONCLUSIONS :

Nos résultats attestent que nous avons bien appliqué les méthodes de classification à nos fichiers . Leur nombre réduit (insuffisance d'espace mémoire) , n'a pas été un inconvénient majeur pour prouver que la qualité de mesure ( $\sigma$ ) augmente avec le nombre de classes et que les meilleures répartitions sont obtenues avec des valeurs de  $\sigma$  proches de 3 . Par conséquent, nous pouvons entamer les tests multilocuteurs sans difficulté .

En résumé , les meilleures configurations obtenues sont les suivantes :

--Voyelle "A" : Nc =8 classes ,  $\sigma$  =3.42 ;  
 --Voyelle "E" : Nc =7 classes ,  $\sigma$  =4.18 ;  
 --Voyelle "I" : Nc =5 classes ,  $\sigma$  =3.41 ;  
 --Voyelle "O" : Nc =9 classes ,  $\sigma$  =2.56 ;  
 --Voyelle "U" : Nc =8 classes ,  $\sigma$  =3.23 ;  
 --Voyelle "Y" : Nc =7 classes ,  $\sigma$  =3.37 ;

VI-C / TESTS MULTILOCUTEURS .

Les tests multilocuteurs nous permettront de finaliser notre travail et de vérifier si les taux de reconnaissances estimés en théorie s'accordent avec la réalité pratique de notre système .

Notons encore une fois que les contraintes de temps de calcul et de disponibilité des micros ne nous ont pas permis de multiplier nos tests pour tirer plus de conclusions sur les performances du système.

C-1 / TESTS :

Les tests , que nous faisons , doivent nous renseigner sur les

-----chap VI  
valeurs optimales du nombre "K" des techniques KNN dans l'étape de  
décision . Les taux que nous donnons dans les tableaux suivants sont  
les moyennes de plusieurs tests c-à-d le nombre de tests positifs  
sur le nombre total de tests .

Test 1 ) Les mots tests appartiennent au dictionnaire (M.T.A.D ):

Nombre de classes	Taux de reconnaissance			
	Valeur de K			
	1	2	3	4
2	100%	83.33%	-----	-----
3	100%	94.44%	88.89%	-----
4	100%	100%	91.67%	87.50%
5	100%	96.67%	90%	86.67%
6	100%	100%	94.44%	94.44%

interprétations : courbe VI-10 (MTAD)

Les taux obtenus pour  $k = 1$  sont évidents puisque les distances globales calculées sont nulles ; pour les autres valeurs de K , les taux sont toujours très bons et augmentent d'autant plus que le nombre de classes augmente .Ceci est attendu parceque les configurations des échantillons deviennent plus meilleures .

L'ordre élevé de nos résultats est dû au fait que les mots test sont comparés à eux mêmes .

Test 2 ) Les mots tests ont pris part à l'apprentissage (M.T.P.A ) :

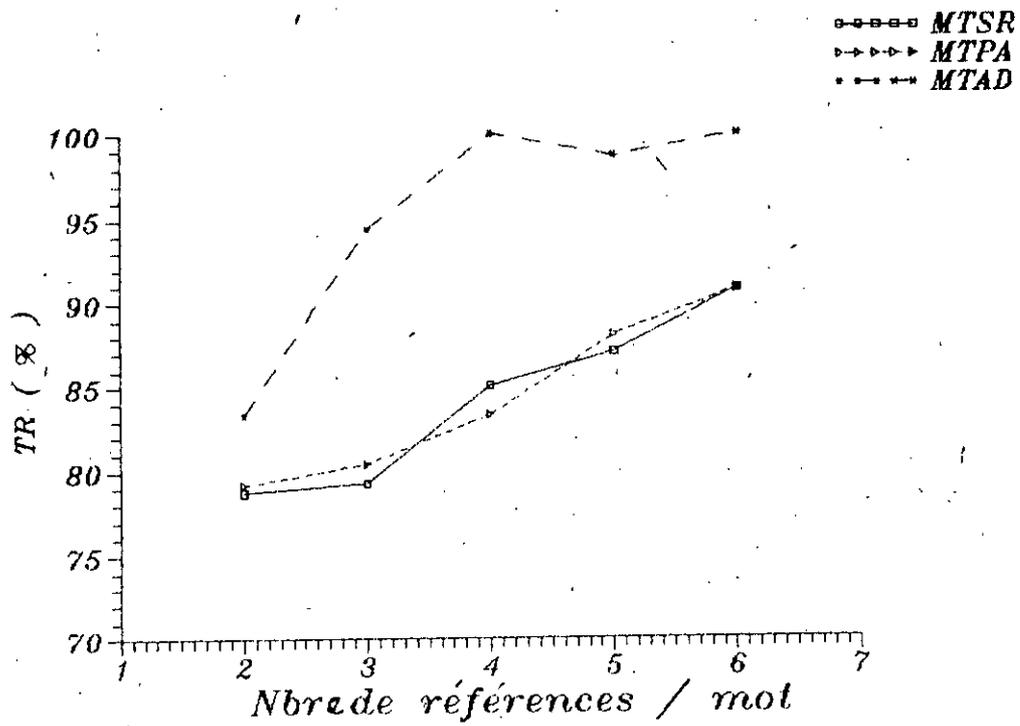


Fig VI-10: Influence du nombre de références par mot sur le taux de reconnaissance pour  $KNN=2$

Nombre de classes	Taux de reconnaissance			
	Valeur de K			
	1	2	3	4
2	84.72%	79.17%	-----	-----
3	77.54%	80.43%	79.91%	-----
4	89.93%	89.93%	79.55%	68.18%
5	86.51%	88.10%	85.71%	80.95%
6	92.50%	90.89%	86.67%	85.60%

Interprétation : courbe VI-10 (MTPA)

Les taux obtenus sont toujours satisfaisants et augmentent suivant le nombre de classes vu leur appartenance à ces mêmes classes. La valeur optimale de K est 2 à partir de 3 classes.

.Test-3-) Les mots tests ( M.T.S.R ) n'ont pas pris part à l'apprentissage :

Nombre de classes	Taux de reconnaissance			
	Valeur de K			
	1	2	3	4
2	89.93%	78.74%	-----	-----
3	78.61%	79.91%	79.56%	-----
4	89.91%	85.06%	80.46%	70.11%
5	86.21%	87.06%	84.48%	81.09%
6	90.80%	90.80%	86.78%	86.21%

Interprétation : courbe VI-10 (MTRR)

Les taux obtenus sont très satisfaisants et augmentent suivant le nombre de classes. le nombre K optimal des "K" premières références est toujours 2 quand le nombre de classes est plus de 2.

C-2 / CONCLUSION :

Nos tests ont montré que les reconnaissances sont d'autant

meilleures que le nombre de classes est élevé et que des valeurs optimales de "K" , existent réellement ( $K=2$ ) indépendamment configuration des échantillons .Ceci prouve que nous avons bien appliqué les méthodes de classification et les techniques de décision puisque la valeur de K obtenue avec de la parole réelle par Rabiner [16] est la même .

# AND CONCLUSIONS

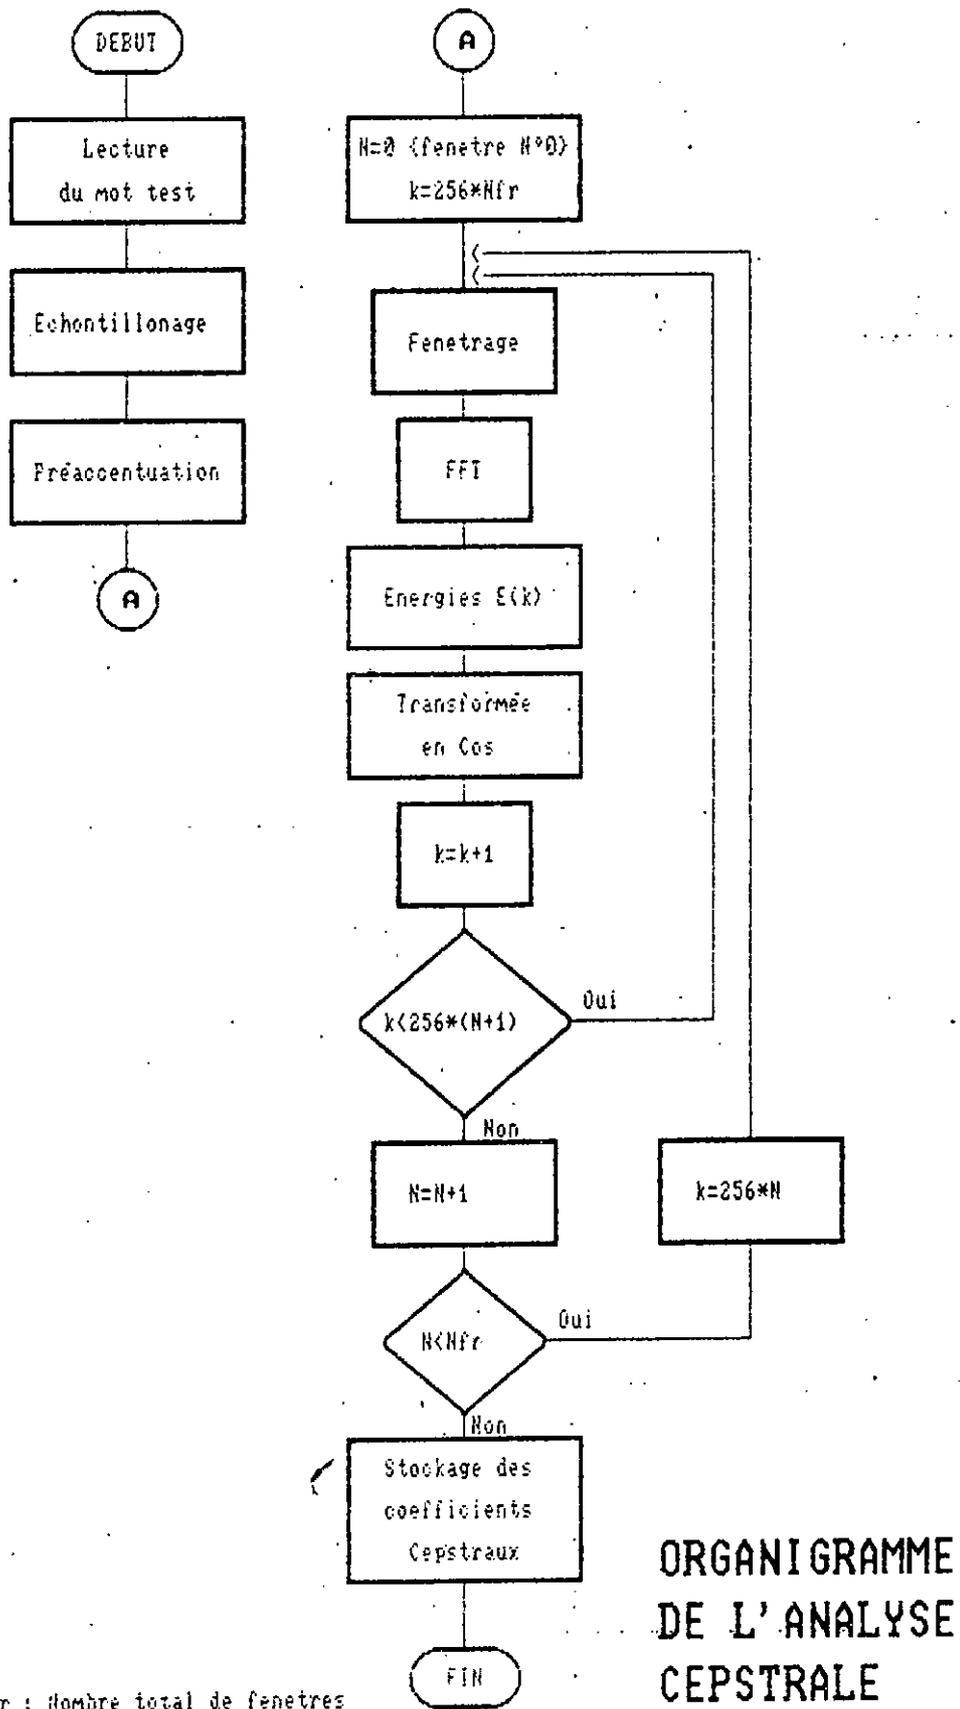
L'objectif initial de notre travail était au départ , l'étude d'un système de reconnaissance de la parole par les méthodes glabales en mode multilocuteurs en vue d'une éventuelle implantation sur le microprocesseur TMS 320 . Cependant , beaucoup de contraintes nous ont empêché de concrétiser ce but . Nous étions donc forcés de nous limiter uniquement à la partie étude où nous avons mis au point des programmations très élaborées et très opérationnelles .

Le manque de temps et la panne prolongée du Vax nous ont créé énormément de lassitudes . Néanmoins , nous avons pu générer assez de fichiers pour nos différents tests où nous avons pu approché , plus au moins , beaucoup de résultats publiés par les chercheurs travaillant , contrairement à nous , sur la parole réelle .

Par ailleurs , nous insistons sur le fait que la recherche sur la reconnaissance de la parole est devenue , de nos jours , presque totalement expérimentale et exige beaucoup de moyens pour pouvoir arriver à un quelconque résultat . Des données théoriques relatives à la parole ne peuvent plus servir de base dès lors que les procédures actuelles des chercheurs , commencent par émettre des hypothèses puis procéder aux expériences pour les valider ou bien les infirmer surtout avec les performances de l'intelligence artificielle .

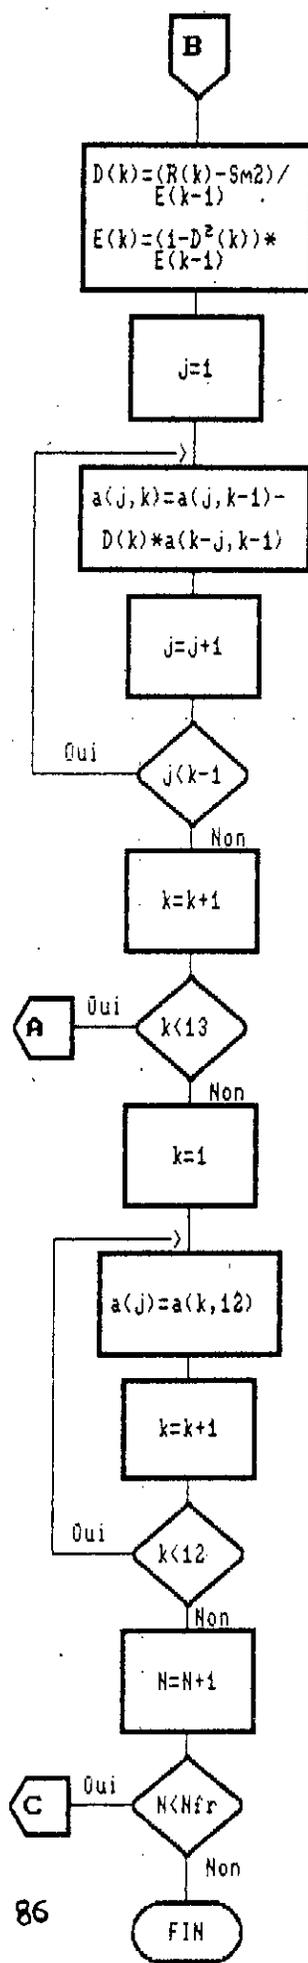
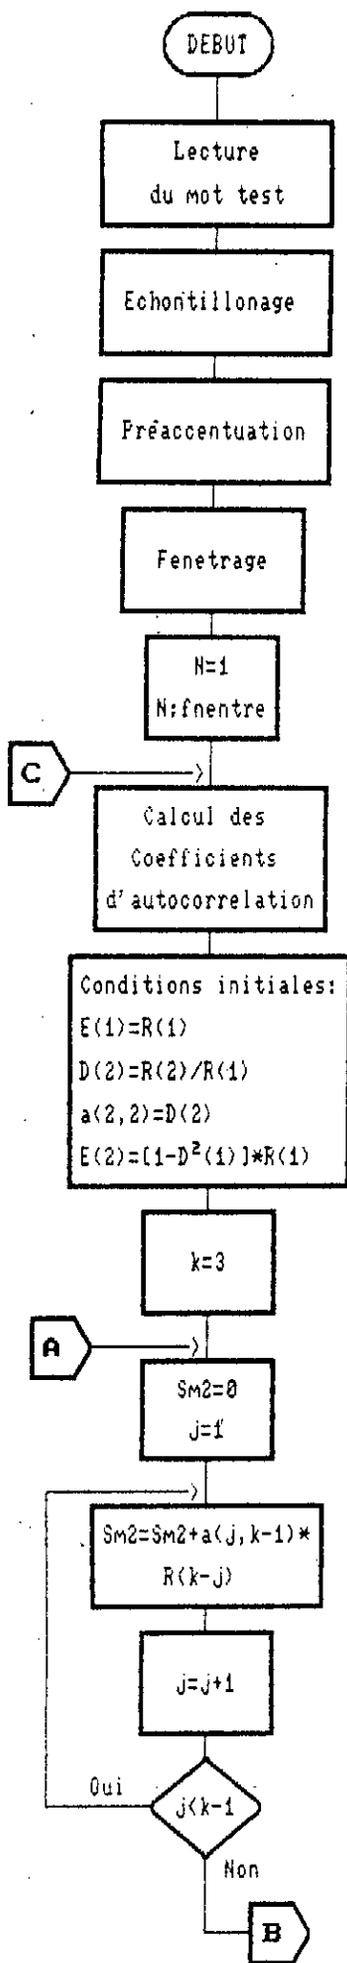
Enfin , il est intuitivement évident qu'avec ce sujet , nous avons développé de beaucoup nos connaissances en programmation , en algorithmique et en traitement du signal .

# ANNEXE

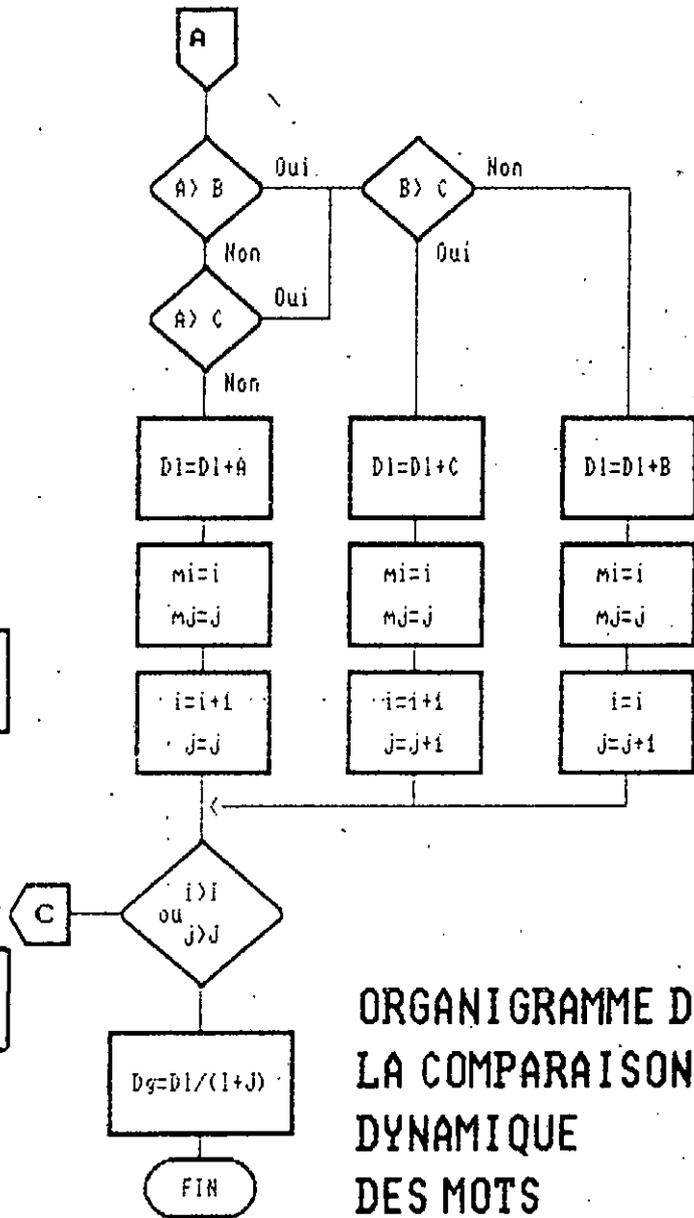
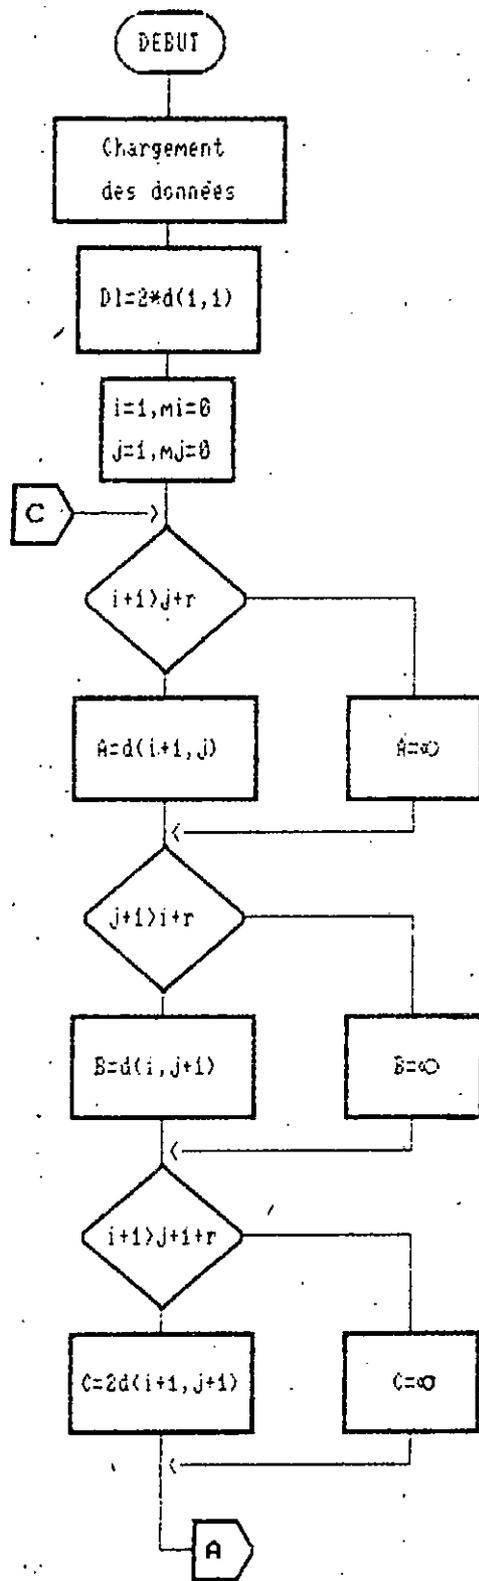


Nfr : Nombre total de fenetres

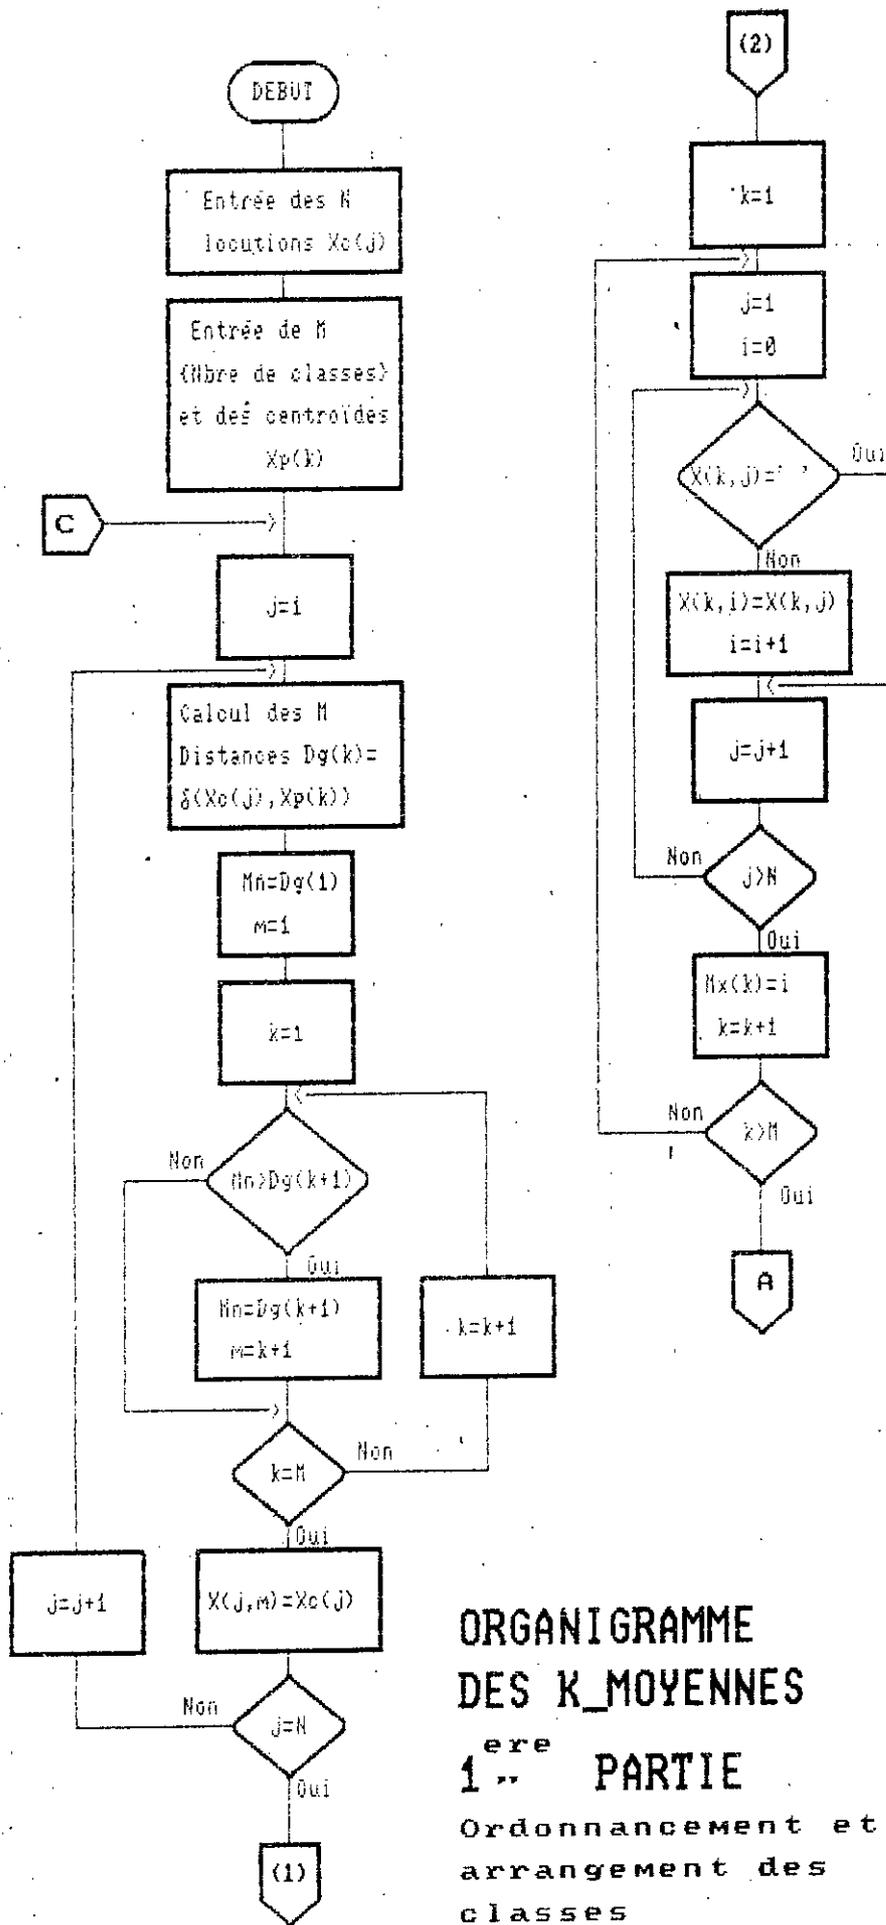
**ORGANIGRAMME  
DE L'ANALYSE  
CEPSTRALE**



ORGANIGRAMME  
DE L'ANALYSE  
LPC



ORGANIGRAMME DE  
LA COMPARAISON  
DYNAMIQUE  
DES MOTS



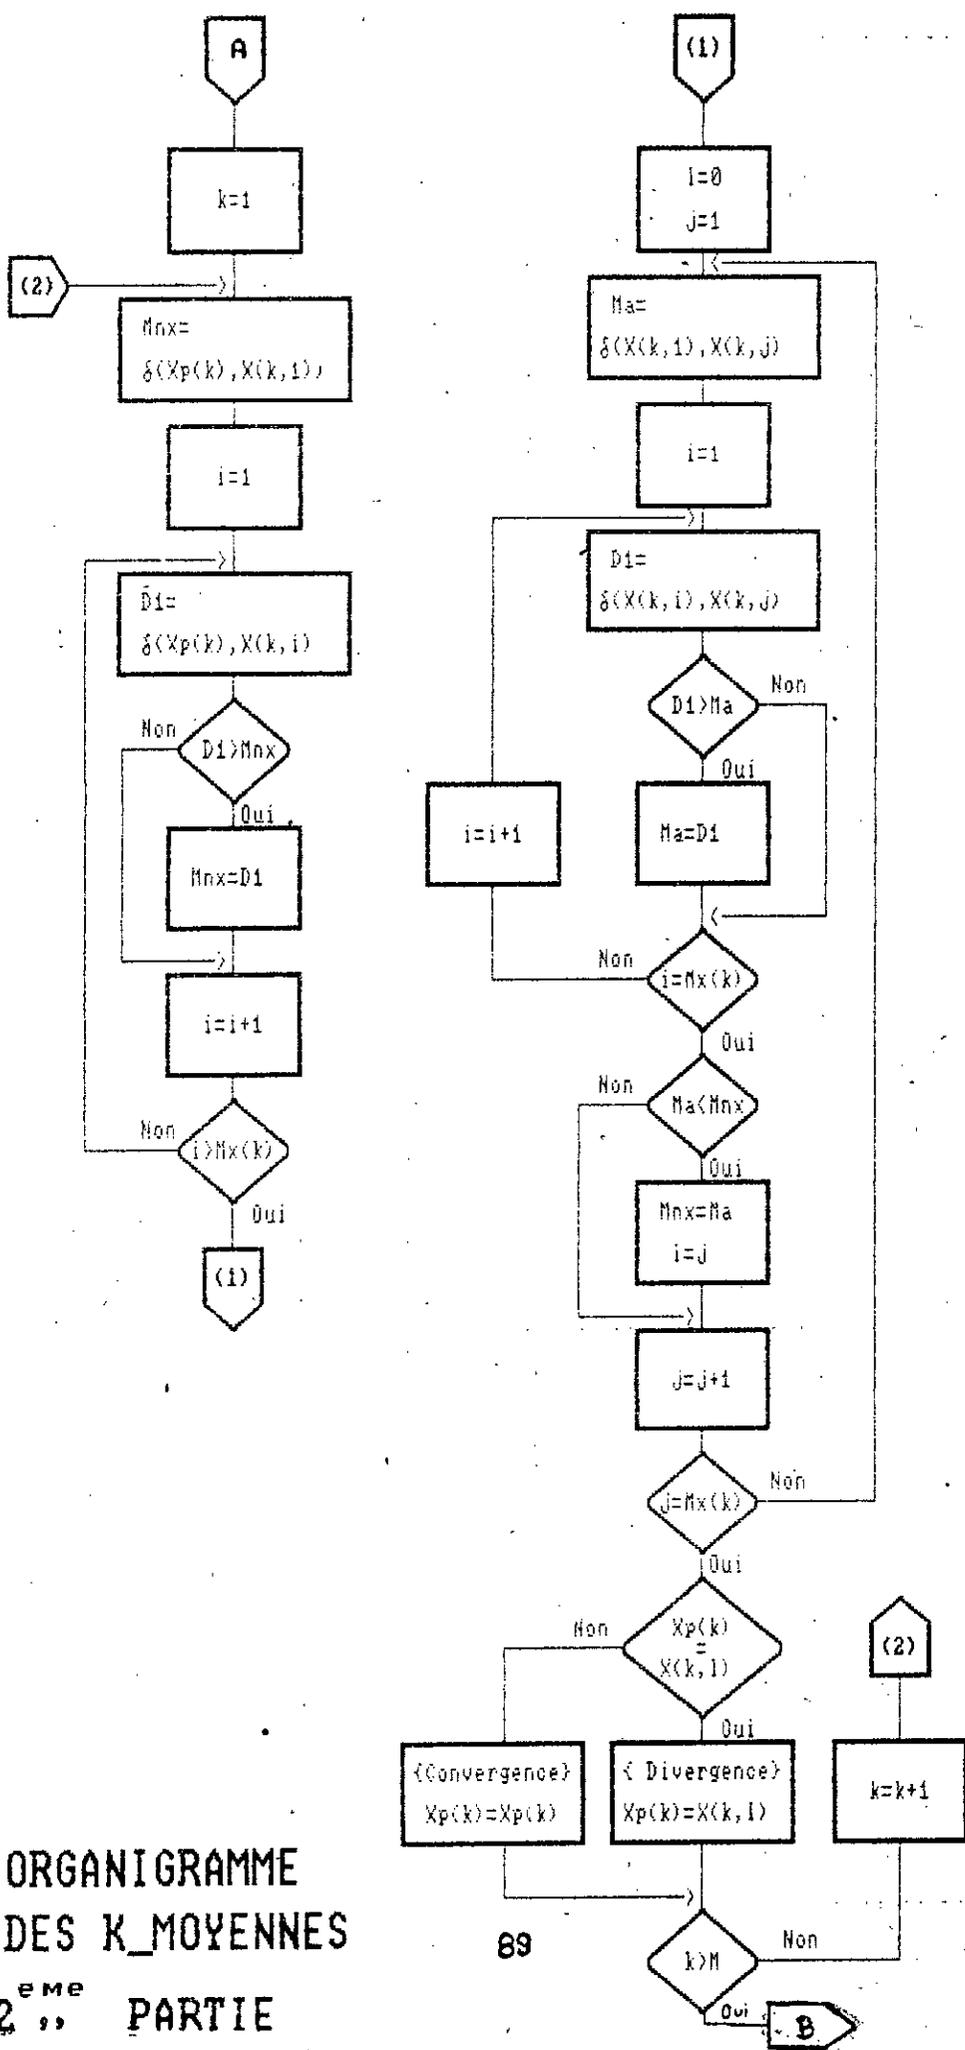
## ORGANIGRAMME DES K\_MOYENNES

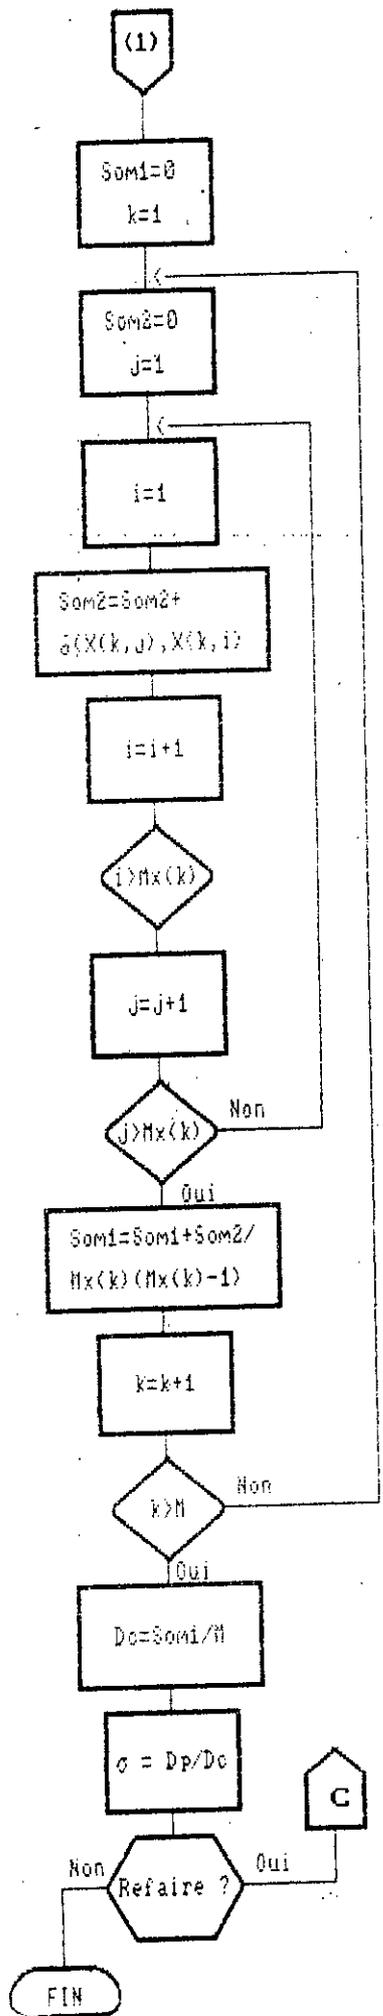
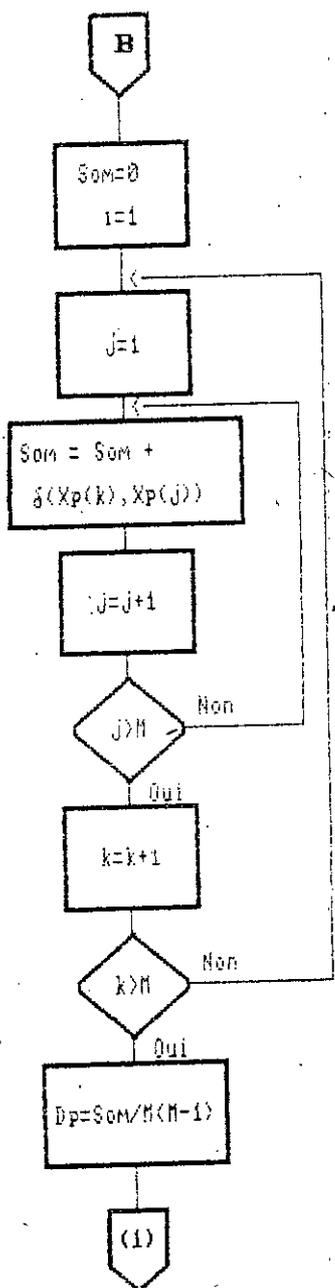
### 1<sup>ere</sup> PARTIE

Ordonnancement et  
arrangement des  
classes

ORGANIGRAMME  
DES K\_MOYENNES

2<sup>eme</sup> PARTIE





**ORGANIGRAMME  
DES K\_MOYENNES  
3<sup>eme</sup> PARTIE**

Calcul de  $\sigma$   
la qualite  
de mesure

BIBLIOGRAPHIE

- [1]: Dictionnaire "Petit Robert" 1972 ;
- [2]: " Reconnaissance de la parole en mode multilocuteur " ,1984  
A Menacer ,thèse Docteur-Ingénieur ,Université de Neuchâtel ;
- [3]: " Traitement de la parole "   
par M.Kunt ,R.Boite ,Presses Polytechniques Romandes, 1987 ;
- [4]: "Linear Prediction :A tutorial review" proceedings "   
par J.Makhoul , IEEE ,vol.63 ,Avril 1975 ;
- [5]: " Traitement Numérique des signaux "   
par M.Kunt ,édition Dunod , 1987 ;
- [6]: " Dynamic Programming Algorithm optimization for Spoken word  
Recognition " par H.Sakoe ,S.Chiba  
IEEE ,ASSP ,vol.35 ,N°10 ,Octobre 1987 ;
- [7]: " Reconnaissance de la parole en mode multilocuteur de mots  
isolés par les systèmes miniaturisés " , 1985  
A.Mokkedem ,thèse Docteur es-Science ,université Neuchâtel
- [8]: " La parole , compréhension et synthèse par les ordinateurs "   
par J.Guibert ,Presses Universitaires ,1979 ;
- [9]: " Interactive Clustering Techniques for Selecting Speaker  
Independent References Templates for Isolated word and  
Recognition " ,  
par S.Levinson ,L.Rabiner ,J.Wilpon ,A.Rosenberg  
IEEE ,vol.27 , N°2 ,Avril 1979 ;
- [10]: "A vector Quantization based Preprocessor for Spoken  
Indépendent Isolated word Recognition "   
par K.Pan ,R.Chafer ,F.K.Soong ,L.Rabiner  
IEEE , ASSP, v.33 ,N°3 ,Juin 1985 ;
- [11]: " Cours de Phonétique " par E.Emerit  
SNED , 1977 ;
- [12]: " Digital Processing of Speech Signals "   
par L.Rabiner ,R.Chafer ,  
Printice Hal , Alan Openheim , New Jersey , 1978 ;

- [13]: "A Weighted Cepstral Distance Measure for Speech Recognition"  
par Y.Tohkura ,  
IEEE , ASSP , vol.35 , N°10 , Octobre 1987 ;
- [14]: -" Considérations in Dynamic Time Worping Algorithms for  
Discrete Word Recognition "  
par L.Rabiner , S.Levinson , A.Rosenberg ,  
IEEE , ASSP , Vol26.34 , N°6 , Decembre 1978 ;
- [15]: "Speaker Independent Isolated word Recognition Using Dynamic  
Features of Speech Spectrum " ,  
par S.Furui , IEEE, ASSP , vol.34 , N°1 , Fevrier 1986 ;
- [16]: "Speaker Independent Isolated Word Recognition a Moderate  
Size Vocabulary " ,  
par L.Rabiner , IEEE , vol.27 , N°6 , Decembre 1979