

# **Master IAD**

## **Module PS**



V. Synthèse de la parole

**Gaël RICHARD**  
**février 2008**



# Contenu



- Introduction aux technologies vocales
- Production et Perception de la parole
- Modélisation articulatoire
- **Synthèse de la parole**
- Reconnaissance de la parole

# Synthèse de la parole

- Introduction
- Petit historique de la synthèse vocale
- Architecture d'un système de synthèse
- Pré-traitement
- Analyse linguistique
- Intonation (prosodie)
- Synthèse acoustique
  - ✓ Synthèse par règles
  - ✓ Synthèse par concaténation
- Applications

# Synthèse de parole

- But : Transformer un texte écrit en un signal de parole

**Réalise l'interface entre le monde de l'écrit et de la voix**

- Quelques exemples d'applications
  - Téléservices (renseignement par téléphone...)
  - Lecture de site Web, lecture de mèl
  - Machine à lire pour handicapés
  - A terme....communication homme-machine

# Un peu d'histoire: il y a très longtemps....

- Exemple d'application de la « synthèse »...

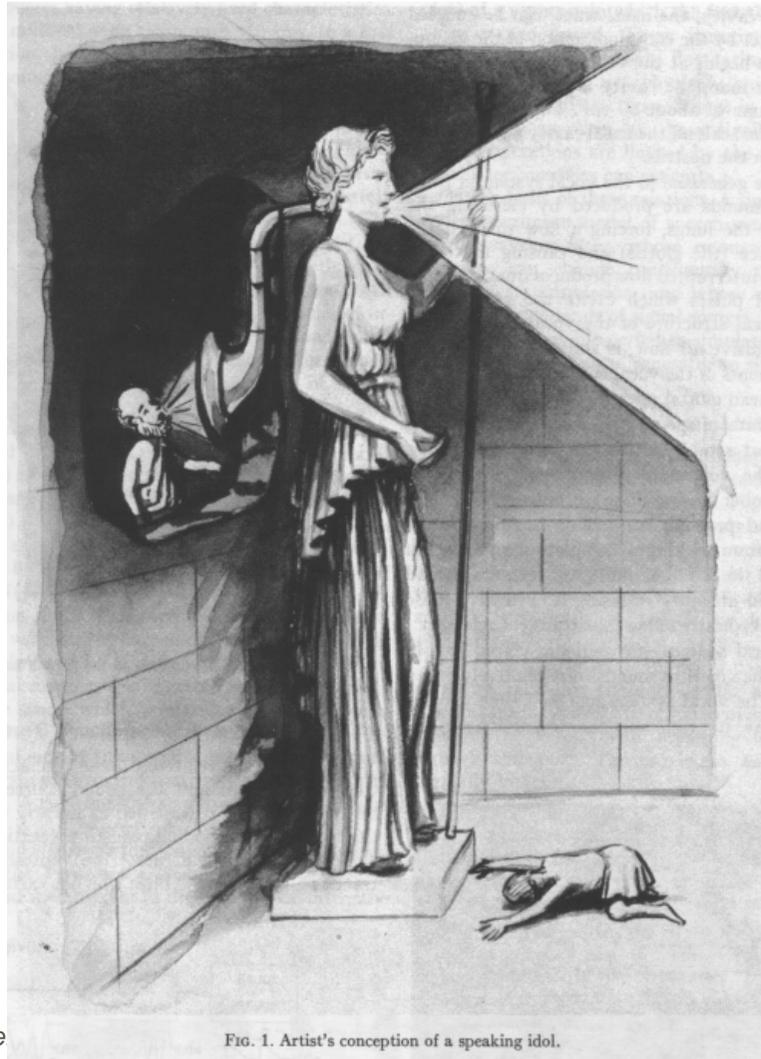


FIG. 1. Artist's conception of a speaking idol.

# Un peu d'histoire: les ancêtres

## □ La machine de Von Kempelen (1791)

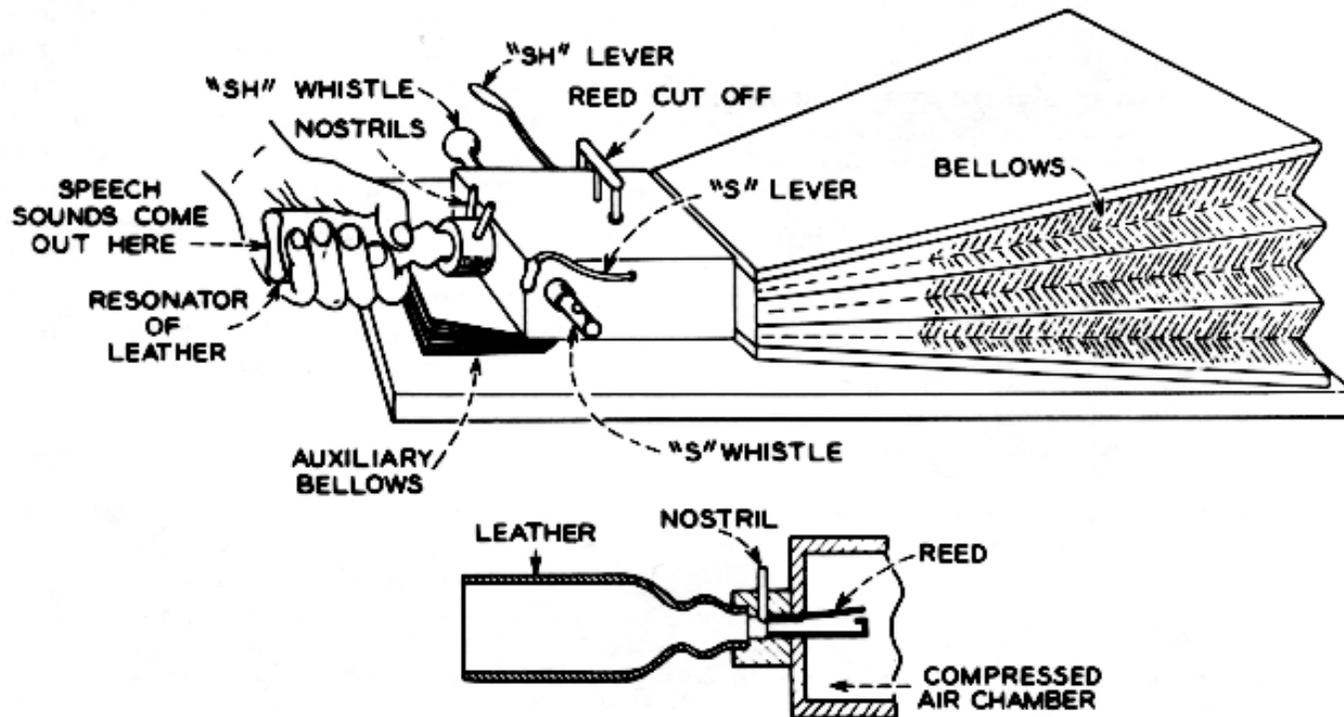
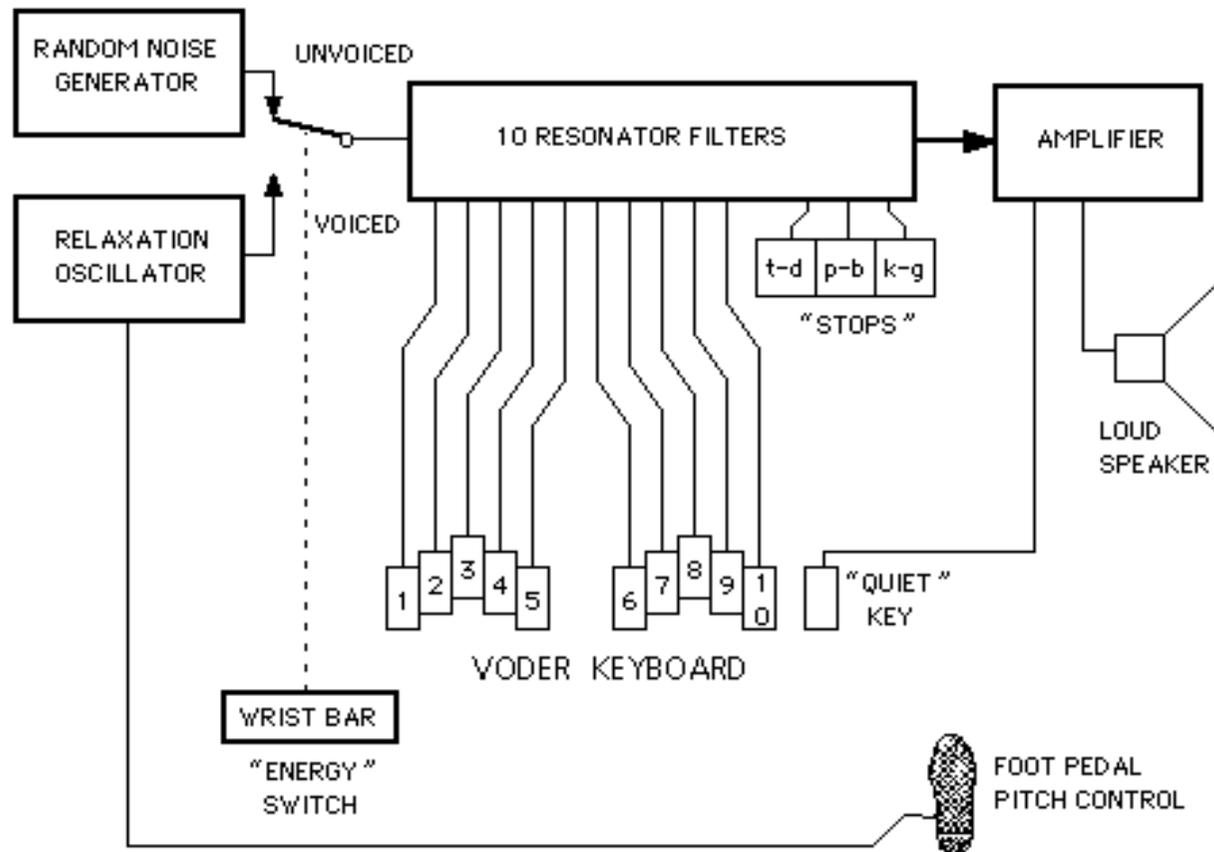


Fig. 10. Wheatstone's reconstruction of von Kempelen's speaking machine.<sup>1</sup>

The Journal of the Acoustical Society of America

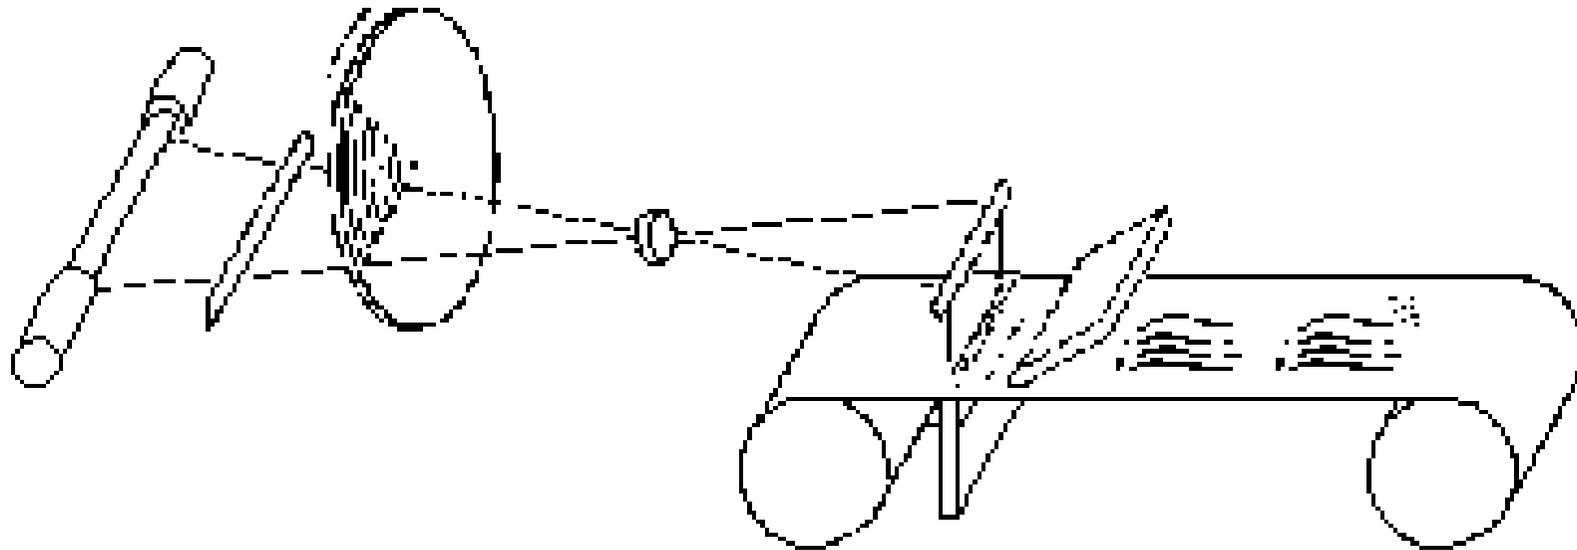
# Un peu d'histoire: les ancêtres

## □ Le voder (Dudley, 1939) 🗣️



# Un peu d'histoire: les ancêtres

- Le Pattern Playback, Cooper ( env. 1951)



# Un peu d'histoire: les ancêtres

- ❑ 1953: OVE, synthétiseur à formant (G. Fant) 
- ❑ 1962: Synthétiseur à formant (copie) 
- ❑ 1968: synthèse articulatoire (Rosen): 

# Premiers systèmes de synthèse (règles)

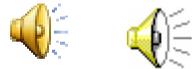
- ❑ Synthèse par règles (P. Delattre), 1959 
- ❑ Synthèse à partir de phonèmes: John Kelly and Louis Gerstman, 1961. 
- ❑ Synthèse par concaténation de diphones codés en formants Rex Dixon and David Maxey, 1968. 

# Premiers systèmes de synthèse

- ❑ Synthèse du japonais Noriko Umeda et al., 1968. 
- ❑ Premier système de synthèse de l'anglais, 1973. 
- ❑ La machine à lire pour aveugle Raymond Kurzweil, 1976. 
- ❑ Le premier système commercial (Type-n-Talk) Richard Gagnon, 1978. 
- ❑ Le système Echo (diphone) 1982. 
- ❑ Le premier système de qualité, 1983 (KlatTalk)... 
- ❑ Quelques voix de DecTalk 

# Aujourd'hui...

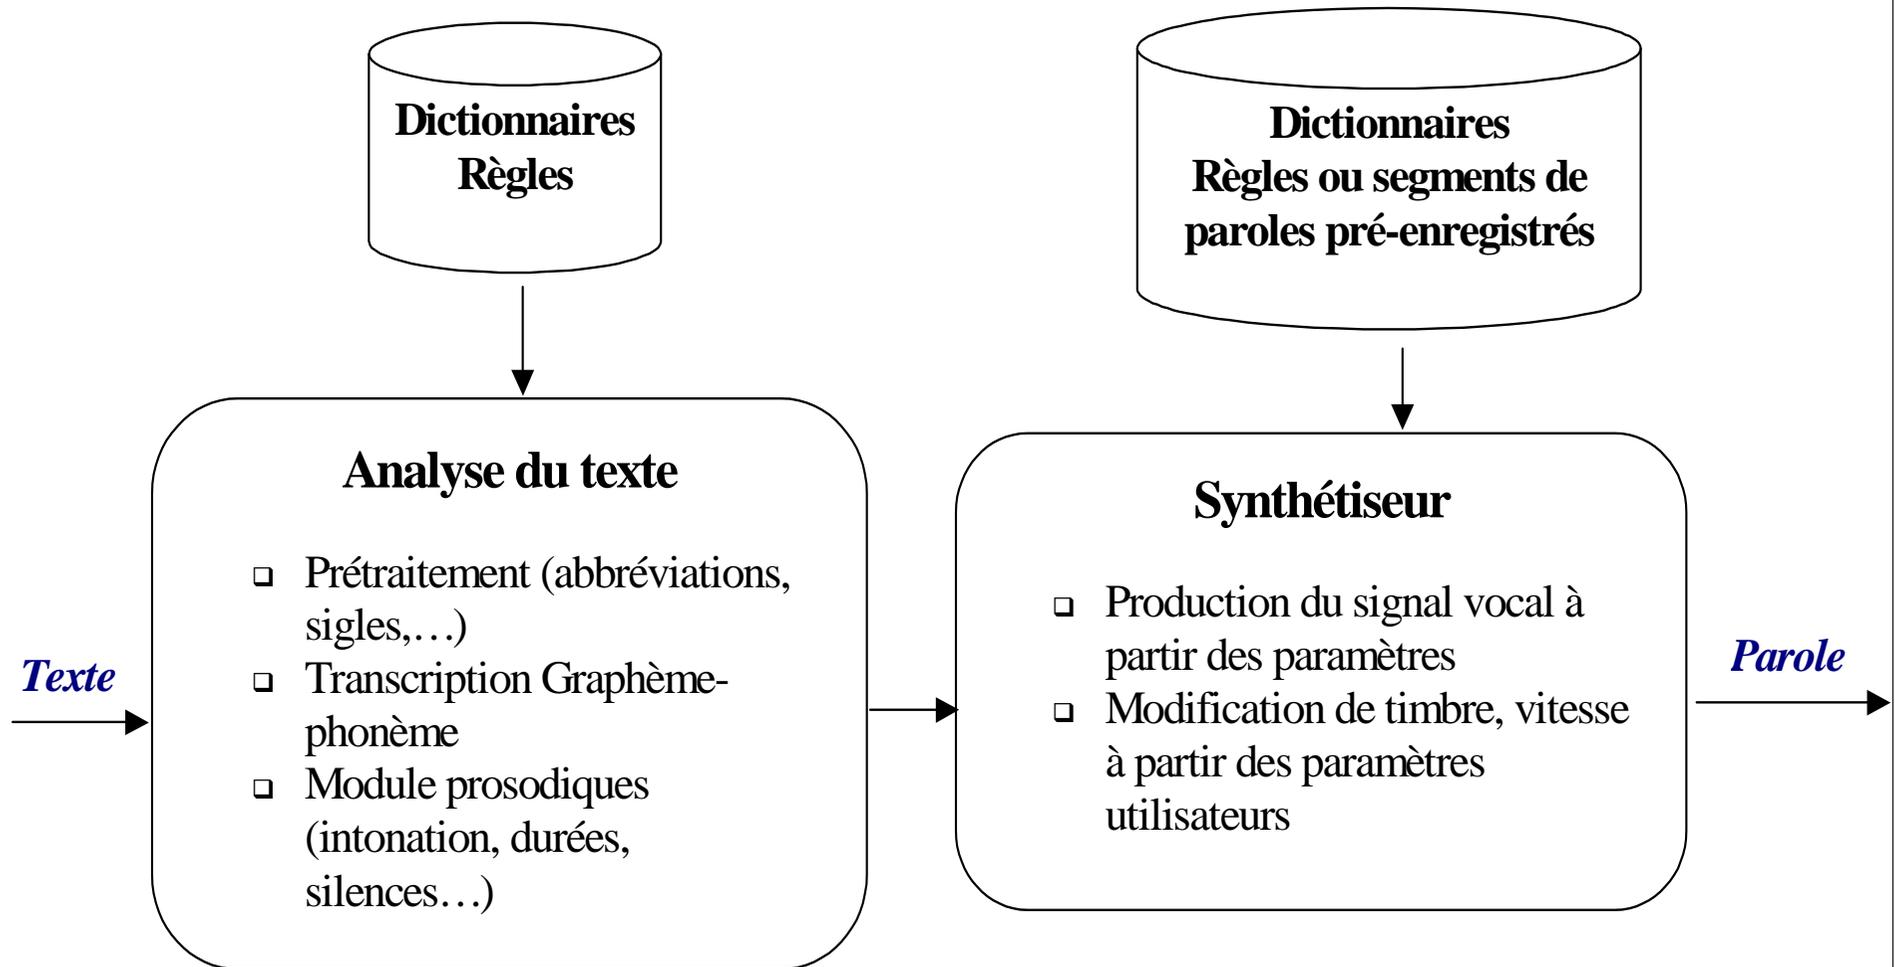
- ❑ Le « communicator » (CMU) 
- ❑ Proverbe (synthèse en français par concaténation de diphones)



- ❑ Synthèse en français (Loquendo) 
- ❑ Synthèse en anglais (Bell Labs) 

- ✓ Pour plus de démos:
  - <http://www.elan.fr/demos/interactive.html>
  - <http://caruso.naturalvoices.com/demos/>

# Architecture d'un système TTS



# Pré-traitement du texte

- Traiter les acronymes, les abréviations, les chaînes alpha-numériques « mixtes »:
  - ✓ Détection de la fin de phrase (localisation du point)
    - Problèmes avec les nombres, dates, abréviations, acronymes...
  - ✓ Traitement des abréviations
    - C-à-d, etc. kg. ...
    - 'Dr. Jones lives at the corner of Jones Dr. And St. James St.'
  - ✓ Traitement des acronymes
    - Prononçable (OVNI,CNET) vs non prononçable (CPAM,SNCF)
  - ✓ Les nombres (nombre rationnel 3.14, heure 3.30, date 30.3.2001...)

**Quelques principes généraux et beaucoup de règles ad-hoc**

# Pré-traitement du texte: Exemple

Hi Gael,

➤Answer to <mailto:gael.richard@enst.fr>

➤Hi Bernd,

for some reason the automatic redirect does not seem to work for you (or at all?... -);. Anyway, this is the correct URL:

<http://www.ims.uni-stuttgart.de/~moehler/ISCA-SynSIG/>

Sorry about the inconvenience.

Best regards

Bernd

---

Dr. Bernd Möbius, Assoc. Professor  
Institute of Natural Language Processing - Experimental Phonetics  
University of Stuttgart, Azenbergstr. 12, D-70174 Stuttgart, Germany

Phone: +49 711 121 1381; Fax: +49 711 121 1366

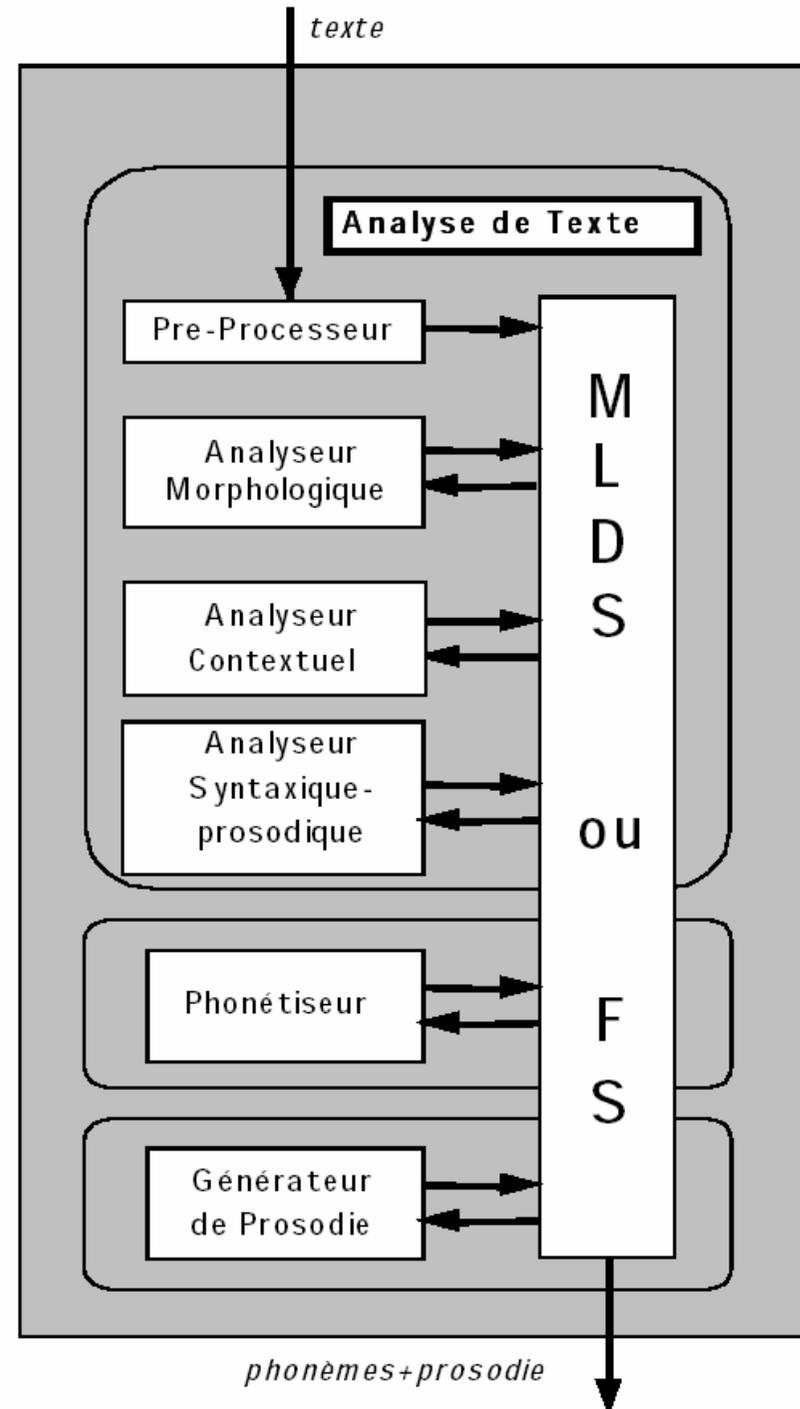
Email: [Bernd.Moebius@IMS.Uni-Stuttgart.DE](mailto:Bernd.Moebius@IMS.Uni-Stuttgart.DE)

Web: <http://www.ims.uni-stuttgart.de/~moebius>

# Analyse linguistique

(d'après T. Dutoit)

- Inclut:
  - ✓ L'analyse morphologique
  - ✓ L'analyse contextuelle
  - ✓ L'analyse structurale
- L'analyse linguistique est essentielle pour:
  - ✓ La transcription graphème-phonème
  - ✓ La prosodie (intonation, rythme, durée)



# Analyse morphologique

## □ 2 catégories de mots:

- ✓ **Les mots grammaticaux (env. 1000):** qui forment le squelette syntaxique de la phrase (déterminants, pronoms, prépositions, conjonctions)
  - Mémorisés dans un lexique qui associera leur graphie et leur prononciation...
  
- ✓ **Les mots lexicaux (en nombre a priori infini)**
  - Décomposition en morphèmes
    - Morphème = unité abstraite (morphème grammatical, etc..)
    - Ex: « soit » combine le morphème 'être' et le morphème du conditionnel présent (3ième pers. Sg.)

# Analyse morphologique

## □ Morphologie inflectionnelle:

- ✓ Tient compte des caractéristiques morphologiques telles que le genre, le nombre, le mode, le temps,...
- ✓ Ex: image – images

## □ Morphologie dérivationnelle:

- ✓ Etudie la construction des mots de catégories syntaxiques différentes à partir d'un morphème de base
- ✓ Ex: image, imagine, imagination, imagerie

## □ Morphologie Compositionnelle:

- ✓ Explique comment plusieurs morphèmes peuvent se composer
- ✓ Ex: porte + avions = porte-avions

# Analyse morphologique

## □ Inflexion-dérivation

**Lexème:** groupe\_d\_inflexion, racine\_1, ..., racine\_N

**groupe\_d\_inflexion:** mode\_d\_inflexion\_1, groupe\_de \_suffixe\_1, i, j,..k  
mode\_d\_inflexion\_2, groupe\_de \_suffixe\_2, l, m,...n

**Groupe\_de\_suffixe\_1:**suffixe\_11, ....suffixe\_1N,

Exemple:

tenir: venir, tien, ten, tienn, tin, tîn

venir:           indicatif\_présent, suf\_ind\_prés, 1, 1, 1, 2, 2, 3  
                  subjonctif\_présent, suf\_subj\_prés, 3, 3, 3, 2, 2, 3  
                  etc..

je tiens, tu tiens, il tient, nous tenons, vous tenez, ils tiennent

Que je tienne, que tu tiennes, que nous tenions, que vous teniez, qu'ils tiennent  
etc...

# Analyse morphologique

## □ Intérêts en TTS

- ✓ Permet de réduire la taille des lexiques
- ✓ Permet d'obtenir des informations sur la catégorie syntaxique des mots et a ainsi une grande influence sur la prosodie
- ✓ Permet d'aider la traduction graphème phonème (par exemple : présupposer)
- ✓ Pour certaines langues (allemand), permet de prédire la position de l'accent. En allemand l'accent tombe souvent sur la première syllabe de la racine d'un mot (ex: '*Band, Ver'Band*)

# Analyse contextuelle

- But: réduire le nombre de catégories possibles pour chaque mot en fonction de ses voisins et fournit un étiquetage de chacune des unités lexicales constituant la phrase
  
- Ex:
  - ✓ **le** : peut être pronom ou déterminant
  - ✓ **Joue**: peut être un verbe ou un nom
  - ✓ **Président, couvent** : nom ? Ou verbe ?

# Analyse syntaxique

- ✓ **Règles heuristiques**, traduction de règles grammaticales standards:
  - complexes.
  - Requiert une grande expertise de la langue
- ✓ **Grammaire probabiliste**:
  - toutes les successions de catégories grammaticales dans une langue donnée ne sont pas équiprobables.
  - On recherche dans l'ensemble des successions possibles de catégories grammaticales la succession de catégories la plus probable (étiquetage n-grammes)
  - Connaissance minimale de la langue à traiter...
  - Nécessite de grosses bases de données.

# La transcription orthographique-phonétique

## □ Transformer un texte orthographique en liste de phonèmes

- ✓ On utilise un `` alphabet phonétique " qui spécifie les sons élémentaires de la langue française.
- ✓ Le français compte 16 sons vocaliques, 17 sons consonantiques et 3 semi-voyelles.
- ✓ Difficile (en français)

## □ Appellations équivalentes

- ✓ Phonétisation automatique
- ✓ Traduction graphème-phonème

# La transcription orthographique-phonétique

## □ Des règles phonologiques complexes:

- ✓ `x' : [ks] axe, [s] six, [z] sixième, [gz] exact
- ✓ `s': [z] doser, [s] parasol entresol, [ ] ...
- ✓ `ch': [k] chlore, [ʃ] château,
  
- ✓ [ai]: mère, fête, fer, peine, sept, aspect, est, relais, tramway, laid, monnaies
- ✓ [o] pot, peau, auréole,...

# Homographes hétérophones

## □ Mots qui s'orthographient de la même façon mais se prononcent différemment.

- ✓ Moins fréquente que les homographes homophones...
- ✓ Le français standard comprend environ 150 homographes hétérophones
  - Fréquents: mêmes racines:
    - un président /ils président
    - somnolent / ils somnolent
  - Rares: racines différentes:
    - les portions / nous portions
    - les fils / les fils

# Les assimilations

## □ Importante source de variation phonétique

- ✓ 'Absent' prononcé *apsent*
  
- ✓ *Harmonisation vocalique*
  - *[e] peut devenir [« ai »]*
    - *Ex céderait, événement*
  
  - *[« ai »] peut devenir [e] devant [i], [y], ou [e]*
    - *Ex: aimer*

# Les liaisons

- Phonèmes apparaissant à la frontière de mots
  - ✓ Le français est un cas à peu près unique
  
- Le nombre de liaisons effectuées dépend du niveau de langue
  - ✓ Mais certaines liaisons sont obligatoires
    - *Très utiles*
  - ✓ D'autres sont optionnelles
    - *Deux à deux*
  - ✓ D'autres sont interdites
    - *Plat exquis*
  
- La présence d'une liaison dépend des classes syntaxiques des constituants

# Problème du « e » muet

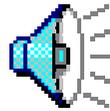
- Problème complexe !!
- Règle des 3 consonnes
  - ✓ Un « e » est prononcé si sa disparition provoque le rapprochement de 3 consonnes
    - Ex: *table rouge*
  
- Plus complexe en pratique:
  - ✓ « e » sera également prononcé devant un *h* aspiré
    - Ex: *le héros*
  - ✓ Parfois au début des groupes rythmiques (Ex. *pesez-les*)
  - ✓ Contraintes rythmiques lorsque plusieurs « e » muets sont en série
    - Ex: *ce que je ne te redirai pas*

# Noms propres / Noms de lieu/ Nouveaux mots

- ❑ Règles phonologiques différentes de celles du français standard
  - ✓ *Guebwiller, Schiltigheim,*
  - ✓ *Ploumanach*
  - ✓ *Reagan, Lendl, Pierce, Washington, etc...*
  
- ❑ Détection de la langue source
  - ✓ *Revolver, football etc..*
  
- ❑ Nouveaux mots:
  - ✓ Utilisation des racines connues

# Exemples avec le synthétiseur d'Acapela

- Sandwich, walkman, schlumberger, Reagan, Clinton, Blair, Trebeurden,



- BRAUX Bertrand, BROUCHERY Hervé, CALEF Emmanuel, CHAILLOU Sylvain, DISCAMPS Nicolas, DUEE Raphaël, DUFOURNIER Jules, DURAND Nicolas, GOLDBERG Raphaël, GUERILLON François, GUIBERT Emmanuelle,



- KUNZ-JACQUES Sébastien, MEULOT Benoît, ROLAND Flavien , VANDEPUTTE Bertrand, VAUDAINE Eric



# Transcription orthographique-Phonétique

## □ 2 approches principales

### ✓ Phonétisation par dictionnaire

- Concentration de connaissances morphologiques dans un lexique
- Adjonction de règles morphologiques permettant de déduire la prononciation des formes fléchies par dérivation, inflexion ou composition
- Dans cette approche seuls les mots non phonétisés par le dictionnaire sont alors transcrits par règles
- Approche traditionnellement suivie pour l'anglais américain (MITALK)

### ✓ Phonétisation par règles

- Concentration des connaissances phonologiques dans des règles
- Seuls les exceptions sont placés dans des lexiques

# Transcription Orthographique-Phonétique

- Automate utilisant des règles de réécriture associant un (groupe) phonème à un (groupe) caractère(s) orthographique(s)
  - ✓ Prendre en compte le contexte gauche et le contexte droit
  - ✓ Ces règles sont organisées de façon hiérarchique, des règles les plus particulières aux règles les plus générales.
  
- ✓ Exemple de règles (phonologie générative)
  - $a \rightarrow b/l\_r:c$
  - « le segment  $a$  est réécrit en un segment  $b$  lorsqu'il est entouré des chaînes  $l$  et  $r$  (à gauche et à droite) et si la condition  $c$  est vérifiée.

# Exemple

Le mot "oiseau" se transcrit phonétiquement " /wazo/ ", par application des règles suivantes:

1. La chaîne de caractères orthographiques "oi" se transcrit par la succession des phonèmes /wa/, parce qu'elle est précédée d'un séparateur de mot et qu'elle n'est pas suivie de la chaîne "gn" comme dans "oignon", ou d'un "n" comme dans "oindre".
2. La lettre "s" se transcrit par le phonème /z/ car cette lettre est entourée par deux voyelles et que "oiseau" ne fait pas parti d'une liste d'exceptions à cette règle, stockée dans le lexique (on pense en particulier à "paraSol" ou "vraiSemblance").
3. La chaîne de caractère "eau" se transcrit par le phonème /o/, indépendamment du contexte.

# Transcription orthographique- Phonétique



- Un système minimal = 500 règles (français)
- moins de 100 règles pour l'italien ou l'espagnol

# Génération de la prosodie

- Primordial pour le naturel de la synthèse
  - ✓ Inclut La génération des contours mélodiques
    - **Mélodie:** Changements audibles de F0
    - **Intensité:** Changements audibles de niveau sonore
  - ✓ Inclut la génération des patterns rythmiques
    - **Durée:** Changement audible de longueur syllabique
  
- Concerne principalement les caractéristiques **suprasegmentales** (liées aux syllabes ou groupe de syllabes)

# La prosodie

## □ Autres fonctions de la prosodie

- ✓ Focus et accents: on peut faire ressortir une syllabe et ainsi marquer le mot ou le groupe syntaxique qui le contient
  - Ex: un gateau de beurre suisse frais
- ✓ Segmentation: permet de faire ressortir une segmentation de la phrase parlée en groupe de syllabes

It will be <i>rainy</i> in ...	
... Boston <i>today</i> .	
... in <i>Boston</i> today	

# La prosodie



## □ Plusieurs niveaux de description

### ✓ Production

- Tension des cordes vocales
- Force
- Débit

### ✓ Perception

- Hauteur ou fréquence fondamentale (pitch)
- Mélodie
- Sonie
- Durée
- Rythme



# Segmentation en groupes prosodiques

## □ Segmentation heuristique

- ✓ Règles simples basées sur la ponctuation
  - *Ex: Le gâteau, que j'ai mangé, était excellent.*
- ✓ Améliorations en tenant compte de la distinction mot lexical/mot grammatical
  - Ex: la table  
de mon oncle  
est noire

# Segmentation en groupes prosodiques

## □ Segmentation par une analyse morphosyntaxique

- ✓ Congruence syntaxe-prosodie
- ✓ Ajouts de règles d'ajustement
  - Principe d'eurythmie

*Le père de marie est venu*

- (2+3)(2)
- (2)(3)(2)
- (2)(3+2)

# Segmentation en groupes prosodiques

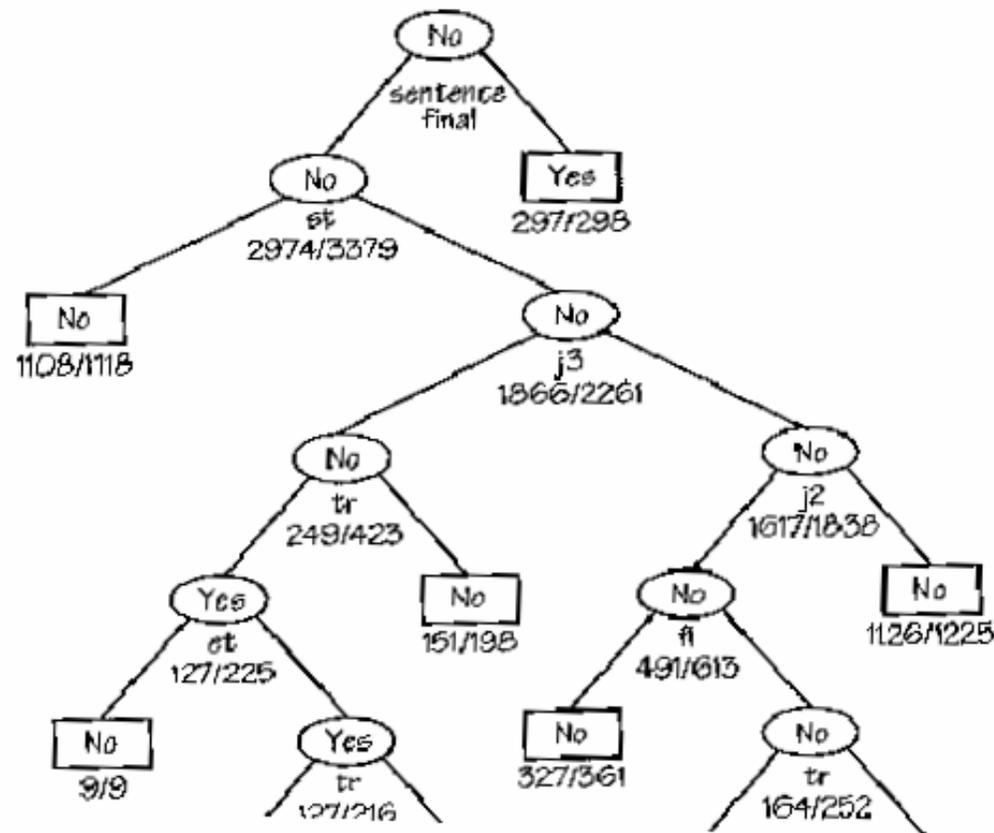
## □ Segmentation par apprentissage

- ✓ Utilisation de grands corpus => inférence automatique de règles
- ✓ Utilisation des arbres de décision: Classification and Regression Tree (CART)
  - Met automatiquement en évidence les facteurs contextuels les plus significatifs
  - Les CART travaillent sur des données symboliques (décisions) et sur des données numériques (régression)

# Segmentation en groupes prosodiques

## □ CART

- ✓ Ex: données temporelles: durées de la phrase <sup>2</sup>en secondes (tt) et en mots (ww), taux d'élocution moyen (tr),....
  - Données syntaxiques: catégories grammaticales des quatre mots autour de la frontière potentielle (j1,j2,j3,j4),.....

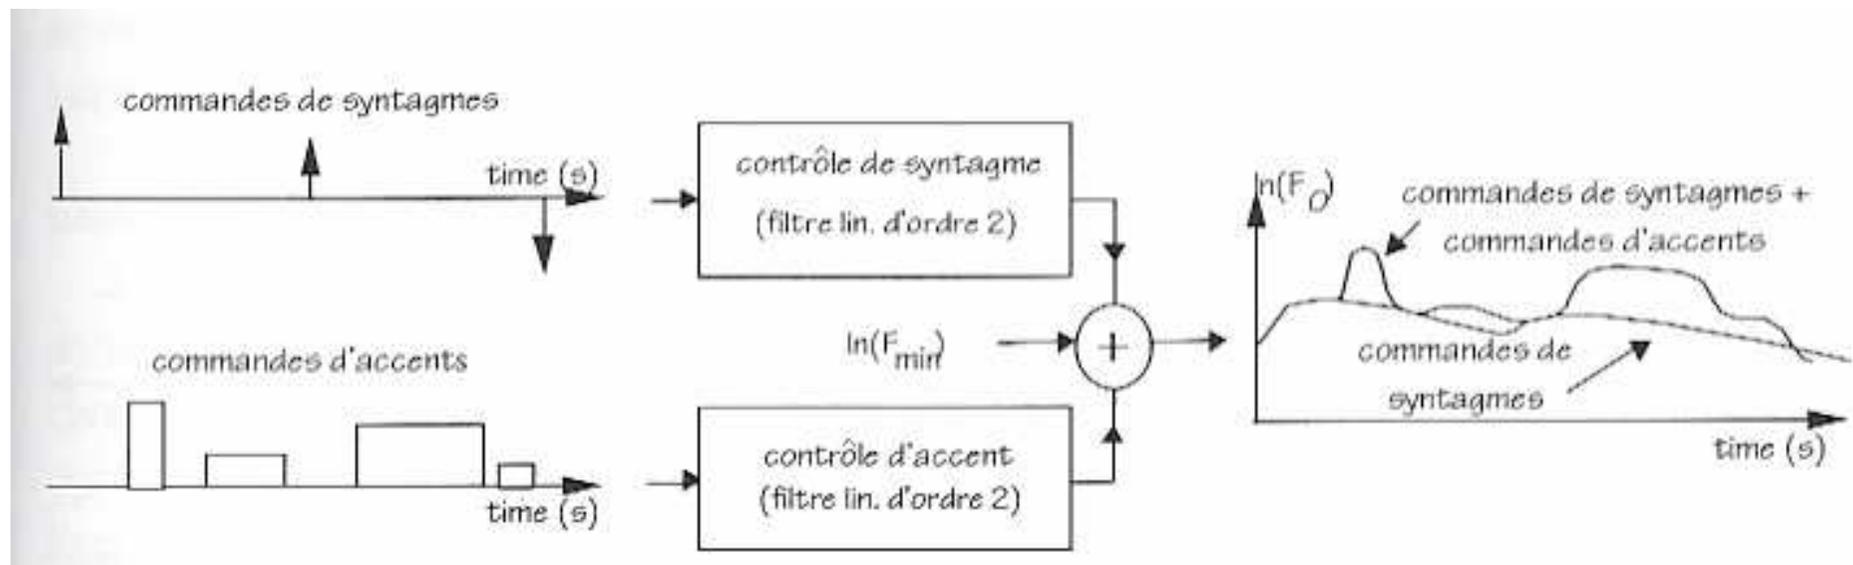


# Placement automatique des accents

- ✓ Mots non clitiques (pouvant prendre un accent) / mots clitiques (ne prennent en général pas d'accent) et qui sont essentiellement les mots grammaticaux
  
- ✓ Accent lexical
  - Gateau, beurre
  
- ✓ Accent d'insistance / accent grammatical
  - En français, l'accent grammatical tombe toujours sur la dernière syllabe
  - Accent d'insistance:
    - Ex: Un gateau de beurre suisse frais
  
- ✓ Utilisation de:
  - La syllabation, analyse grammaticale, morphologie,

# Génération de l'intonation

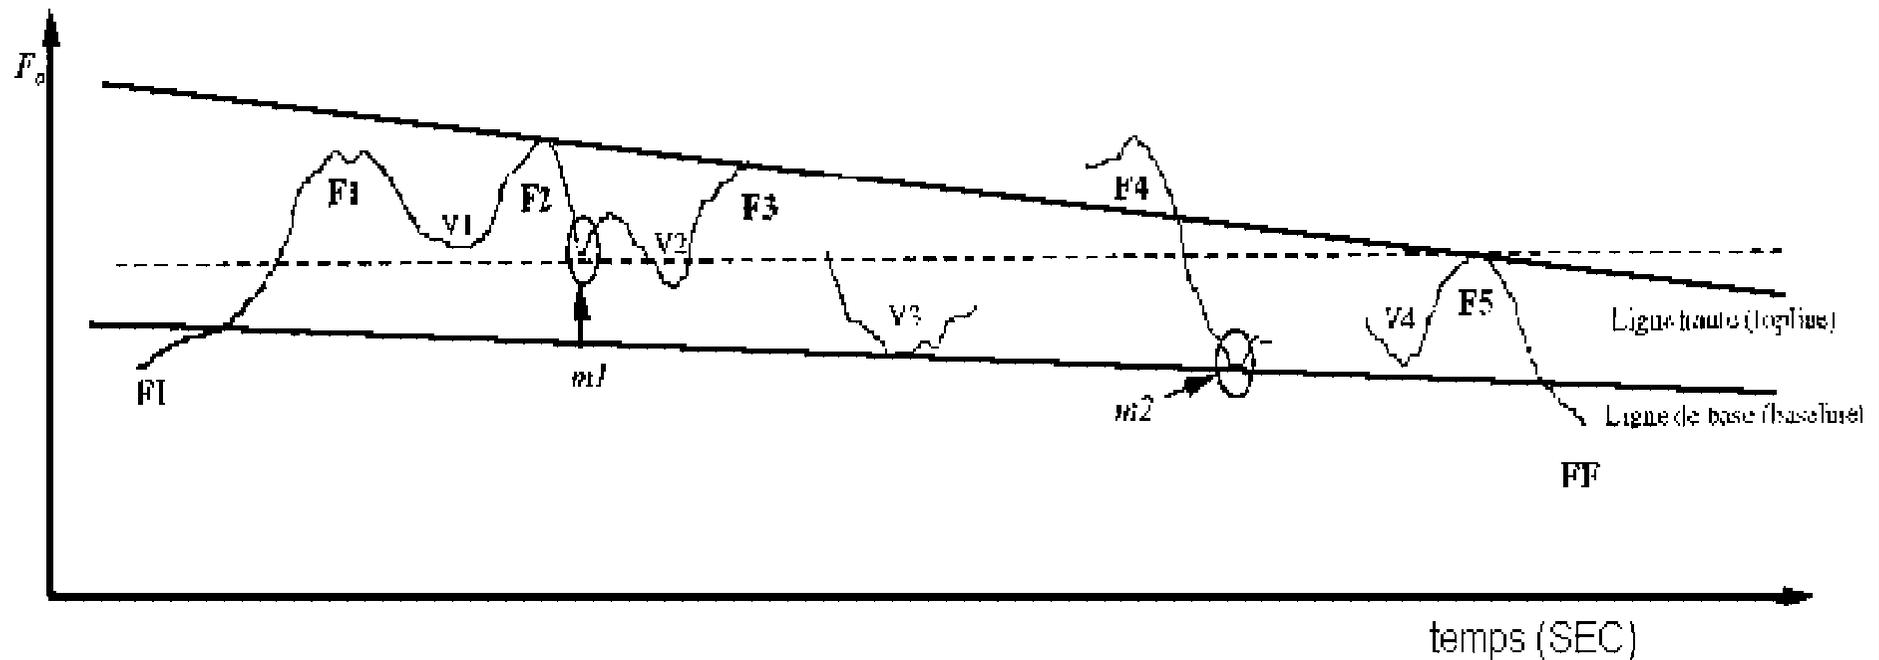
## □ Modèle de fujisaki



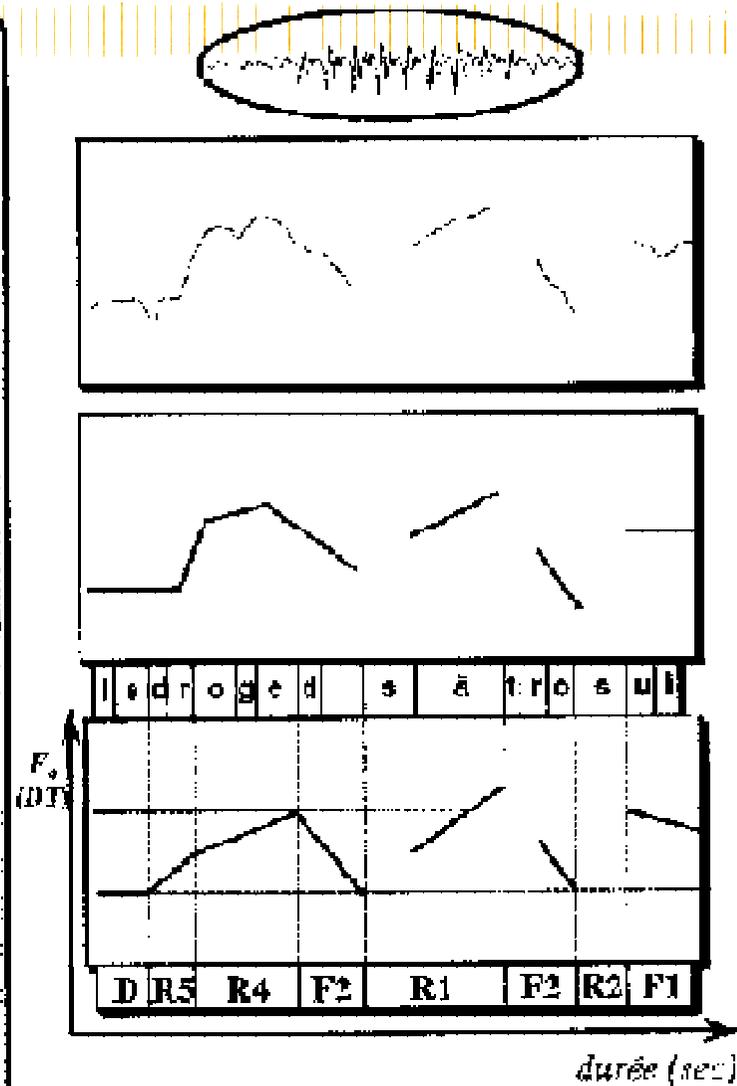
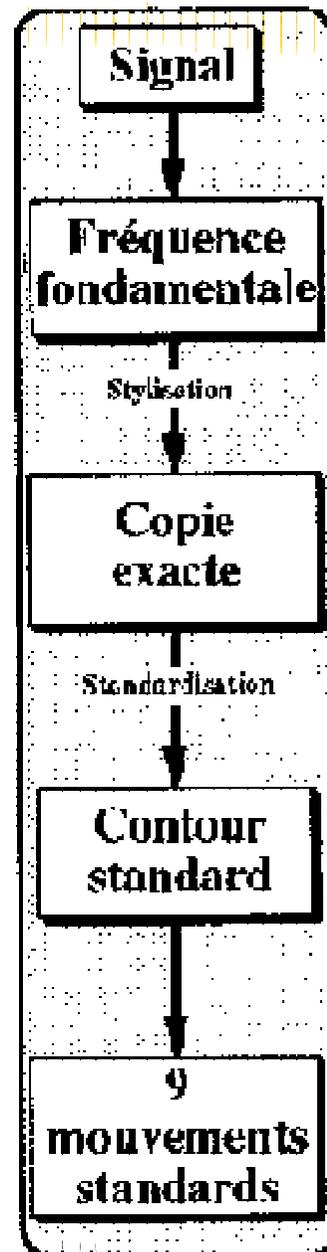
# Génération de l'intonation

## □ Stylisation (école hollandaise):

- ✓ Ligne de déclinaison, Contours standards, stylisés



# Stylisation



# Prosodie

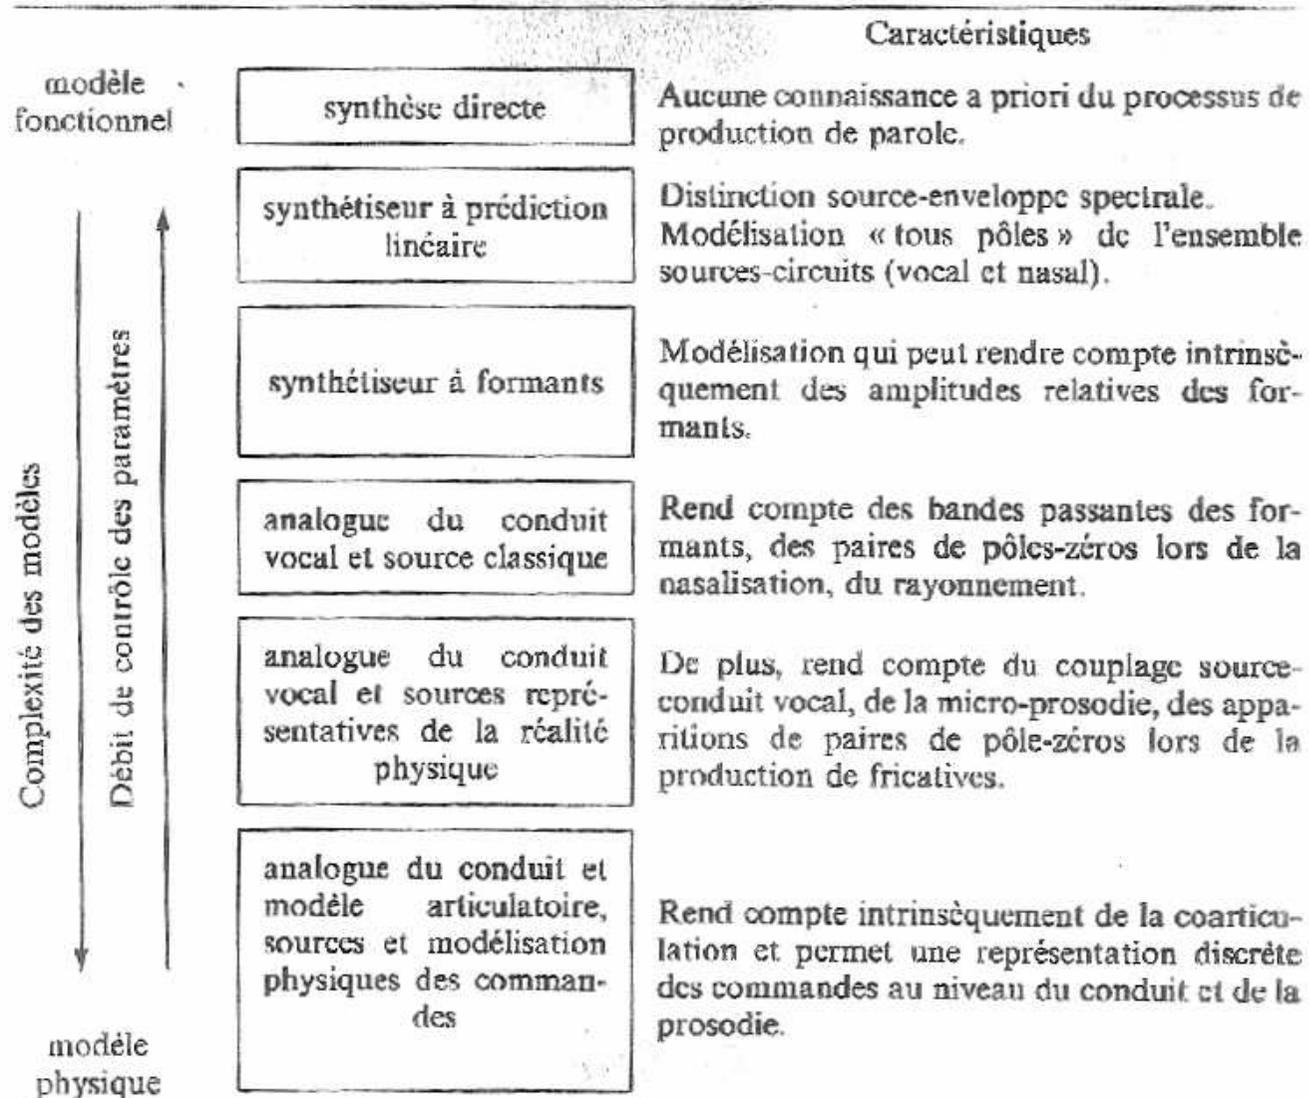
## □ Exemples

Pas de prosodie	
Ligne de déclinaison	
Ligne de déclinaison + accent	
Prosodie (modèle statistique)	

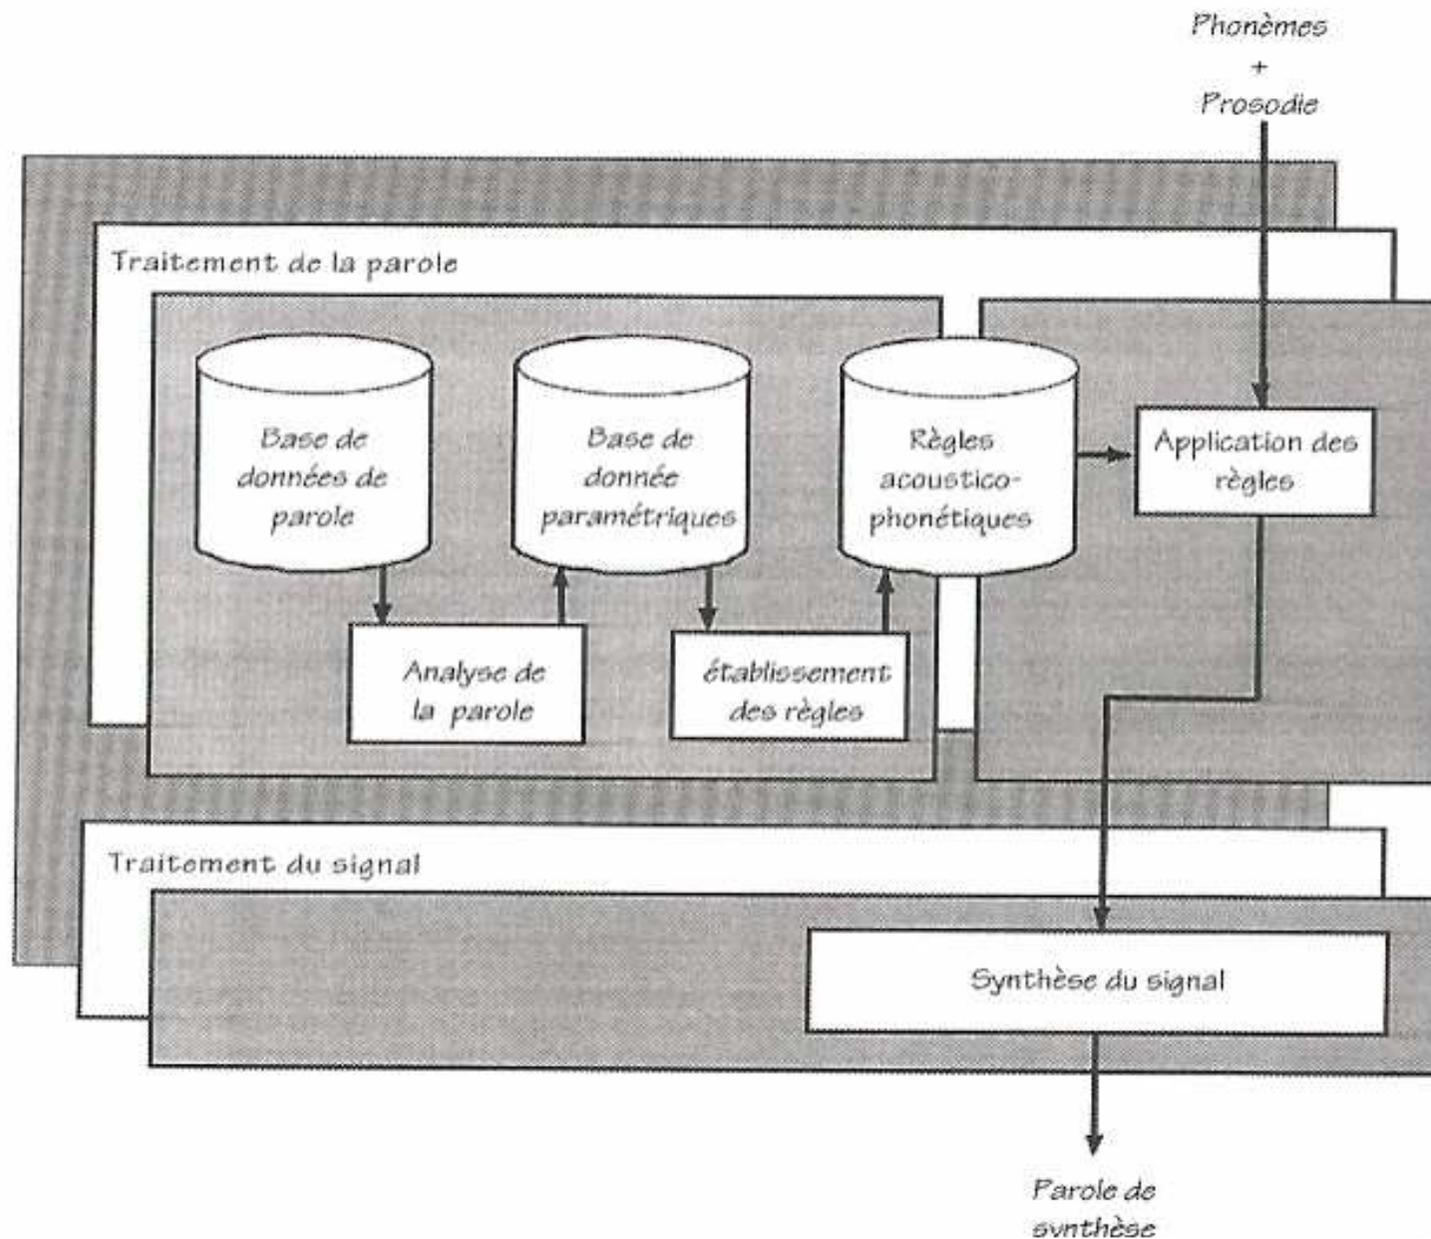
# Modèles de durées

- 4 sources d'information
  - ✓ Informations de phonéticiens (principes articulatoires ou phonologiques)
  - ✓ Informations d'explorations statistiques
  - ✓ Estimation de paramètres basée sur des expériences où un petit nombre de paramètres varient
  - ✓ L'estimation de paramètres basée sur des expériences de grande ampleur (utilisation de corpus de grande taille)
  
- Approche couramment retenue
  - ✓ Estimer les durées intrinsèques (valeurs moyenne sur un grand corpus)
  - ✓ Modifier ces durées en faisant intervenir des facteurs co-intrinsèques (durées des phonèmes voisins) et linguistiques
  
- Evolution vers les modèles généralistes (CART, réseaux de neurones, ...)

# Synthèse: classification des techniques

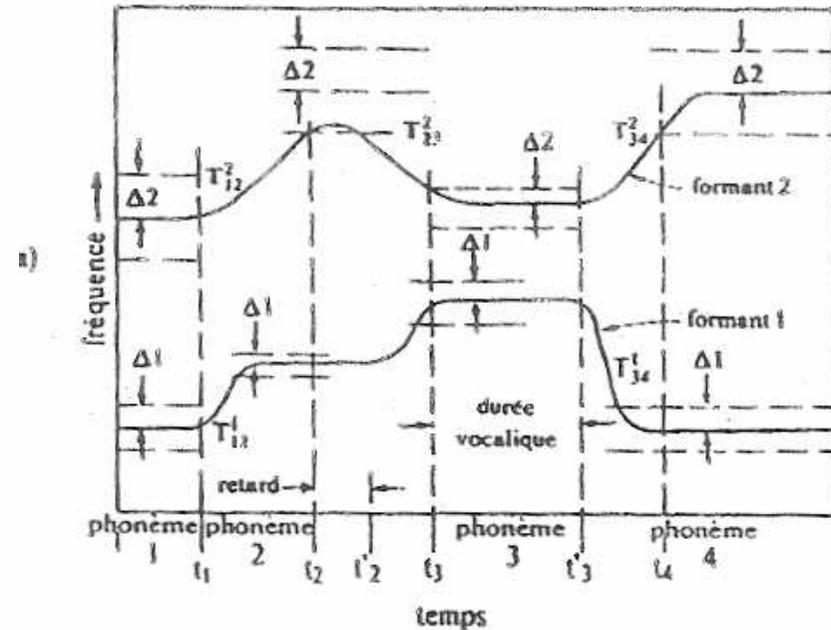
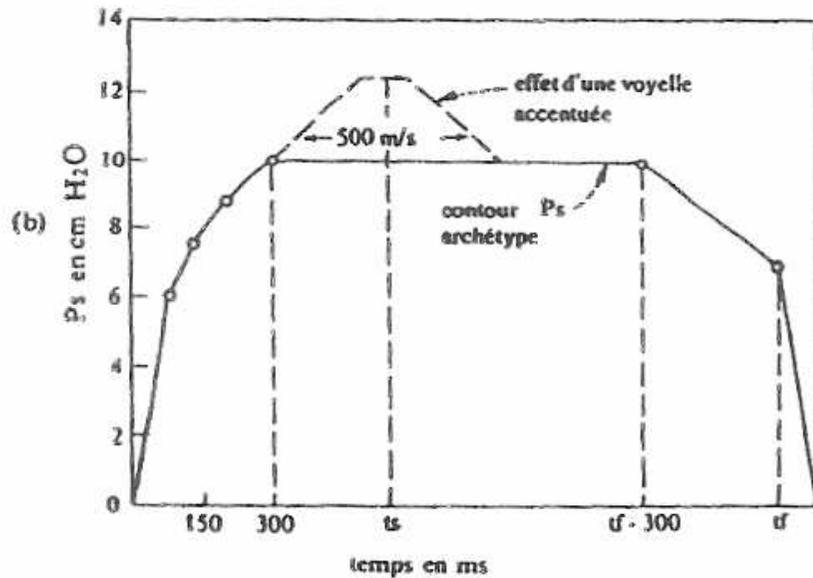
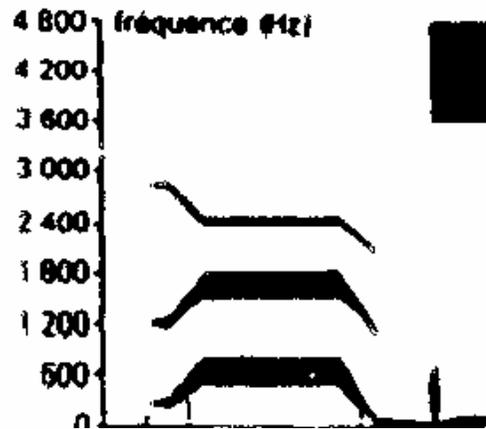


# Synthèse par règles



# Synthèse par règles

- ✓ Modélisation des transitions entre phonèmes sous forme de règles. Utilisation de valeurs-cibles



# Exemples de règles

## □ KTH

### TIMING OF PITCH CHANGE

60.00: <VOK,A>0 ^ <D:=F0-X> / & <KONS>(,) <VOK,X:=F0>

60.10: <KONS> ^ <D:=Y-X> / <VOK,Y:=F0> & <VOK,X:=F0>

### F0 CHANGE

60.20: <KONS> ^ <F0=X,TF0=0> / & <VOK,X:=F0> <SEG>

60.21: <KONS> ^ <F0=X,TF0=0> / <VOK> & <\,X:=F0,DR<20>

60.30: <KONS,+OBST> ^ <F0:=X-2,TF0=.1\*DRMS-2> / & <VOK,X:=F0>

60.40: <KONS,-VOICE> ^ <F0:=X> / <KONS> & <VOK,X:=F0>

### MARCATO

60.50: <VOK,D>0,BIND=0 ^ <LF0:=X-2,TLF0=.1\*DRMS-6> / & <VOK,X:=F0>

60.99: <SEG> ^ <D=#>

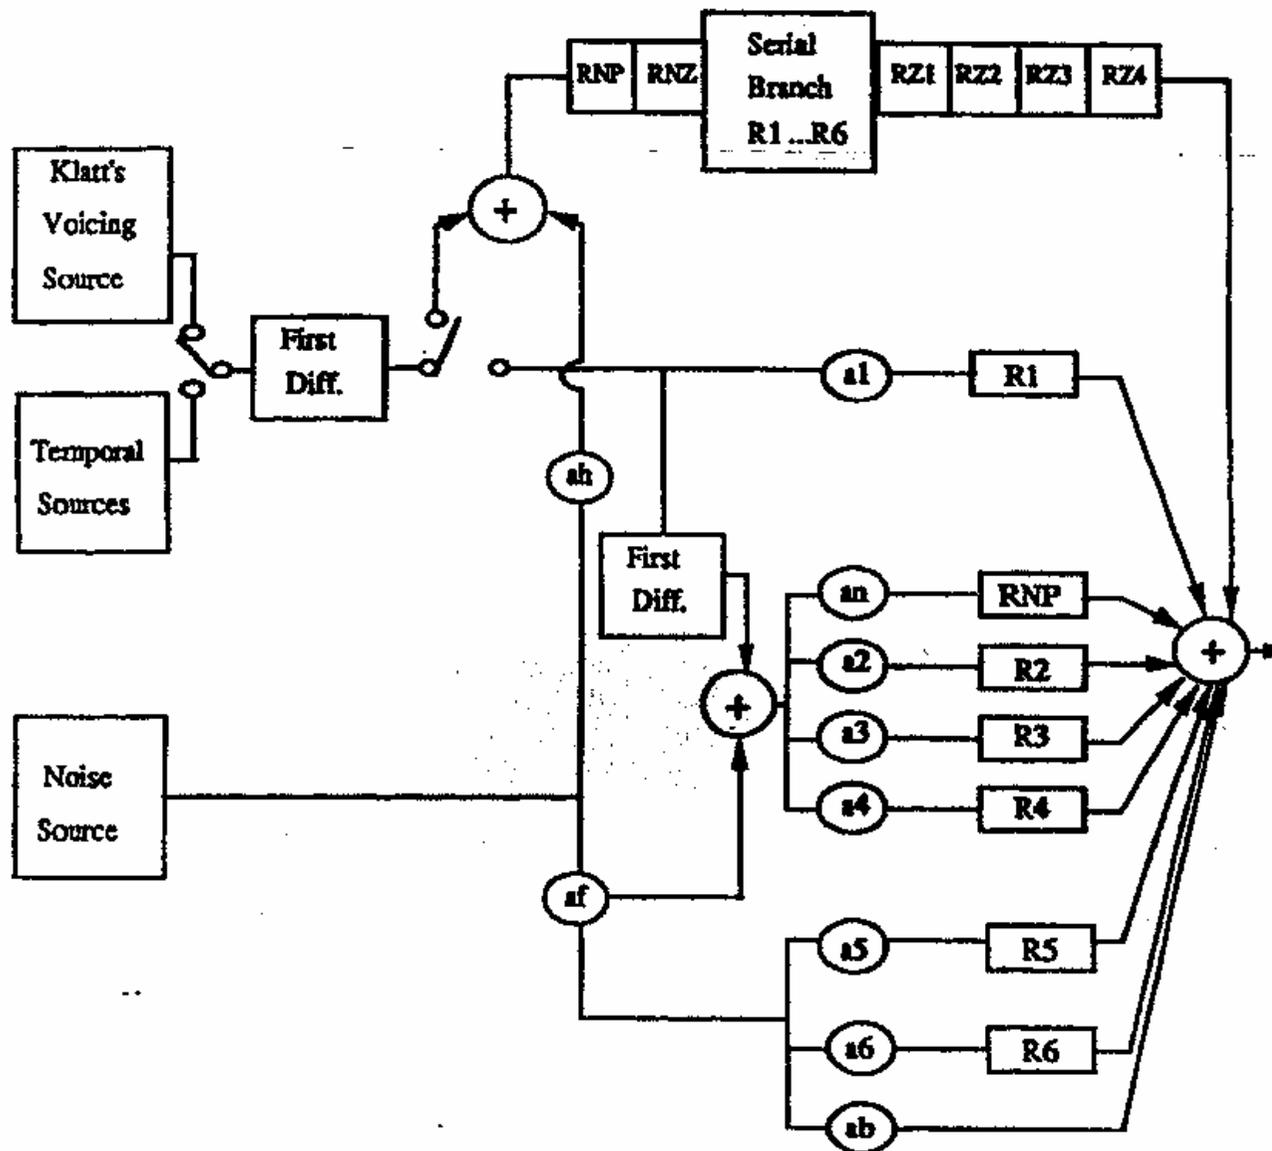
### FORMANT FREQUENCIES

65.00: S ^ <F1=80,F2=132> / & <VOK,+BACK>

65.05: <VOK,+HIGH> ^ <TF5=-1> / S &

65.10: F ^ <LF1:=X,TLF1=.1\*DRMS-2> / & <VOK,X:=F1>

# Architecture série / parallèle



# Synthèse par règles

## □ Avantages:

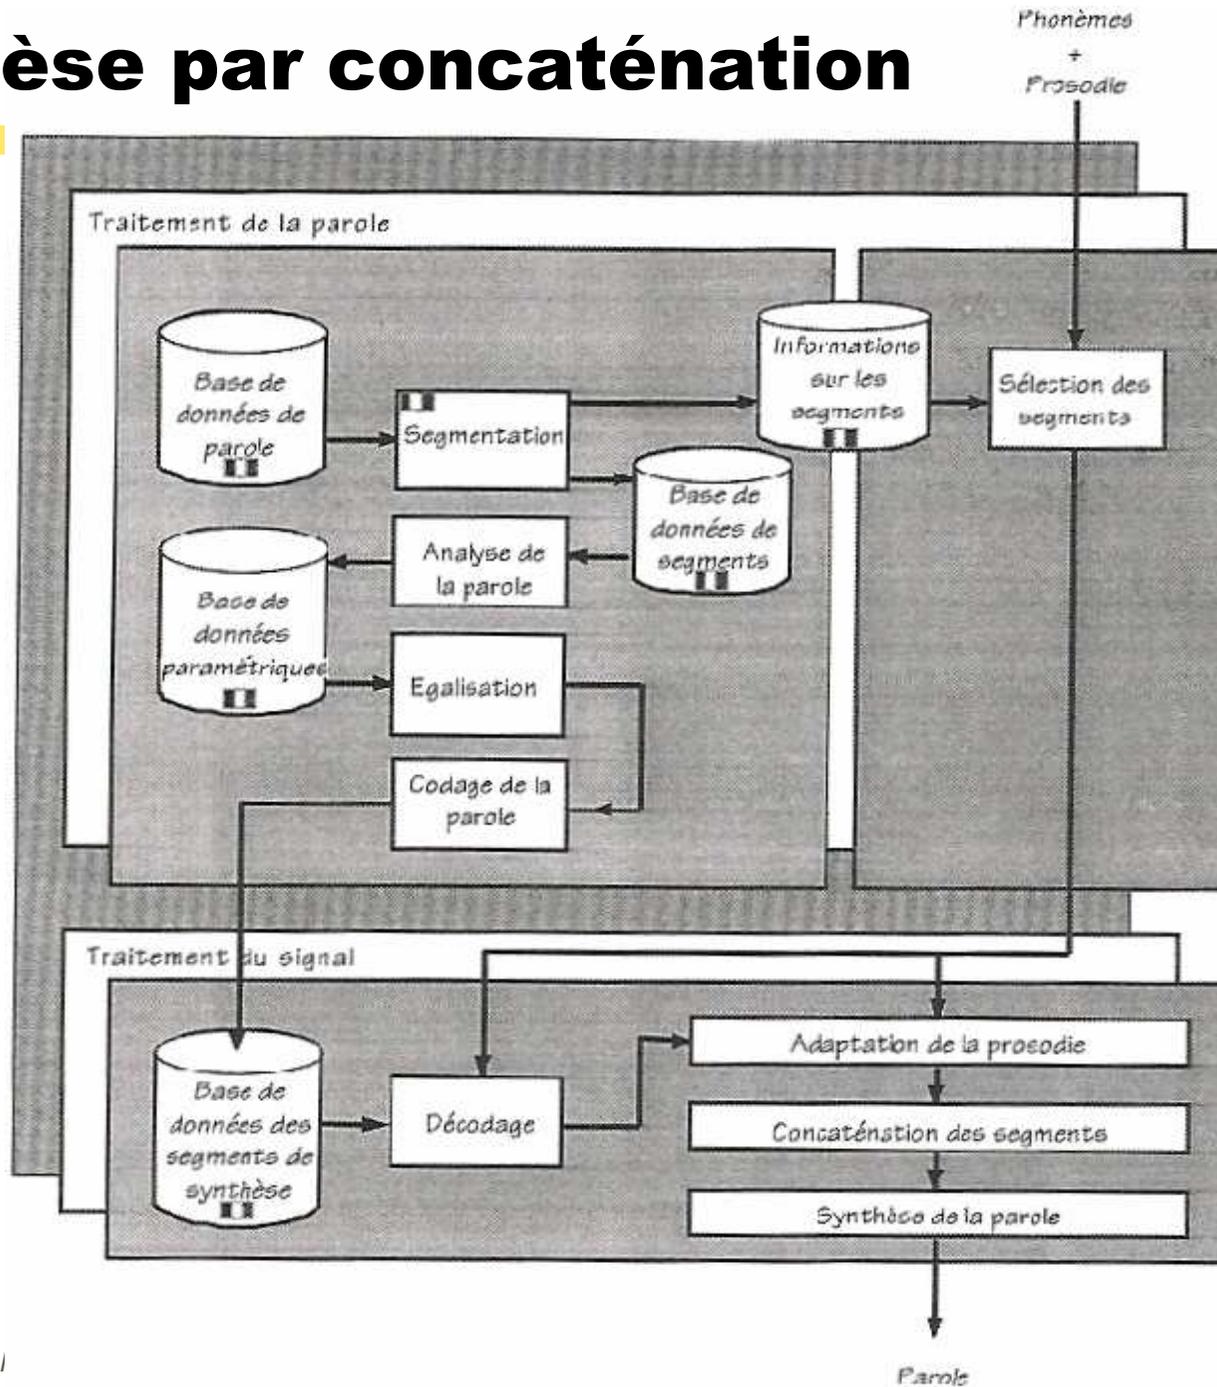
- ✓ Peu de données à stocker
- ✓ Progression des connaissances sur la parole

## □ Inconvénients

- ✓ Etablissement des règles long et fastidieux
- ✓ Règles dépendent en grande partie de la langue et en moindre partie du locuteur
- ✓ Exemple sonore (DecTalk):

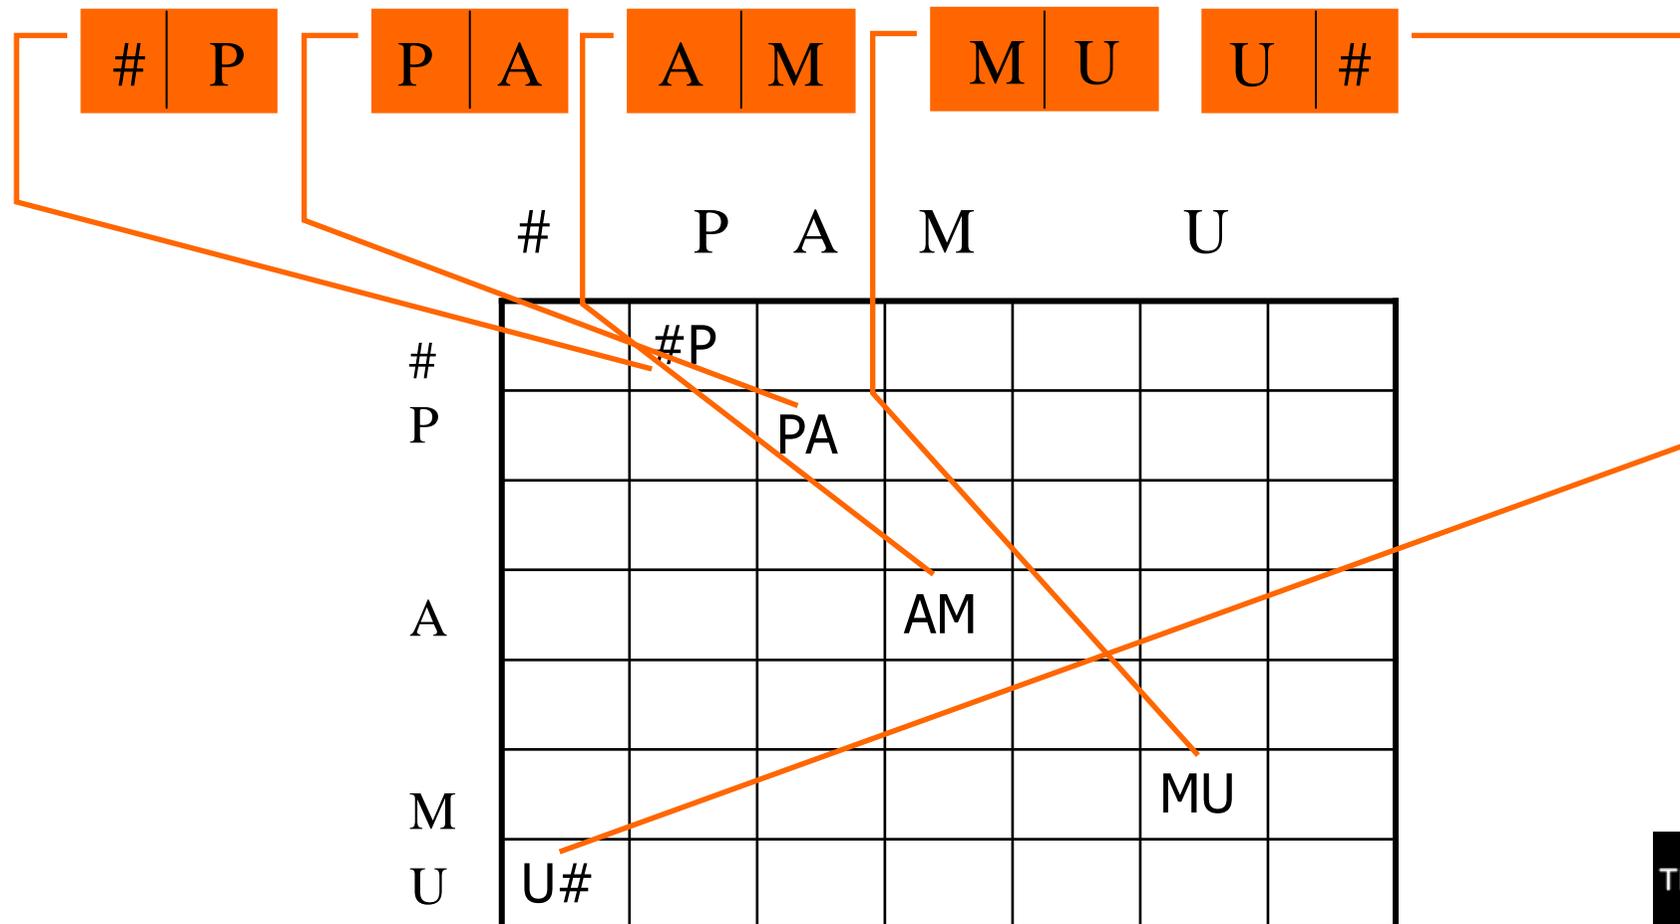


# Synthèse par concaténation



# Sélection des unités de synthèse

## □ Sélection statique (diphones)



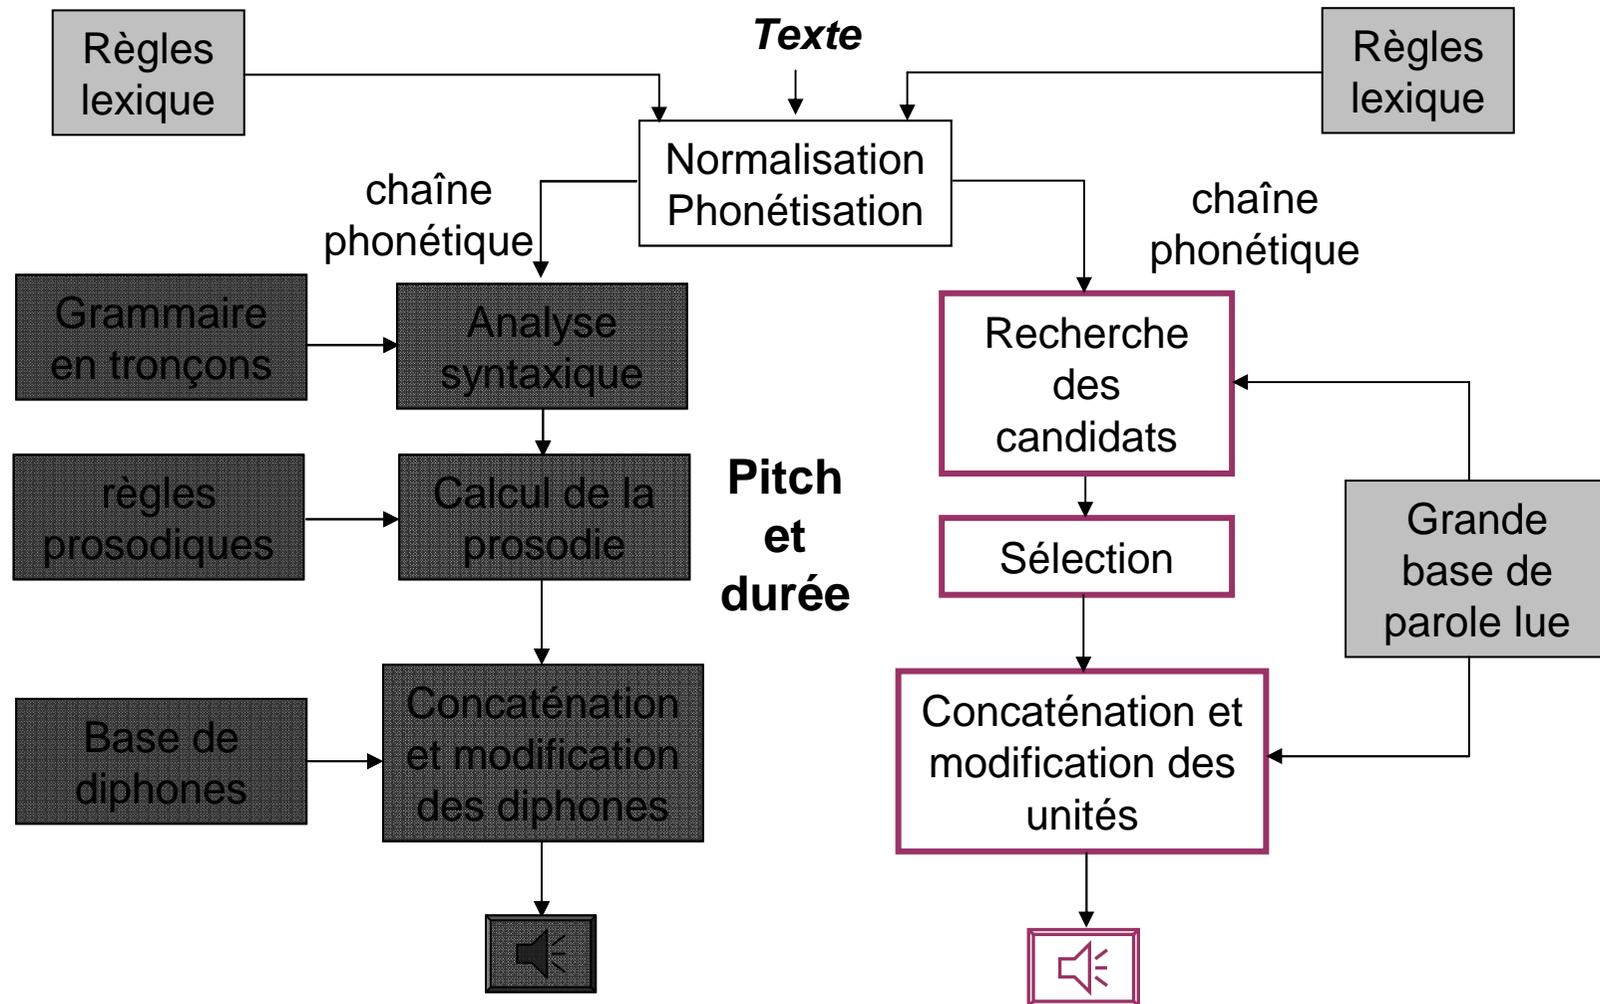
# Sélection des unités de synthèse

## □ Sélection dynamique (sélection totale)

- ✓ Minimisation d'un coût de sélection global
- ✓ Unités non uniformes
- ✓ Choix du segment de telle sorte que:
  - Le contexte est le plus proche possible de la chaîne phonétique à synthétiser
  - La prosodie se rapproche le plus possible de la prosodie à produire
  - Les extrémités ne présentent pas trop de discontinuités spectrales

=> utilisation de la programmation dynamique (Viterbi)  
dans le treillis de segments utilisables.

# Comparaison sélection dynamique / statique

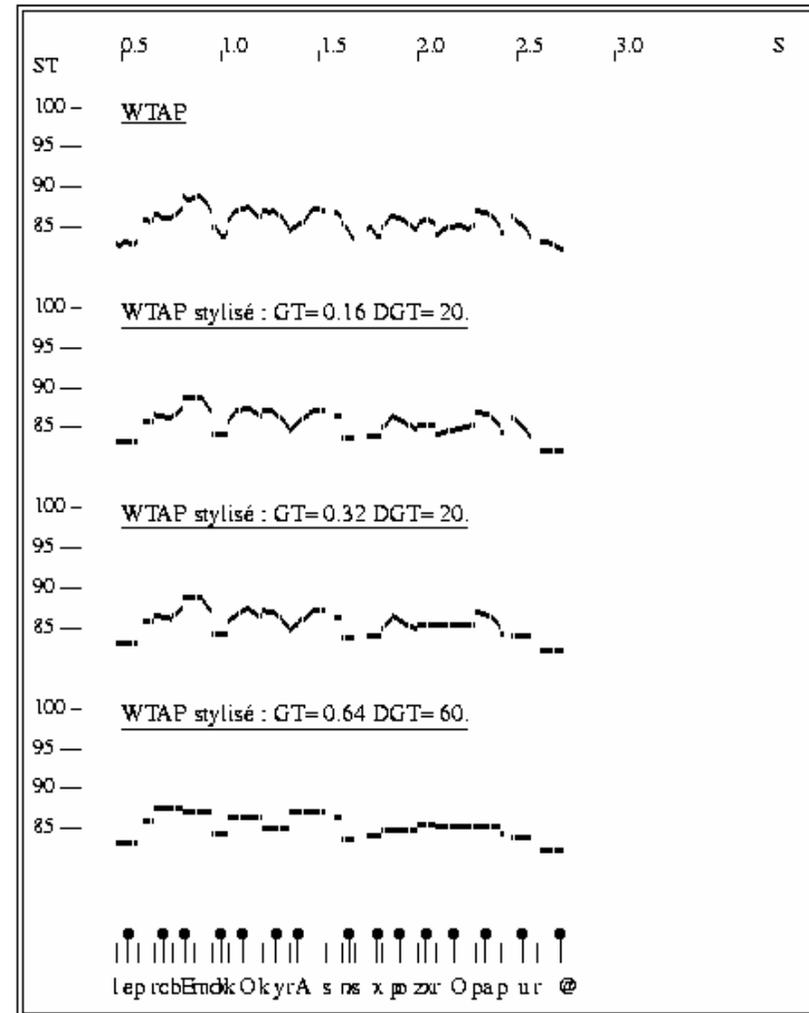


D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003

# Les bases de données : l'étiquetage

## Étiquetage complètement automatique :

- ❑ Alignement : durées + phones
- ❑ Syllabation et découpage en mots
  - ✓ outils de reconnaissance de la parole
- ❑ Calcul du pitch
- ❑ Stylisation du pitch
- ❑ Calcul de l'Énergie



*D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003*

# Principe de sélection

liste de tous les diphtonges possibles

↓  
Sélection

↓  
liste et caractéristiques des diphtonges sélectionnés

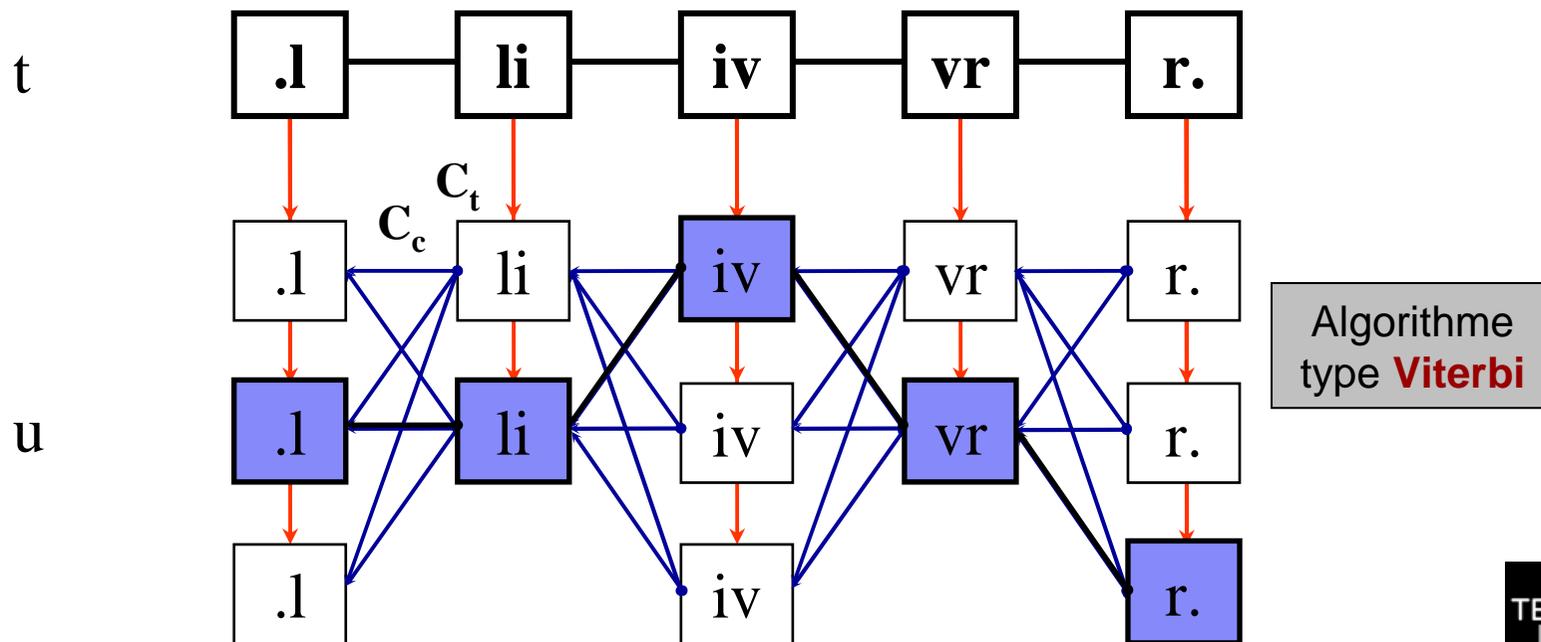
- ❑ Application de critères de **haut niveau**
  - ✓ **génériques**
  - ✓ adaptables aux différents locuteurs
  - ✓ peu nombreux
  
- ❑ **Critères phonotactiques, syntaxiques, symboliques, acoustiques**

# Algorithme de sélection

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003

- ❑ **Coût de concaténation ( $C_c$ )** : qualité de la concaténation
- ❑ **Coût de cible ( $C_t$ )** : distance entre un diphone cible et un diphone candidat

$$C(t, u) = \sum_{i=1}^n \Omega_t C_t(t_i, u_i) + \sum_{i=2}^n \Omega_c C_c(u_i, u_{i-1})$$



# Algorithme

– Initialisation

$$\begin{aligned}\delta_1(i) &= C_1 1(u_{i,1}), \quad 1 \leq i \leq N_1 \\ \psi_1(i) &= 0\end{aligned}$$

– Récursion:

$$\begin{aligned}\delta_t(j) &= \min_{1 \leq i \leq N_{t-1}} [\delta_{t-1}(i) + C_c(u_{i,t-1}, u_{j,t})] + C_t(u_{j,t}), \quad 2 \leq t \leq T-1; \quad 1 \leq j \leq N_t \\ \psi_t(j) &= \arg \min_{1 \leq i \leq N_{t-1}} [\delta_{t-1}(i) + C_c(u_{i,t-1}, u_{j,t})], \quad 2 \leq t \leq T-1; \quad 1 \leq j \leq N_t\end{aligned}$$

– Arrêt:

$$\begin{aligned}P^* &= \min_{1 \leq i \leq N_T} [\delta_T(i)] \\ q_T^* &= \arg \min_{1 \leq i \leq N_T} [\delta_T(i)]\end{aligned}$$

– Rétropropagation (chemin optimal):

$$q_t^* = \psi_{t+1}(q_{t+1}^*), \quad t = T-1, T-2, \dots, 1$$

# Sélection : coût de cible

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003

## □ Place du phone dans la syllabe

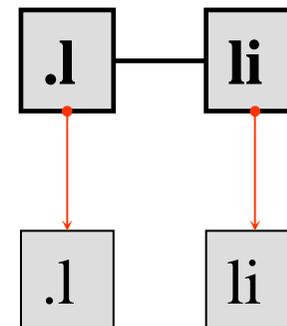
Codage	1	2	0	3	4	5	6
Position	début	fin	milieu	monophone	silence initial	silence final	?

phrase	.	l	a	k	s	A	f	i	n	a	l	.
Mot	4	3	1	0	0	2	1	0	0	0	2	5
Syllabe	4	1	2	1	0	2	1	2	1	0	2	5

$$C_t(t_i, u_i) = \sum_{j=1}^3 \omega_j^t C_j^t(u_i, t_i)$$

## □ Place du phone dans le mot

- ✓ position des accents en français : **début** ou **fin** de mot
- ✓ Forcer les accents finaux



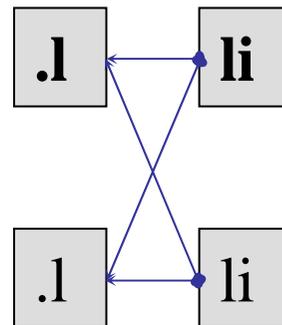
## □ Table des durées

# Sélection : coût de concaténation

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003

- ❑ Sons consécutifs
- ❑ Pitch proche
- ❑ Contexte phonétique gauche et droite
- ❑ Durée
- ❑ Énergie

$$C_c(u_i, u_{i-1}) = \sum_{j=1}^5 \omega_j^c C_j^c(u_i, u_{i-1})$$



# Sélection : coût de concaténation

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003

## □ Contexte phonétique gauche et droite

### Pour les consonnes :

- 1 **lieu** d'articulation identique (b-p)
- 2 **mode** d'articulation identique et **voisement** identique (b-d)
- 3 **mode** d'articulation identique et **voisement** différent (d-p)

### Pour les voyelles :

- 1 **position constriction** **conduit vocal** identique (e-E)
- 2 **protrusion** des lèvres identique (y-u)

### Analyse

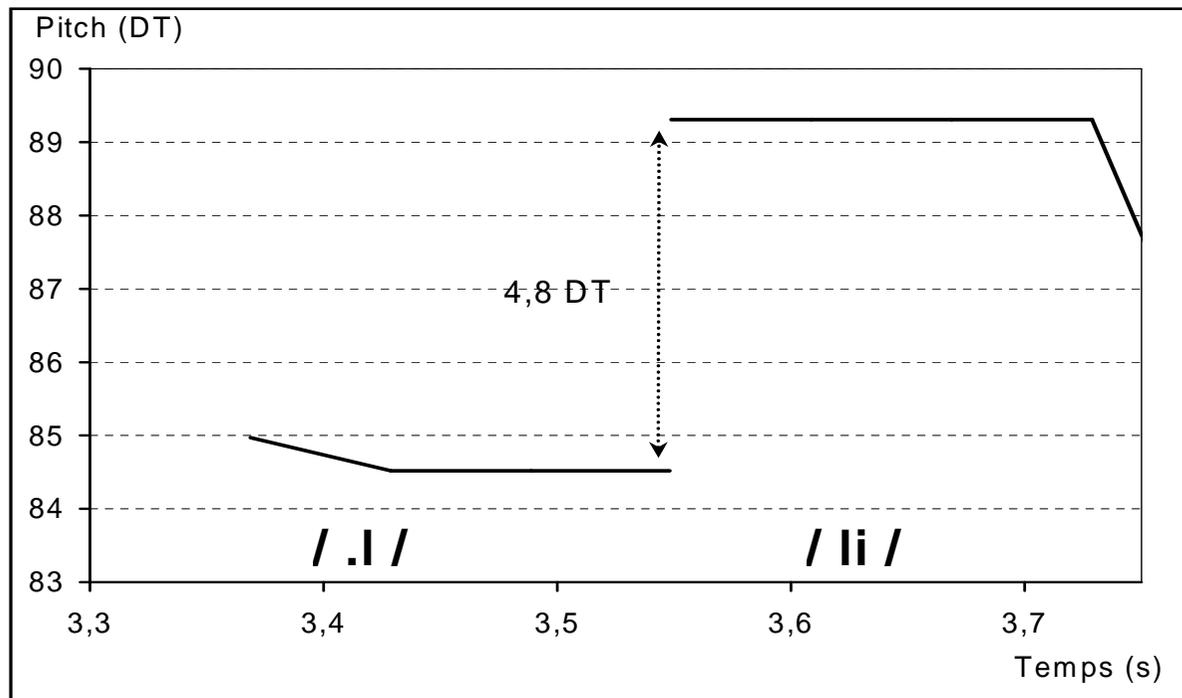
**lieu d'articulation** : cohérence de mouvement du premier et du deuxième formant

**arrondissement des lèvres** : cohérence de mouvement du troisième formant

# Sélection : coût de concaténation

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003

## □ Pitch proche



# Réglage des coûts

*D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003*

- ❑ Valeurs des coûts normalisées
- ❑ Réglage manuel
- ❑ Favorise la maximisation des chaînes
- ❑ **Les trois critères principaux réalisent 66% de la sélection**

<b>Coût de cible</b> 0,55			<b>Coût de concaténation</b> 0,45				
<b>mot</b> 0,3	<b>syllabe</b> 0,45	durée 0,25	<b>maximisation</b> 0,55	contexte 0,15	pitch 0,25	durée 0,025	énergie 0,025

*D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003*

# Exemples de sélection (1)

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003



<i>"Je me suis fait tout petit."</i>	
/ Zx mx shi fE tu pxti . /	
... étape, <b>J</b> érôme ...	/ .Z /
... et <b>je me suis</b> mis ...	/ Zx mx shi /
... Dupuis <b>y fait</b> ...	/ i fE /
... ser <b>ai</b> toujours ...	/ E t /
... et <b>tout p</b> articulièrement ...	/ tu p /
... la <b>pet</b> ite fille ...	/ pxt /
... du part <b>i</b> .	/ ti. /

# Exemples de sélection (2)

D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003



<i>"La mauvaise réputation."</i>	
/ la movEz repytasjO. /	
... elle, <b>la m</b> achine ...	/ . la m /
... au <b>mauvais</b> endroit ...	/ movEz /
... <b>puiser</b> a t'il ...	/ z r /
... sa <b>réput</b> ation, ...	/ repyt /
... nouvelle réglement <b>ation</b> .	/ tasjO./

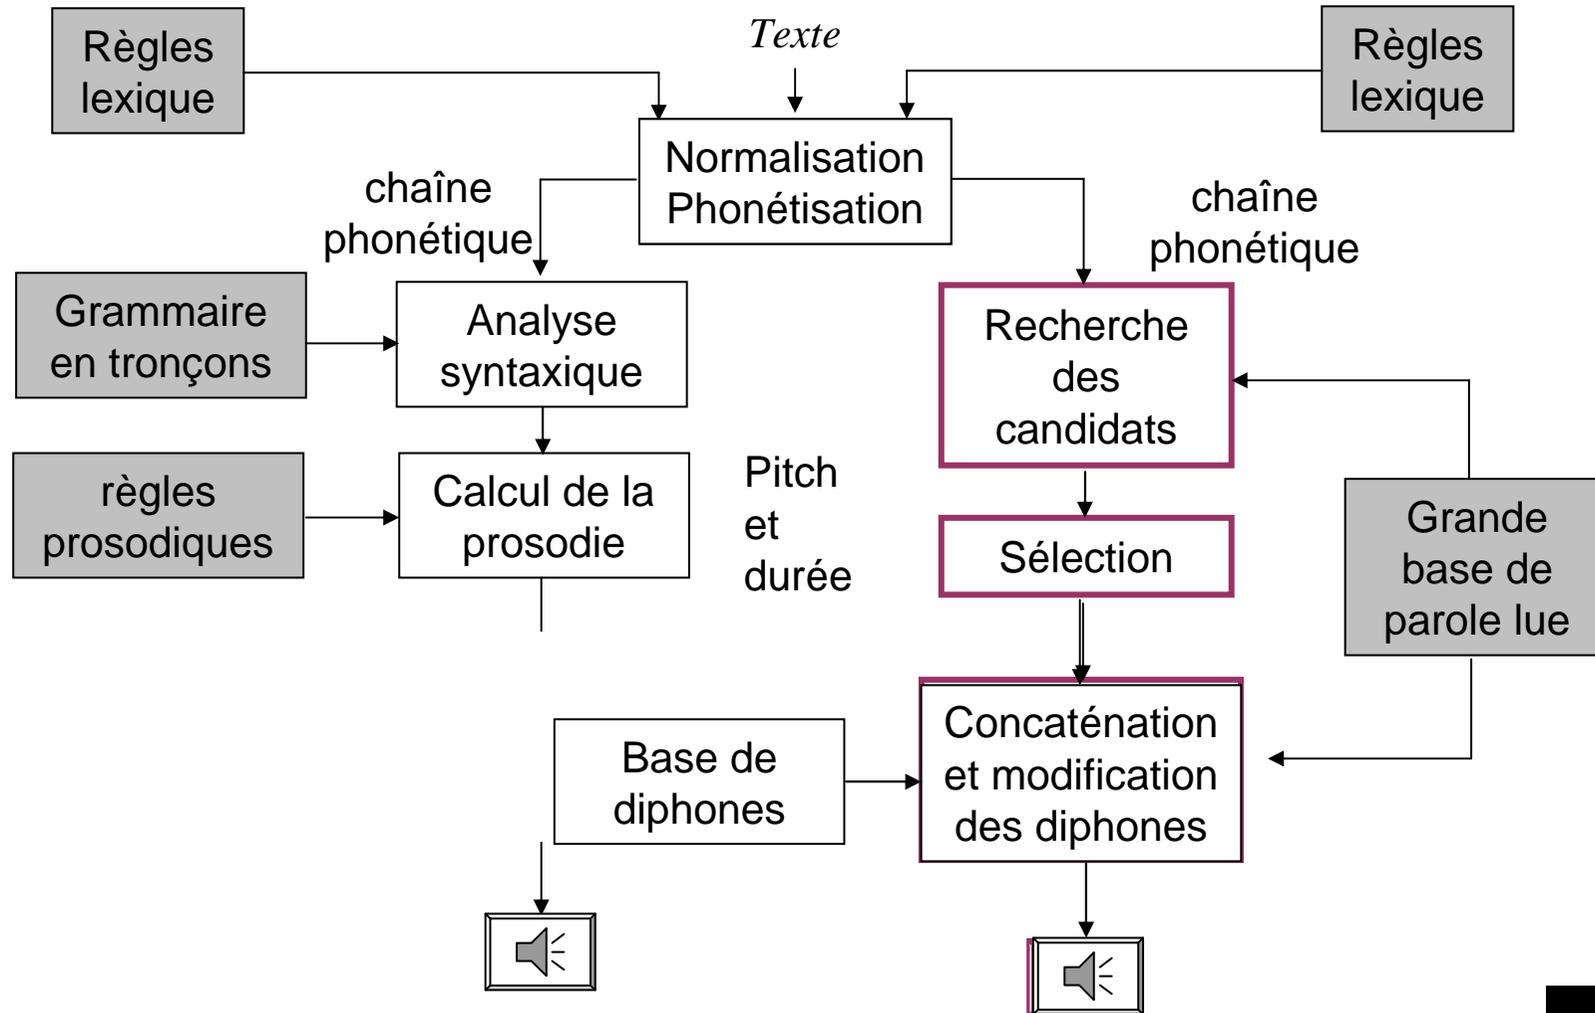
# Utilisation d'un système par sélection pour la prosodie

*D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003*

- ❑ Prédiction de **la prosodie par sélection** : pitch et durée
- ❑ Synthétiseur à partir de diphone pour la partie segmentale
- ❑ **Pourquoi utiliser la sélection ?**
  - ✓ changement de style par rapport aux règles
  - ✓ pas d'analyse syntaxique, pas de règles
  - ✓ place : base  $\approx 3$  Mo (160 Mo pour le son)

# Synthèse de la prosodie par sélection

*D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003*



# Les modifications apportées au système

*D'après R. Prudon, Thèse de doctorat Univ. Paris-XI, 2003*

- ❑ Priorité des données prosodiques aux dépens des données segmentales
- ❑ Réglage des coûts spécifiques

<b>Coût de cible</b> 0,55			<b>Coût de concaténation</b> 0,45				
mot 0,3	<b>syllabe</b> 0,45	<b>durée</b> 0,25	<b>maximisation</b> 0,55	contexte 0,15	pitch 0,25	Durée 0,025	<b>énergie</b> 0,025

<b>Coût de cible</b> 0,7			<b>Coût de concaténation</b> 0,3				
mot 0,3	<b>syllabe</b> 0,35	<b>durée</b> 0,35	<b>maximisation</b> 0,675	contexte 0,1	pitch 0,2	Durée 0,025	<b>énergie</b> 0

# Le choix des unités de synthèse

## □ Les unités retenues doivent:

- ✓ Rendre compte intrinsèquement du plus grand nombre d'effets de coarticulation possible
- ✓ Être faciles à concaténer
- ✓ Être courtes et peu nombreuses (pour des raisons de place mémoire et de temps de segmentation)

# Les unités utilisées

## □ Diphones (les plus utilisés)

- ✓ Env. 1200 en français
- ✓ Env. 5 Mo d'échantillons sur 16 bits à 16 kHz.

## □ Disyllabes (début et fin sur des voyelles)

- ✓ > 10000 unités
- ✓ Env. 50 Mo de données

## □ Polyphones (triphones, quadriphones)

- ✓ Ex en français
  - Triphones: 153 incluant [j], 54 incluant [w], 544 incluant [l] ou [r]
  - Quadriphones: 288 incluant [j] et soit [l] soit [r]

## □ Unités totales

- Unité de base: diphones, phones, demi-phones,....

# Concaténation des segments

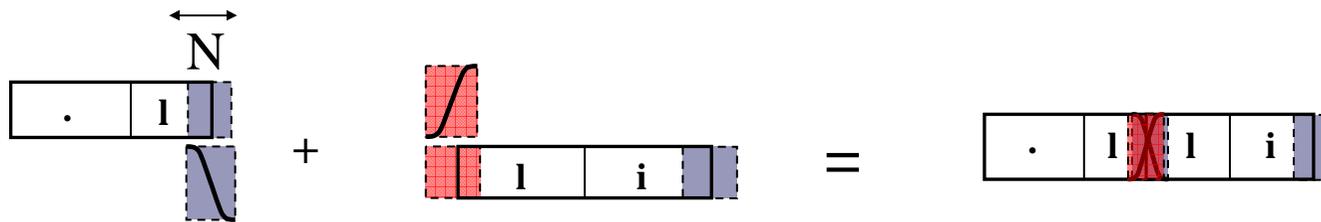
## □ Lisser les discontinuités

- ✓ Lissage simple
  - Simple fenêtrage
  - Recouvrement par corrélation
- ✓ Fenêtrage puis addition-recouvrement
  - TD-PSOLA
- ✓ Utilisation d'un modèle paramétrique
  - LP-PSOLA
  - Modèle harmonique + bruit
  - MBROLA

# Lissage temporel

## □ Lissage temporel simple:

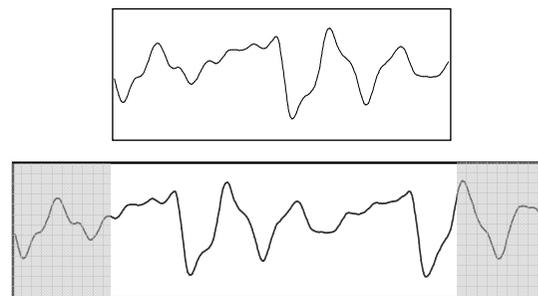
- ✓ lissage de la forme d'onde, addition recouvrement (Overlap and Add; fenêtre de Hanning pour  $N \approx 10$  ms)



## □ Lissage par recherche du point de concaténation

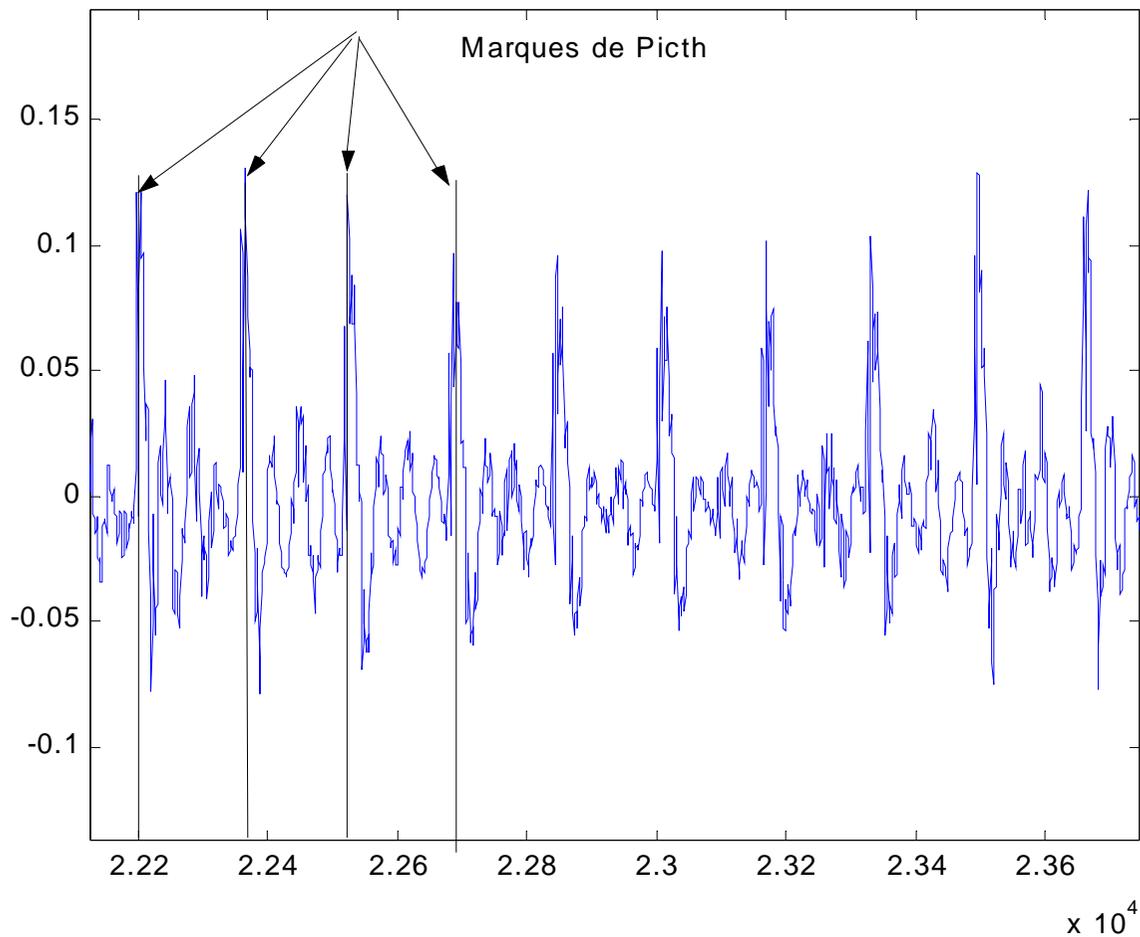
- ✓ mise en phase de deux signaux par intercorrélation

$$0 < k < K$$

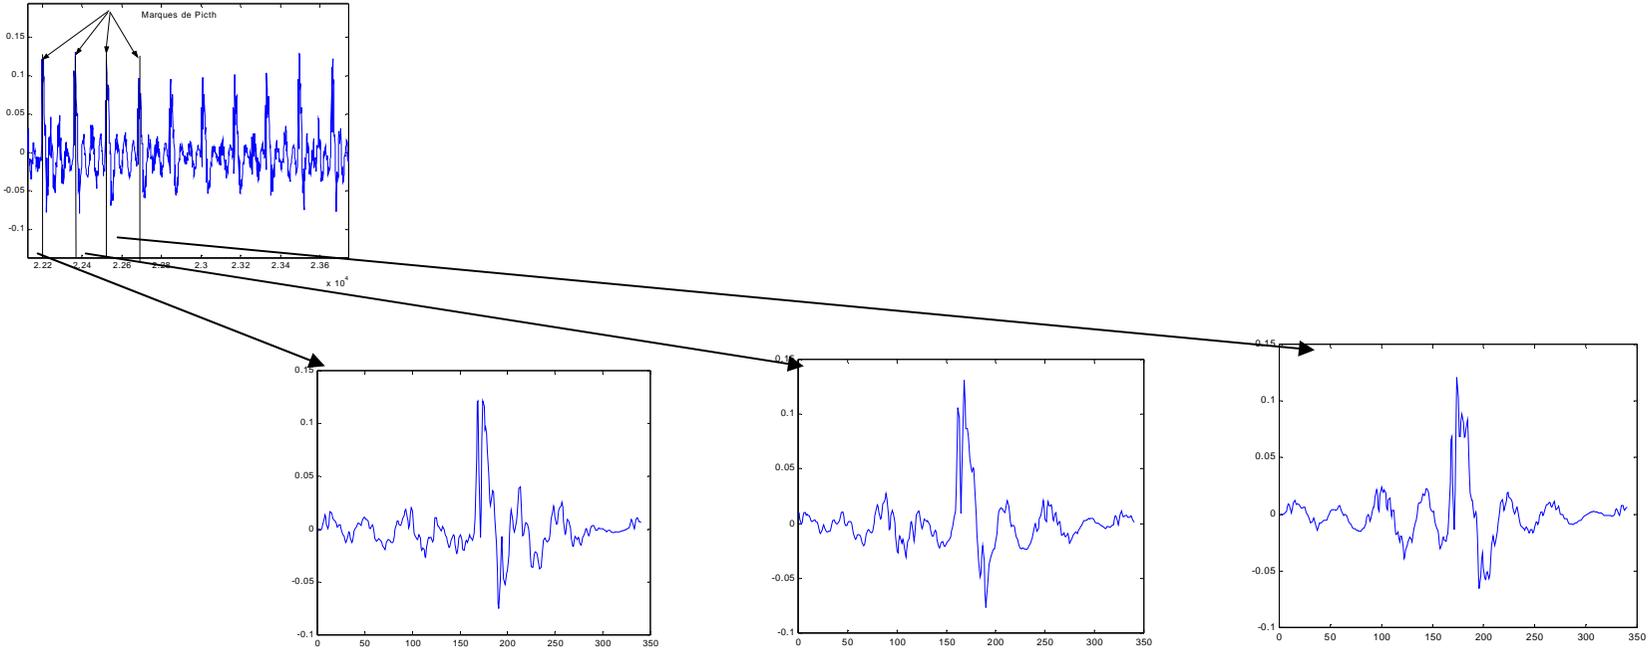


# TD-PSOLA: Lissage et modifications

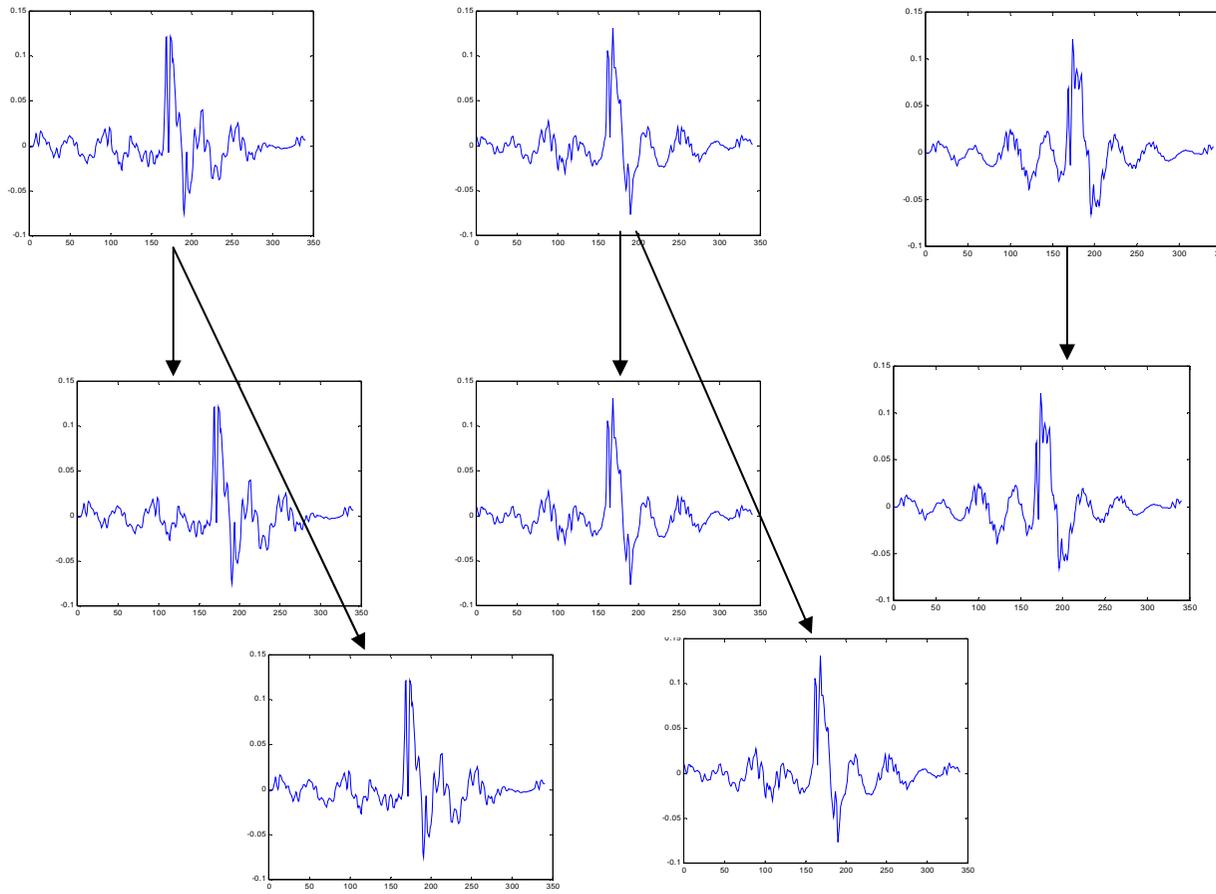
## TD-PSOLA: Time Domain Pitch Synchronous OverLap and Add



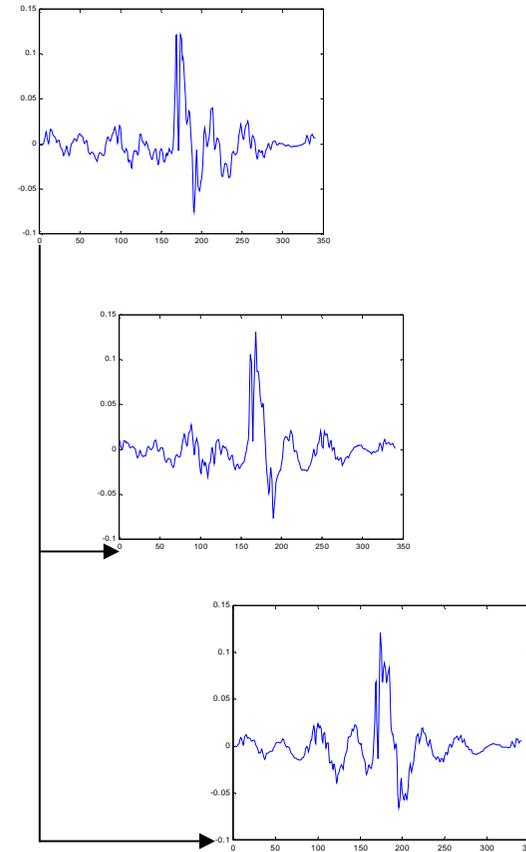
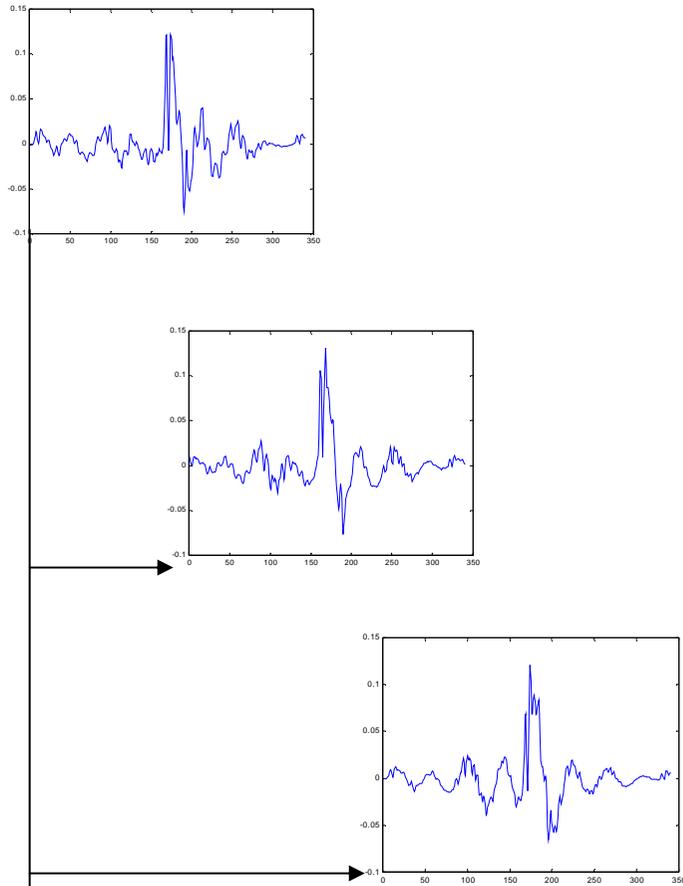
# Signaux à court-terme



# Modification de durée



# Modification de fréquence fondamentale



# Synthèse

- ❑ Extraction des formes d'onde synchrones de la fréquence fondamentale
- ❑ Synthèse par addition / recouvrement de formes d'onde
  - ✓ Insertion / Suppression de signaux à court-terme pour modifier la durée
  - ✓ Modification de l'espacement des signaux à court-terme pour modifier la fréquence fondamentale
- ❑ Le même principe peut être appliquée sur l'excitation (prédiction linéaire): LP-PSOLA

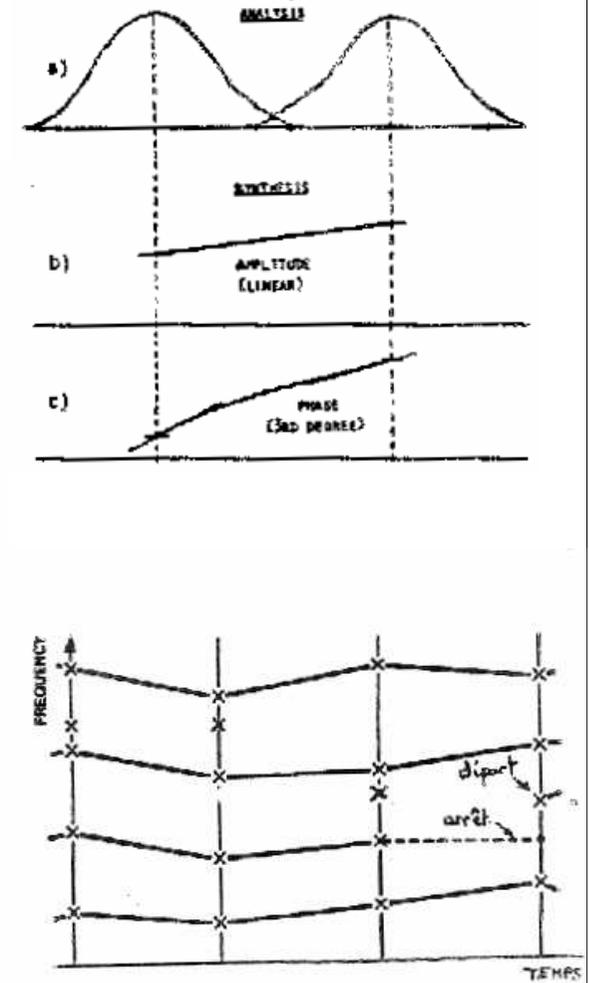
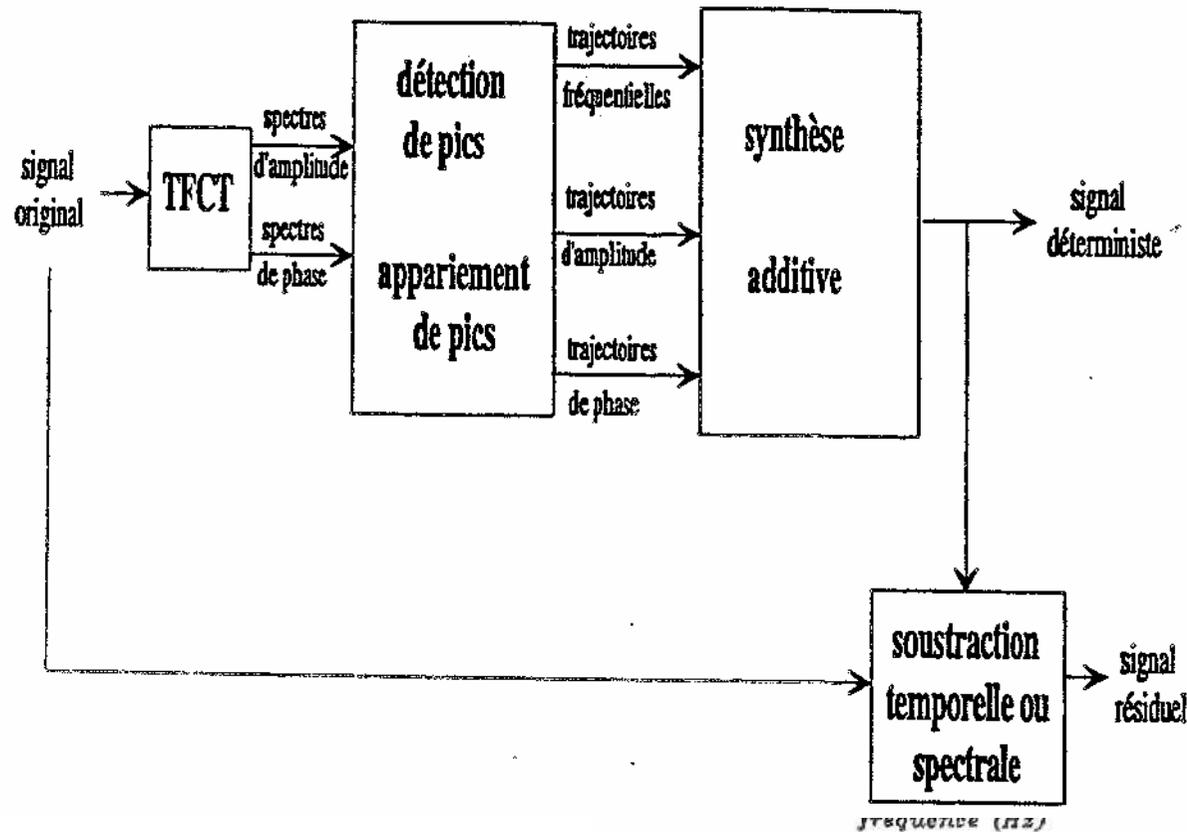
# Exemples

Original (voix d'homme)	
Abaissement fréquence fondamentale (80 %)	
Élévation fréquence fondamentale (120 %)	
Raccourcissement du temps (50 %)	
Allongement de la durée (300 %)	

*Un exemple plus complet (Beaugendre & al.):* 

# Lissage spectral des segments

## □ Méthode Harmonique-bruit



# Lissage des segments



## □ Méthode MBROLA

- ✓ Resynthèse de la base
  - À pitch constant
  - À phase fixe
  
- ✓ => overlap simple (fenêtre de longueur constante)

# Applications



- ✓ Services de télécommunications
  - Informations cinema, routières, compte en banque
  - Intelligibilité primordiale
  
- ✓ Apprentissage (ou perfectionnement) de langues étrangères
  - Système complet
  - Dictionnaire de poche pour la traduction
  
- ✓ Aide aux handicapés
- ✓ Livres et jouets parlants
  
- ✓ Communication homme machine (dialogue)

# Perspectives



- ❑ Améliorations de la qualité segmentale des modèles (HNS,..)
- ❑ Synthèse à partir de concepts
- ❑ Synthèse variable dans le temps
- ❑ Synthèse émotionnelle
- ❑ Conversion de voix