



UNIVERSITÉ DE
SHERBROOKE

Faculté de génie

Génie électrique et informatique

Extension spectrale d'un signal de parole de la bande téléphonique
à la bande AM

Mémoire de maîtrise

Specialité : génie électrique

Jean-Marc Valin

Résumé

Le présent mémoire propose un système d'extension de la bande permettant de produire un signal en bande AM à partir d'un signal de parole en bande téléphonique. L'objectif est donc de reconstruire le signal en bande AM avec une qualité sonore se rapprochant le plus possible de la référence en bande AM.

L'extension est effectuée de façon indépendante pour les hautes fréquences et les basses fréquences. L'extension des hautes fréquences utilise le modèle filtre-excitation, ce qui divise le problème en deux parties : l'extension de l'excitation et de l'enveloppe spectrale. L'extension de l'excitation est réalisée dans le domaine temporel par une fonction non linéaire, alors que l'extension de l'enveloppe spectrale s'effectue dans le domaine cepstral par un perceptron multi-couches. L'extension de la bande basse utilise le modèle sinusoïdal. L'amplitude des sinusoïdes est aussi estimée par un perceptron multi-couches.

Les résultats obtenus montrent que la qualité sonore après extension est supérieure à celle de la bande téléphonique. Toutefois, on note une importante différence de perception entre différents auditeurs.

Certaines techniques développées pour le projet d'extension de la bande présentent un certain intérêt pour le domaine du codage de la parole. L'extension de l'excitation est l'une d'entre elles et fait l'objet d'une étude plus approfondie.

Remerciements

Je voudrais d'abord remercier mon directeur de recherche et professeur, Roch Lefebvre pour son aide précieuse tout au long de ce projet. Je voudrais ensuite remercier la compagnie VoiceAge, ainsi que le Conseil de recherches en sciences naturelles et en génie (CRSNG) pour leur support financier au cours de ma maîtrise.

Je suis reconnaissant à Dominic Létourneau pour m'avoir aidé à plusieurs reprises. Je remercie ma fiancée Nathalie, pour sa patience et son support malgré les nombreuses journées de travail s'achevant souvent à 4h du matin ! Je veux remercier mes parents, Laila et Michel qui m'ont supporté tout au long de mes études.

J'aimerais enfin remercier les nombreux volontaires qui ont accepté de participer aux évaluations subjectives.

Table des matières

1	Introduction	1
1.1	Description du problème	1
1.2	Bande téléphonique et bande AM	1
1.3	Solution proposée	2
1.4	Caractéristiques recherchées	2
1.4.1	Qualité sonore	3
1.4.2	Complexité	3
1.4.3	Délai algorithmique	3
1.5	Organisation du mémoire	3
2	Signal de parole et modélisation	4
2.1	Caractéristiques du signal de parole	4
2.2	Analyse LPC et domaine de représentation	6
2.2.1	Estimation des coefficients de prédiction	8
2.2.2	Conditionnement de l'analyse	9
2.2.3	Coefficients de prédiction et enveloppe fréquentielle	10
2.2.4	Le domaine cepstral	11
2.3	Analyse du pitch	11
3	Modèle d'extension proposé	13
3.1	Points principaux du système d'extension	14
3.2	Inversion du IRS modifié	14

4	Extension des hautes fréquences	17
4.1	Modèle utilisé	17
4.2	Extension de l'excitation	17
4.2.1	Repliement spectral et non linéarité	18
4.2.2	Application au codage large bande	19
4.3	Extension de l'enveloppe spectrale	21
4.3.1	Mesure de distorsion spectrale	22
4.3.2	Représentation de l'enveloppe spectrale	22
4.3.3	Extraction de paramètres vocaux	24
4.3.4	État de l'art	25
4.3.5	Réseaux de neurones	27
4.4	Résultats	30
4.4.1	Régression linéaire	30
4.4.2	Dictionnaires associatifs	30
4.4.3	Perceptron multi-couches	30
4.4.4	Analyse de complexité	31
4.4.5	Reconstruction de la bande haute	33
4.5	Post-traitement	34
4.5.1	Lissage des variations dans l'enveloppe spectrale	34
4.5.2	Atténuation de la bande haute reconstruite	34
4.6	Codage de l'enveloppe	35
5	Extension des basses fréquences	36
5.1	Modèle utilisé	36
5.2	Synthèse des sinusoïdes	37
5.3	Estimation de l'amplitude des sinusoïdes	37
5.4	Résultats quantitatifs	39
5.4.1	Régression linéaire	39
5.4.2	Réseaux de neurones	39
5.5	Utilisation des basses fréquences résiduelles	40

6	Résultats	42
6.1	Résultats quantitatifs	42
6.2	Résultats qualitatifs	43
6.2.1	Méthode expérimentale	43
6.2.2	Résultats expérimentaux	44
6.2.3	Analyse des résultats	44
7	Discussion et conclusion	47
7.1	Réalisation des objectifs initiaux	48
7.1.1	Qualité sonore	48
7.1.2	Complexité	48
7.1.3	Délai algorithmique	48
7.2	Limitations et perspectives de recherche	49

Table des figures

2.1	Signaux voisés et non voisés	5
2.2	Discrimination des voyelles par les formants	6
2.3	Excitation pour les phonèmes voisés et non voisés	7
3.1	Vue d'ensemble du système	14
3.2	Réponse du filtre IRS modifié	15
3.3	Réponse du filtre inverse	16
3.4	Réponse combinée du filtre IRS modifié et de son filtre inverse	16
4.1	Modèle d'extension des hautes fréquences	18
4.2	Extension de l'excitation	19
4.3	Application au codage de parole	20
4.4	Codage par extension de l'excitation	21
4.5	Distorsion spectrale et coefficients DCT	24
4.6	Exemple de spectre représenté par la DCT	25
4.7	Dictionnaire associatif	27
4.8	Unité d'un perceptron	28
4.9	Perceptron multi-couches	29
4.10	Performances des dictionnaire associatif	31
4.11	Hautes fréquences : performances des perceptrons multi-couches	31
4.12	Performances vs. degrés de liberté	32
4.13	Performances vs. complexité algorithmique	32

4.14	Spectrogramme : reconstruction de la bande haute	33
5.1	Système d'extension des basses fréquences	38
5.2	Basses fréquences : performances des perceptrons multi-couches	40
5.3	Système modifié d'extension des basses fréquences	41
6.1	Distribution des préférences entre l'extension et la bande téléphonique	45

Liste des tableaux

6.1	Résultats des tests subjectifs avec écouteurs	44
6.2	Résultats des tests subjectifs avec haut-parleurs	44
6.3	Résultats cumulatifs des tests subjectifs	44
6.4	Résultats pour les <i>utilisateurs potentiels</i>	46

Lexique

CELP	Code-Excited Linear Prediction
CODEC	COdeur DÉCodeur
DCT	Discrete Cosine Transform (transformée en cosinus discrète)
DSP	Digital Signal Processor
FFT	Fast Fourier Transform (transformée de Fourier rapide)
LPC	Linear Prediction Coefficients (coefficients de prédiction linéaire)
MOS	Mean Opinion Score
MMSE	Minimum Mean Square Error (erreur quadratique minimale)
pitch	Fréquence fondamentale de la voix
QV	Quantification vectorielle
REL	Residue-Excited Linear Prediction
RSB	Rapport signal sur bruit (aussi SNR : Signal to Noise Ratio)

Chapitre 1

Introduction

1.1 Description du problème

La plupart des applications de transmission vocale actuelles transmettent la parole dans la « bande téléphonique », soit de 200 Hz à 3500 Hz. Toutefois, afin d'améliorer la qualité de la voix, on a de plus en plus recours à des systèmes transmettant la voix dans la bande AM, soit de 50 Hz à 7000 Hz. Un signal dans la bande AM est souvent appelé signal « large bande ».

Alors qu'une fréquence d'échantillonnage de 8 kHz est suffisante pour transmettre un signal en bande téléphonique, la bande AM nécessite une fréquence d'échantillonnage de 16 kHz. Malheureusement, le réseau téléphonique actuel a été conçu pour fonctionner à une fréquence d'échantillonnage de 8 kHz et il est presque impensable de modifier tout le matériel du réseau téléphonique pour que ce dernier fonctionne à 16 kHz.

C'est pour cette raison qu'il existe un besoin pour un système qui permettrait de produire un signal large bande à partir du signal correspondant dans la bande téléphonique. Ce système ferait en sorte de modifier uniquement les récepteurs téléphoniques, sans modifier le réseau lui-même. Toutefois, pour des applications de téléphonie numérique, il peut être préférable de « dépenser » quelques bits supplémentaires afin d'obtenir une qualité de son se rapprochant encore plus de la qualité « large bande ». On pourra alors coder la partie de l'information qui n'a pu être restaurée en ajoutant un faible débit à un codeur de parole en bande téléphonique.

1.2 Bande téléphonique et bande AM

La majeure partie de l'information contenue dans un signal de parole est comprise entre 50 Hz et 7 kHz, soit dans la bande AM. Le fait de transmettre uniquement la bande téléphonique

(200 Hz à 3,5 kHz) du signal affecte considérablement la qualité perçue par l'utilisateur tout en diminuant légèrement l'intelligibilité. Chacune des bandes de fréquence perdue lors du filtrage dans la bande téléphonique affecte d'une manière différente le signal de parole tel que perçu par l'utilisateur.

La partie basses fréquences perdue est surtout liée à l'impression de « présence » lors de la communication, surtout lorsque le locuteur est un homme. En effet, les fréquences entre 50 Hz et 200 Hz sont surtout perçues comme des vibrations qui indiquent normalement que le locuteur est proche.

La partie hautes fréquences, quant à elle, donne une impression de « clarté » au signal de parole. Un signal de parole en bande téléphonique perd beaucoup de cette clarté, surtout pour des locuteurs féminins. De plus, c'est surtout par les hautes fréquences que l'oreille arrive à discriminer les fricatives (/s/, /f/, /ʃ/) entre elles. Pour cette raison, la partie hautes fréquences contribue à l'intelligibilité de la parole.

1.3 Solution proposée

Contrairement à d'autres travaux qui ne s'intéressent qu'à la bande basse ou la bande haute, ce projet consiste à faire l'extension des deux bandes, soit de 50 Hz à 200 Hz et de 3500 Hz à 8000 Hz. De plus, le signal de parole utilisé en entrée du système est filtré de la même manière qu'un signal ayant passé par le réseau téléphonique.

En plus de l'objectif premier du projet qui est de faire un système d'extension complet, il est aussi question de l'application de certaines techniques développées pour ce projet au domaine plus général du codage large bande. En effet, on sait qu'une technique permettant de prédire une certaine variable permet de diminuer la quantité d'information nécessaire à la quantification de cette même variable (pourquoi coder l'information qui peut être obtenue autrement?).

1.4 Caractéristiques recherchées

Afin d'être utile dans une application de téléphonie, il est important que le système d'extension de la bande conçu possède certaines caractéristiques. Celles-ci sont : la qualité du son, une complexité raisonnable et un faible délai algorithmique.

1.4.1 Qualité sonore

La qualité sonore est, bien entendu, la première caractéristique recherchée, puisque c'est justement pour augmenter la qualité de la parole que l'on désire passer de la bande téléphonique à la bande AM. Le signal de parole traité doit être plus agréable à écouter que le signal original en bande téléphonique et sa qualité doit se rapprocher le plus possible de celle du signal « original » large bande.

1.4.2 Complexité

La complexité est une caractéristique très importante de tout système de traitement de la voix. En effet, ces systèmes sont, la plupart du temps, implantés sur des DSP ayant une capacité de traitement et une mémoire limitées. Bien qu'aucune mise en oeuvre sur DSP ne soit proposée, il faudra tout de même tenir compte de contraintes de complexité « raisonnables ».

1.4.3 Délai algorithmique

Afin de pouvoir être utilisé lors d'une conversation en temps réel, un algorithme de traitement de la parole doit avoir un délai qui ne soit pas perceptible par l'utilisateur. Ceci exclut certains traitements non causaux qui nécessitent de connaître une partie importante du signal à venir. Pour des applications de voix en temps réel, on accepte généralement un délai de traitement ne dépassant pas 100 *ms*.

1.5 Organisation du mémoire

Comme le présent projet requiert une certaine connaissance du signal de parole et des outils d'analyse de ce signal, cette partie sera traitée au chapitre 2. Suivra ensuite au chapitre 3 un aperçu global du système proposé. Les chapitres 4 et 5 traiteront respectivement des algorithmes utilisés pour reconstruire les hautes et les basses fréquences. Le chapitre 6 sera consacré aux résultats obtenus, suivi par une discussion au chapitre 7.

Chapitre 2

Signal de parole et modélisation

2.1 Caractéristiques du signal de parole

La parole est produite lorsque l'air, poussé hors des poumons, passe par les cordes vocales et le conduit vocal pour produire un son. Les modes de production des sons diffèrent grandement, ce qui permet une grande variété de phonèmes. On peut diviser ces phonèmes en deux classes : voisés et non voisés. Les voyelles sont des exemples de sons voisés, alors que les fricatives sont des exemples de sons non voisés. La figure 2.1 montre, dans le domaine temporel et fréquentiel, une voyelle (/a/) et une fricative (/s/). On remarque que le signal correspondant à une voyelle est périodique, ce qui s'explique par le fait que la glotte s'ouvre et se referme à intervalles réguliers. Pour les fricatives, la glotte reste grande ouverte, ce qui explique l'absence de périodicité. Les phonèmes voisés se distinguent dans le domaine spectral par une structure fine harmonique, alors que la structure fine des phonèmes non voisés est stochastique.

En plus d'être différents par leur voisement, les phonèmes se distinguent par la forme générale de leur spectre, soit l'enveloppe spectrale. Les résonances présentes dans l'enveloppe sont appelées « formants » et permettent de discriminer les voyelles entre elles. On peut voir à la figure 2.2 la différence entre les formants d'un /a/ et ceux d'un /i/.

Le signal de parole peut donc être modélisé simplement comme une source d'excitation (sortie des cordes vocales) filtrée par un filtre résonant (conduit vocal) représentant l'enveloppe spectrale. On connaît cette représentation de la parole comme modèle « filtre-excitation ». Afin de modéliser la réponse en fréquence du conduit vocal, on utilise de façon générale un filtre tout-pôles, dont les coefficients évoluent dans le temps. Si le filtre tout-pôles représente bien l'enveloppe spectrale du signal, c'est dire que le spectre de l'excitation doit être généralement plat.




FIGURE 2.1 – Illustration des différences entre un phonème voisé et un phonème non voisé. (a) Le phonème voisé /a/ (voyelle) dans le domaine temporel et (b) fréquentiel. (c) Le phonème non voisé /s/ (fricative) dans le domaine temporel et (d) fréquentiel.

Il y a relativement peu de différence entre les excitations des différents phonèmes. La principale différence se situe entre les phonèmes voisés et non voisés. En effet, tel qu'illustré à la figure 2.3, l'excitation pour les phonèmes voisés (/e/) peut être approximée par un train d'impulsions et a donc un spectre comportant des harmoniques espacées de façon régulière. L'excitation pour une fricative (/s/), quant à elle, ressemble plutôt à du bruit blanc et son spectre ne comporte donc pas d'harmoniques.




FIGURE 2.2 – Illustration des différences entre les formants de différentes voyelles. (a) Le phonème /a/. (b) Le phonème /i/.

2.2 Analyse LPC et domaine de représentation

La prédiction linéaire est un outil indispensable dans le domaine du traitement et du codage de la parole. En prédisant un échantillon $x(n)$ à partir d'une combinaison linéaire des échantillons $x(n - i)$ passés, elle permet d'estimer la corrélation à court terme du signal. Comme cette corrélation à court terme du signal de parole est l'effet du filtrage de l'excitation par le conduit vocal, la prédiction linéaire permet d'estimer les caractéristiques du conduit vocal et par conséquent, l'enveloppe spectrale. Un fois le filtre du conduit vocal identifié, il est alors facile d'obtenir l'excitation glottale. Ainsi, soient a_i les coefficients de prédiction linéaire, le signal de parole $x(n)$ est représenté par :

$$x(n) = \sum_{i=1}^N a_i x(n - i) + r(n) \quad (2.1)$$

où $r(n)$ est appelé « résidu de prédiction » et représente le signal d'excitation. Si on considère les coefficients a_i comme représentant un filtre tout-zéros

$$A(z) = 1 - \sum_{i=1}^N a_i z^{-i} \quad (2.2)$$

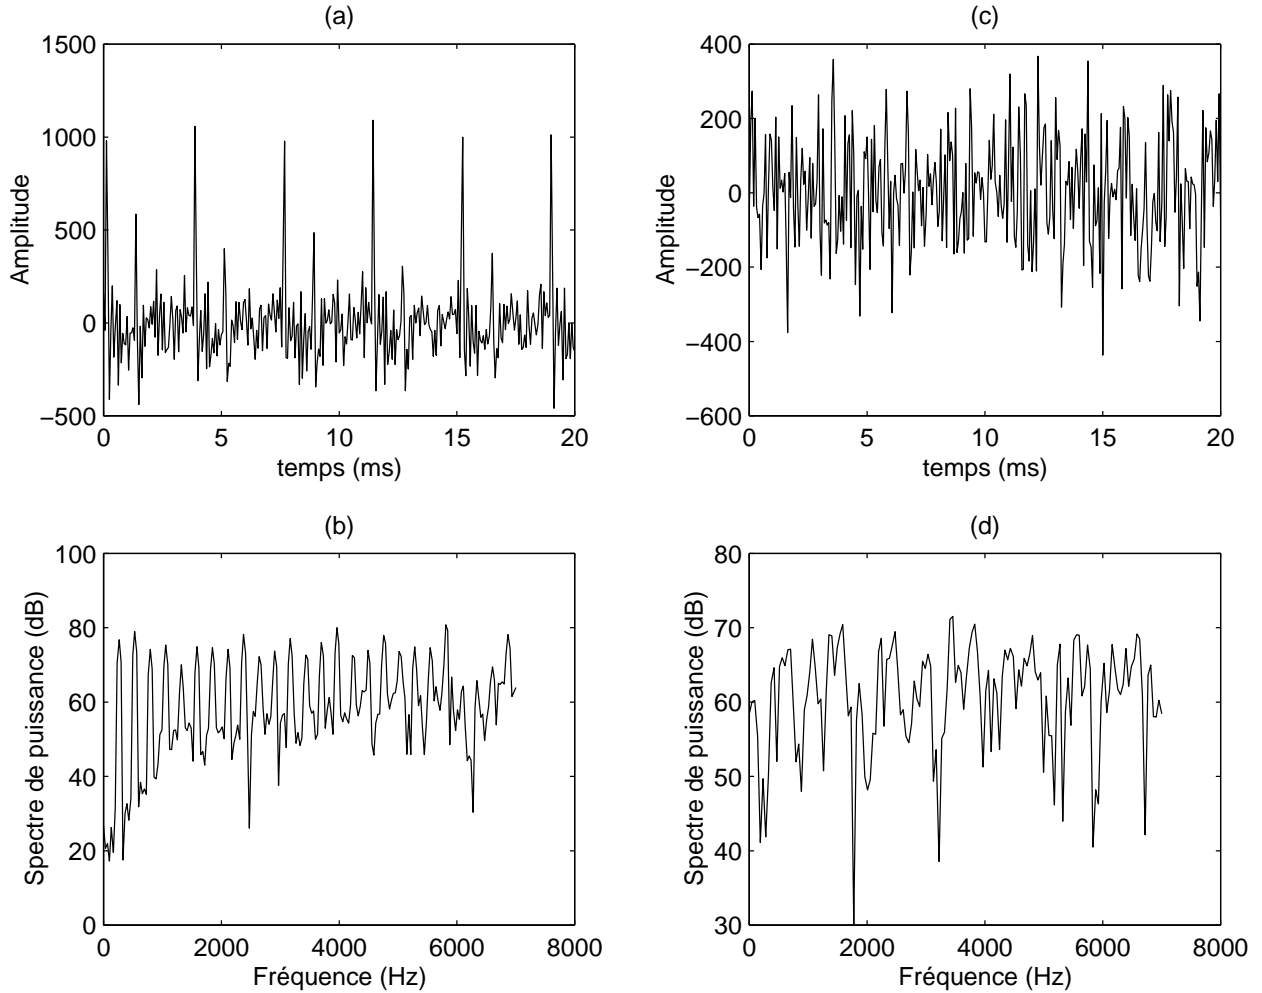


FIGURE 2.3 – Illustration des différences entre l’excitation pour un phonème voisé et un phonème non voisé. (a) L’excitation du phonème voisé /a/ (voyelle) dans le domaine temporel et (b) fréquentiel. (c) L’excitation du phonème non voisé /s/ (fricative) dans le domaine temporel et (d) fréquentiel.

le signal d’excitation devient alors

$$R(z) = A(z)X(z) \quad (2.3)$$

Inversement, on peut reconstruire le signal de parole à partir de l’excitation et d’un filtre tout-pôles par

$$X(z) = \frac{1}{A(z)}R(z) \quad (2.4)$$

L’analyse LPC permet donc de décomposer un signal de parole en son excitation et son enveloppe spectrale et permet de refaire la synthèse du signal original par la suite. On référera

à $A(z)$ comme étant le filtre d'analyse et à $\frac{1}{A(z)}$ comme étant le filtre de synthèse.

2.2.1 Estimation des coefficients de prédiction

Avant d'effectuer l'analyse LPC, on multiplie généralement le signal $x(n)$ par une fenêtre de Hanning $w(n)$ de longueur L pour obtenir un signal $x_w(n)$, soit

$$x_w(n) = w(n)x(n) \quad (2.5)$$

La fenêtre de Hanning est définie par :

$$w(n) = \begin{cases} 0,5 - 0,5 \cos\left(\frac{2\pi n}{L-1}\right), & 0 \leq n < L \\ 0, & \text{sinon} \end{cases} \quad (2.6)$$

Le critère d'erreur utilisé pour estimer les coefficients de prédiction est l'erreur quadratique entre le signal $x_w(n)$ et sa prédiction linéaire, soit

$$E = \sum_{n=-\infty}^{\infty} \left[x_w(n) - \sum_{i=1}^N a_i x_w(n-i) \right]^2 \quad (2.7)$$

On obtient les valeurs de a_k optimales en minimisant le critère d'erreur E de sorte que

$$\frac{\partial E}{\partial a_i} = 0, \quad i = 1, 2, \dots, N \quad (2.8)$$

d'où on tire que

$$\sum_{n=-\infty}^{\infty} x_w(n)x_w(n-k) = \sum_{i=1}^N a_i \sum_{n=-\infty}^{\infty} x_w(n)x_w(n-i), \quad k = 1, 2, \dots, N \quad (2.9)$$

Soit $R(m)$ l'autocorrélation du signal fenêtré $x_w(n)$ donnée par

$$R(m) = \sum_{n=i}^{L-1} x_w(n)x_w(n-m) \quad (2.10)$$

on obtient que

$$\begin{bmatrix} R(0) & R(1) & \cdots & R(N-1) \\ R(1) & R(0) & \cdots & R(N-2) \\ \vdots & \vdots & \ddots & \vdots \\ R(N-1) & R(N-2) & \cdots & R(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_N \end{bmatrix} = \begin{bmatrix} R(1) \\ R(2) \\ \vdots \\ R(N) \end{bmatrix} \quad (2.11)$$

Comme la matrice en 2.11 est Toeplitz-Hermitienne, le système peut être résolu efficacement par la récursion de Levinson-Durbin[1] en un temps $\mathcal{O}(N^2)$. De plus, il peut être démontré que tous les pôles du filtre de prédiction se trouvent à l'intérieur de cercle unitaire dans le plan z , ce qui assure la stabilité du filtre tout-pôles[2].

2.2.2 Conditionnement de l'analyse

L'analyse LPC est une opération qui peut être sensible à certaines caractéristiques du signal. Cette sensibilité vient de l'inversion de la matrice des autocorrélations en 2.11. Il est donc nécessaire de s'assurer que cette matrice soit toujours bien conditionnée, peu importe le signal d'entrée de l'analyse LPC.

Comme dans un signal de parole, l'énergie aux hautes fréquences est généralement beaucoup plus faible que celle aux basses fréquences, il se peut que la matrice des autocorrélations soit mal conditionnée[3]. Afin de remédier à la situation, on applique au signal une préaccentuation des hautes fréquences, généralement en filtrant le signal avec le filtre passe-haut

$$H(z) = 1 - \alpha z^{-1} \quad (2.12)$$

Afin d'aider au conditionnement de la matrice des autocorrélations, on peut légèrement augmenter les valeurs sur sa diagonale, soit $R(0)$. Ceci est exactement équivalent à l'ajout de bruit blanc au signal original, puisque l'autocorrélation du bruit blanc vaut $R(m) = \delta_{m,0}$. Le fait de multiplier le coefficient $R(0)$ par α correspond à un rapport signal sur bruit de

$$RSB = 10 \log_{10} \left(\frac{1}{\alpha - 1} \right) \text{ dB} \quad (2.13)$$

Ainsi, la valeur $\alpha = 1,0001$ correspond à un « plancher de bruit » de 40 dB. Ce plancher de bruit aura aussi des avantages lors de la transformation vers le domaine cepstral.

Enfin, lorsque le conduit vocal comporte une résonance importante, les pôles du filtre de prédiction se trouvent très près du cercle unitaire dans le plan z . Dans ces cas, les erreurs

d'arrondi lors des calculs ou la quantification des coefficients LPC peut faire en sorte que le filtre tout-pôles devienne instable. De plus, lorsque un ou plusieurs pôles du filtre LPC se trouvent près du cercle unitaire dans le plan z , il devient plus difficile de traiter ce filtre par son enveloppe spectrale (section 2.2.3).

Une des façons de remédier au problème est de ramener les pôles du filtre $\frac{1}{A(z)}$ vers l'origine par un facteur γ , ce qui correspond à utiliser le filtre $\frac{1}{A(\gamma z)}$. Malheureusement, cette technique, appelée *bandwidth expansion*[2], a l'inconvénient de modifier aussi la position de tous les autres pôles. Pour cette raison, on utilise plutôt une technique appelée *lag windowing*[4]. Cette méthode consiste à fenêtrer la valeur des autocorrélations $R(m)$ avant de résoudre le système en 2.11. Comme le spectre de puissance d'un signal n'est autre que la transformée de Fourier de l'autocorrélation, un fenêtrage de l'autocorrélation est équivalent à un filtrage (un lissage) du spectre de puissance. On peut utiliser une fenêtre gaussienne

$$w_a(m) = e^{-(\beta m)^2} \quad (2.14)$$

où le paramètre β contrôle la largeur de bande des résonances.

2.2.3 Coefficients de prédiction et enveloppe fréquentielle

Lors du traitement, il est parfois désirable de calculer l'enveloppe spectrale du signal à partir des coefficients de prédiction a_i . Ceci correspond à calculer le spectre de la réponse impulsionnelle du filtre de synthèse $\frac{1}{A(z)}$. Comme cette réponse impulsionnelle est théoriquement infinie et peut, en pratique, être très longue si le filtre comporte un pôle près du cercle unitaire, on calculera plutôt le spectre de la réponse du filtre d'analyse $A(z)$, puis on inversera ce spectre. Ainsi, le spectre $S_a(k)$ du filtre d'analyse est

$$S_a(k) = \left| \sum_{i=0}^N a_i e^{-2\pi j i k / N} \right|^2 \quad (2.15)$$

Le spectre de puissance du filtre de synthèse est donc

$$S_s(k) = \frac{1}{S_a(k)} \quad (2.16)$$

Il faut noter que le nombre de points utilisé pour la transformée de Fourier est d'une grande importance. En effet, si le nombre de points est trop faible, les résonances du filtre LPC ne seront pas « vues » lors de la transformation. La longueur de la transformée est donc fonction

du paramètre β utilisé lors du *lag windowing*. En effet, la « distance » entre deux points du spectre doit être au moins égale à la largeur minimale des résonances du filtre LPC.

Enfin, il est possible d'effectuer l'opération inverse, soit de retrouver les coefficients de prédiction a_i à partir du spectre de puissance du filtre de synthèse. En effet, étant donné $S_s(k)$, on peut trouver les autocorrélations $R(m)$ par la transformée de Fourier inverse, soit

$$R(m) = \sum_{k=0}^N S_s(k) e^{2\pi j km/N} \quad (2.17)$$

Une fois les autocorrélations trouvées, on peut retrouver les coefficients de prédiction par la récursion de Levinson-Durbin.

2.2.4 Le domaine cepstral

Le domaine cepstral représente de façon harmonique le logarithme du spectre d'un signal de parole. Plus précisément, le cepstre $C_s(T)$ de l'enveloppe spectrale $S_s(k)$ s'exprime comme suit :

$$C_s(T) = \mathcal{IFFT} \{ \log (S_s(k)) \} \quad (2.18)$$

Ce domaine de représentation comporte plusieurs avantages. D'abord, le fait de traiter l'enveloppe spectrale dans le domaine logarithmique se rapproche plus de la sensibilité de l'oreille. Ensuite, la transformée de Fourier inverse a pour effet de décorréler les valeurs du spectre et d'en « concentrer » l'énergie dans les quelques premiers coefficients cepstraux. Typiquement, de 8 à 12 coefficients cepstraux sont suffisants pour représenter adéquatement l'enveloppe spectrale dans la bande téléphonique. Il faut noter que $C_s(T)$ représente le cepstre de la réponse temporelle du filtre de synthèse, et non le cepstre du signal de parole lui-même.

Il faut noter que la terminologie utilisée pour le domaine cepstral est obtenue en inversant le mot correspondant pour le domaine spectrale. Ainsi, *spectre*, *fréquence* et *filtrer* deviennent respectivement *cepstre*, *quéfrence* et *liltrer* pour le domaine cepstral.

2.3 Analyse du pitch

Le signal de parole comporte des corrélations, autant à court terme qu'à long terme. Les corrélations à court terme forment l'enveloppe spectrale et sont produites par les résonances du conduit vocal. Les corrélations à long terme quant à elles, représentent le pitch de la voix

et sont le résultat des impulsions glottales. Alors que l'analyse LPC modélise les corrélations à court terme du signal de parole, on utilise un filtre prédicteur long terme pour modéliser le pitch comme

$$x(n) \approx \beta x(n - T) \quad (2.19)$$

où T est la période du pitch (la durée entre les impulsions glottales) et β est appelé « gain de pitch ». La fonction de transfert du filtre prédicteur long-terme est donc :

$$H(z) = 1 - \beta z^{-T} \quad (2.20)$$

Dans l'intervalle $[M N]$, les paramètres du pitch peuvent être trouvés en minimisant la fonction d'erreur :

$$E = \sum_{i=M}^N [x(i) - \beta x(i - T)]^2 \quad (2.21)$$

En posant $\frac{\partial E}{\partial \beta} = 0$, on trouve :

$$0 = \sum_{i=M}^N [x(i) - \beta x(i - T)] x(i - T) \quad (2.22)$$

$$\sum_{i=M}^N x(i)x(i - T) = \beta \sum_{i=M}^N x(i)x(i - T) \quad (2.23)$$

$$\beta = \frac{\sum_{i=M}^N x(i)x(i - T)}{\sum_{i=M}^N x(i - T)^2} \quad (2.24)$$

Ainsi, en remplaçant 2.24 dans 2.21, on obtient :

$$E = \sum_{i=M}^N x(i)x(i) - 2\beta \sum_{i=M}^N x(i)x(i - T) + \beta^2 \sum_{i=M}^N x(i - T)x(i - T) \quad (2.25)$$

$$E = \sum_{i=M}^N x(i)x(i) - \frac{\left(\sum_{i=M}^N x(i)x(i - T)\right)^2}{\sum_{i=M}^N x(i - T)^2} \quad (2.26)$$

$$T = \max_T \left[\frac{\left(\sum_{i=M}^N x(i)x(i - T)\right)^2}{\sum_{i=M}^N x(i - T)^2} \right] \quad (2.27)$$

Pour les phonèmes voisés, le gain de pitch β est souvent près de 1, alors que pour les phonèmes non voisés, β est plus près de 0. Bien que β soit généralement compris entre 0 et 1, il peut arriver que dans certaines circonstances, il en soit autrement.

Chapitre 3

Modèle d'extension proposé

Dans le projet d'extension de la bande téléphonique à la bande AM, on note deux principales parties, soit l'extension des hautes fréquences et l'extension des basses fréquences. Ces deux parties ont relativement peu en commun l'une avec l'autre. De cette façon, il est possible de choisir pour chaque bande, le modèle le plus approprié. Cette façon de faire comporte aussi des avantages pour le design et le débogage de ces parties. En effet, il est ainsi possible d'isoler les artefacts causés par l'extension des deux bandes de fréquence.

Le signal large bande reconstruit sera constitué des trois parties :

- la bande téléphonique originale, de 200 Hz à 3500 Hz ;
- la bande basse reconstruite, de 50 Hz à 200 Hz ;
- la bande haute reconstruite, de 3500 Hz à 7000 Hz.

Comme le signal original dans la bande téléphonique est échantillonné à 8 kHz, il sera d'abord nécessaire de le sur-échantillonner par un facteur 2, puis de filtrer passe-bas afin de ne garder que la partie sous 3500 kHz, évitant ainsi le repliement spectral causé par le sur-échantillonnage. Une fois la bande téléphonique échantillonnée à 16 kHz, on pourra la combiner aux deux bandes étendues pour obtenir le signal large bande reconstruit à 16 kHz. Le processus est illustré à la figure 3.1. Il faut noter que la sortie des blocs « extension basses fréquences » et « extension hautes fréquences » est échantillonnée à 16 kHz. Le bloc « filtre IRS modifié inverse » est optionnel et décrit à la section 3.2.

Étant donné la diversité du public visé pour ce projet, le système conçu devra pouvoir fonctionner pour différents locuteurs parlant différentes langues. Pour cette raison, les différentes étapes d'entraînement devront utiliser une base de donnée multilingue et multilocuteur.




FIGURE 3.1 – Vue d'ensemble du système d'extension de la bande.

3.1 Points principaux du système d'extension

Le sous-système d'extension des hautes fréquences est basé sur le modèle filtre-excitation, permettant de reconstruire séparément l'enveloppe spectrale (filtre) et l'excitation. L'extension de l'excitation s'effectue dans le domaine temporel par un système non linéaire. L'enveloppe spectrale est reconstruite par hétéro-association entre l'enveloppe spectrale de la bande téléphonique et l'enveloppe spectrale de la bande haute.

Le sous-système d'extension des basses fréquences utilise plutôt le modèle sinusoïdal pour reconstruire les deux premières harmoniques du pitch. Leur amplitude est, elle aussi, estimée par hétéro-association à partir de paramètres calculés sur la bande téléphonique.

3.2 Inversion du IRS modifié

Dans la majorité des applications téléphoniques, le signal échantillonné à 8 kHz est filtré de manière à améliorer l'intelligibilité, ainsi que la qualité perçue par l'utilisateur. Le filtre FIR utilisé est appelé « filtre IRS modifié » et sa réponse temporelle et fréquentielle est montrée à la figure 3.2. On considère généralement que la bande passante de ce filtre est entre 200 Hz à 3500 Hz et le gain maximal se trouve aux environs de 3000 Hz. Aussi, comme la réponse temporelle est symétrique, le filtre comporte une réponse de phase linéaire.

Avant de pouvoir faire l'extension de la bande, il est d'abord nécessaire de s'assurer que la réponse dans la bande téléphonique soit constante, telle qu'elle était dans le signal original. Pour cela, il est nécessaire d'utiliser un filtre dont la réponse fréquentielle est l'inverse de celle du filtre IRS modifié. On considère un filtre FIR à phase linéaire dont la réponse fréquentielle




FIGURE 3.2 – Réponse (a) temporelle et (b) fréquentielle du filtre IRS modifié

est

$$|H(\omega)| = a_0 + 2a_1 \cos \omega + 2a_2 \cos 2\omega + \dots + 2a_N \cos N\omega \quad (3.1)$$

Aussi, soit $G(\omega)$ la réponse fréquentielle du filtre IRS modifié, on cherche les coefficients a_k qui font que

$$|G(\omega)| |H(\omega)| \approx 1, \quad \text{pour } \omega_1 < \omega < \omega_2 \quad (3.2)$$

où $\omega_1 = 2\pi \frac{200 \text{ Hz}}{8 \text{ kHz}} = 0,16 \text{ rad/s}$ et $\omega_2 = 2\pi \frac{3500 \text{ Hz}}{8 \text{ kHz}} = 2,75 \text{ rad/s}$. Ainsi, si on minimise, dans l'intervalle $\omega_1 < \omega < \omega_2$, l'erreur quadratique

$$E = \left[\frac{1}{|G(\omega)|} - a_0 + 2a_1 \cos \omega + 2a_2 \cos 2\omega + \dots + 2a_N \cos N\omega \right]^2 \quad (3.3)$$

on obtient un filtre FIR à phase linéaire qui, lorsque convolué avec le filtre IRS modifié $G(\omega)$, produit une réponse constante entre 200 Hz et 3500 Hz. Ainsi, si on choisit $N = 30$, on obtient le filtre inverse dont les réponses temporelle et fréquentielle sont montrés à la figure 3.3. En convoluant ce filtre inverse avec le filtre IRS modifié, on obtient la réponse combinée montrée à la figure 3.4. On constate ainsi, que la réponse est en effet constante entre 200 Hz et 3500 Hz ; le but est donc atteint.




FIGURE 3.3 – Réponse (a) temporelle et (b) fréquentielle de l'inverse du filtre IRS modifié.




FIGURE 3.4 – Réponse combinée du filtre IRS modifié et de son filtre inverse. (a) Réponse temporelle. (b) Réponse fréquentielle.

Chapitre 4

Extension des hautes fréquences

4.1 Modèle utilisé

La plupart des articles[5, 6, 7, 8, 9] traitant de l'extension spectrale dans la bande haute utilisent le modèle « filtre-excitation » de la parole et c'est ce modèle qui a été retenu pour les présents travaux. Selon ce modèle, décrit à la section 2, le signal de parole est représenté par un filtre prédicteur à court terme excité par un signal d'excitation « blanc », c'est-à-dire dont le spectre est globalement plat. Le filtre prédicteur à court terme est obtenu à partir d'une analyse LPC sur le signal de parole et représente l'enveloppe spectrale du signal.

Lors de l'extension de la bande haute, l'excitation et le filtre prédicteur sont reconstruits séparément. Plutôt que de calculer l'excitation en filtrant le signal échantillonné à 8 kHz par le filtre LPC calculé sur la bande téléphonique, il est préférable de sur-échantillonner ce signal à 16 kHz et de calculer l'excitation à partir des nouveaux coefficients LPC large bande[9]. En plus de simplifier les calculs, ceci permet de réduire certains artefacts qui résulteraient des légères différences entre les filtre d'analyse et de synthèse. Le modèle d'extension pour les hautes fréquences est illustré à la figure 4.1.

Bien que le modèle filtre-excitation soit le plus utilisé, il faut noter que d'autres travaux sur l'extension de la bande haute sont plutôt basés sur le modèle sinusoïdal[10].

4.2 Extension de l'excitation

Le problème de l'extension spectrale du signal d'excitation est connu depuis les années 1970. En effet l'extension de l'excitation a d'abord été utilisée dans les codeurs de parole de type

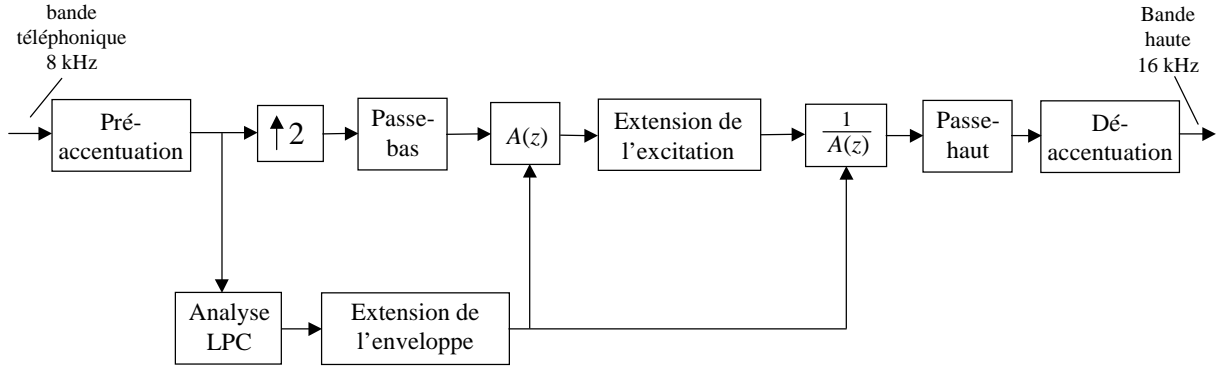


FIGURE 4.1 – Modèle filtre-excitation pour l’extension des hautes fréquences

RELp au cours des années 1970. Cependant, pour le présent projet, l’extension se fera jusqu’à 8000 Hz, plutôt que 4000 Hz.

4.2.1 Repliement spectral et non linéarité

La méthode la plus utilisée pour étendre la bande de l’excitation est le repliement spectral[11]. Le signal d’excitation en bande téléphonique $r_{bt}(n)$ est transformé en un signal d’excitation large bande $r_{lb}(n)$

$$r_{lb}(n) = \begin{cases} 2r_{bt}(n) & n \text{ pair} \\ 0 & n \text{ impair.} \end{cases} \quad (4.1)$$

Le spectre résultant est alors une image miroir du spectre dans la bande basse. Il est cependant connu que cette méthode, en plus de causer des discontinuités dans le spectre, produit un son trop harmonique aux hautes fréquences. De plus, cette méthode ne fonctionne bien que si l’on effectue l’extension de la bande 0 – 4000 Hz à la bande 0 – 8000 Hz. Dans le cas où l’on fait l’extension à partie de la bande téléphonique en utilisant un repliement spectral par deux, on obtient un « trou » dans la bande 3500 Hz à 4500 Hz[9].

Une méthode alternative consiste à utiliser une distortion non linéaire dans le domaine temporel, produisant ainsi des harmoniques dans la bande haute. La fonction « valeur absolue » (redresseur pleine-onde) constitue un bon choix pour cette fonction non linéaire[11], car elle est très peu complexe à calculer et affecte peu l’amplitude du signal (contrairement à la fonction x^2). Comme le spectre du signal d’excitation après redressement (fig. 4.2b) n’est plus plat comme il doit l’être (voir section 2.1), il est nécessaire de le filtrer de manière à le rendre plat (fig. 4.2c). Ceci peut être accompli en utilisant un filtre LPC[12, 13], après quoi il est nécessaire de renormaliser le signal de telle sorte que l’énergie dans la bande téléphonique demeure la même que pour l’excitation originale.

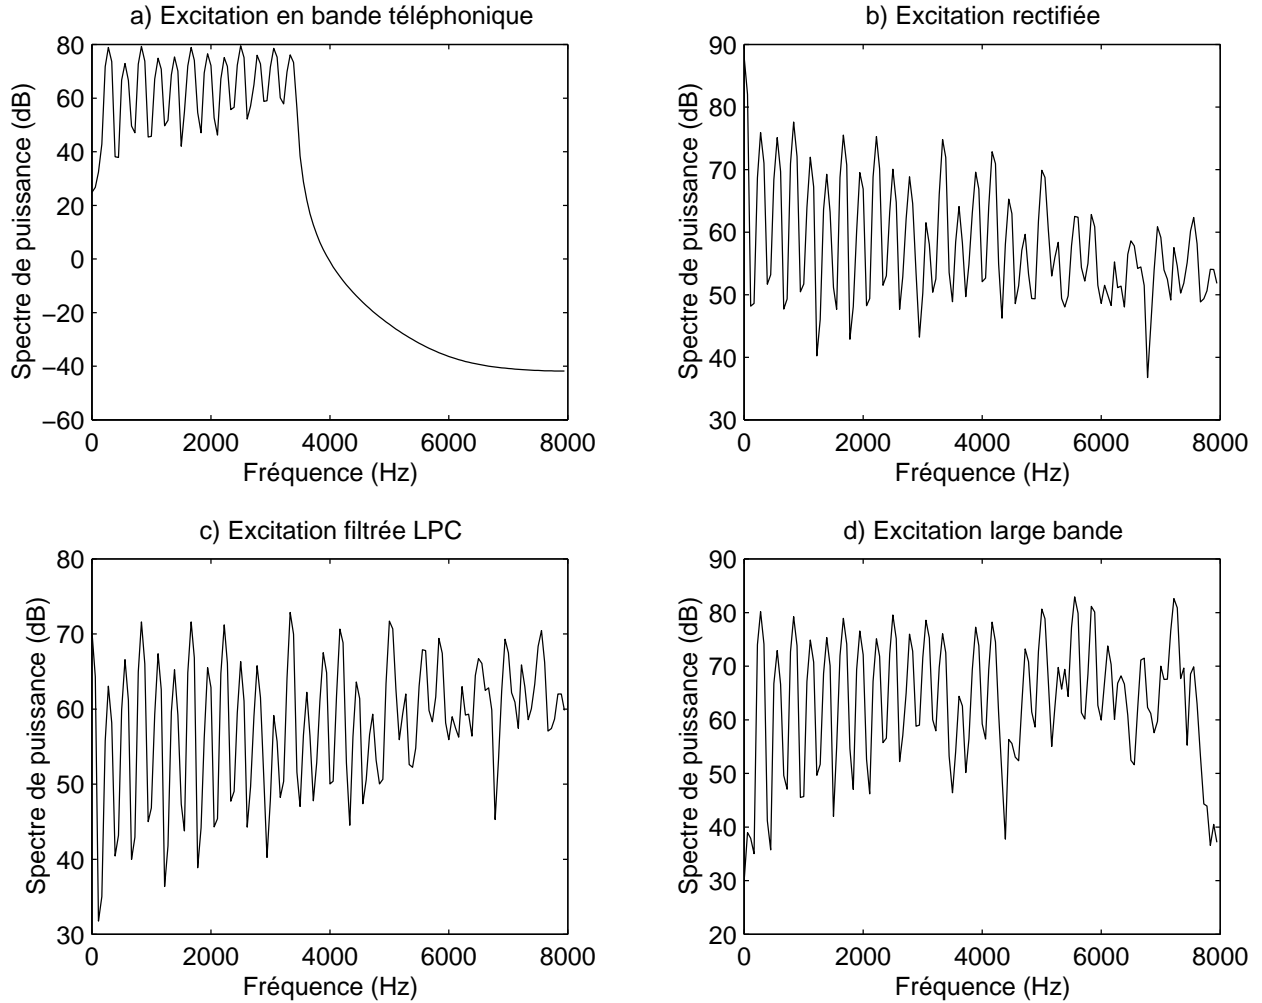


FIGURE 4.2 – Spectre du signal d’excitation à différentes étapes du processus d’extension. (a) Excitation filtrée passe-bas à 3500 Hz. (b) Excitation redressée. (c) Excitation redressée, filtrée par le filtre LPC. (d) Excitation originale large bande.

On voit que le signal résultant est très semblable au signal d’excitation large bande original (fig. 4.2d). Il faut noter que les distorsions produites aux fréquences inférieures à 3500Hz n’auront pas d’effet sur le signal reconstruit, puisque le résultat de l’extension aux hautes fréquences est filtré passe-haut (fig. 4.1) avant d’être combiné au signal original en bande téléphonique (fig. 3.1).

4.2.2 Application au codage large bande

En plus de l’application au présent problème de l’extension spectrale, la méthode d’extension de l’excitation présentée à la section 4.2.1 peut avoir des applications pour le codage de la parole large bande. En effet, certaines expériences montrent que lorsque l’on utilise le filtre

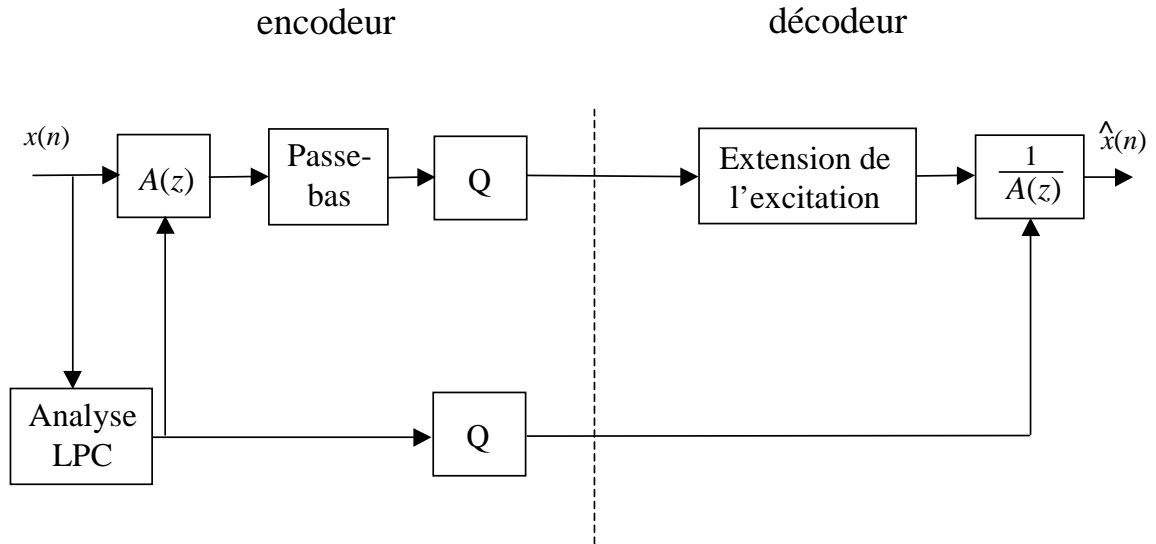



FIGURE 4.3 – Codeur large bande utilisant l’extension de l’excitation. L’enveloppe spectrale est codée dans la bande 0 – 8000 Hz, l’excitation est codée dans la bande 0 – 4000 Hz.

LPC calculé sur le signal large bande et que l’on effectue l’extension de l’excitation entre 3500 Hz et 7000 Hz, le signal résultant est presque impossible à distinguer de l’original.

Ceci rend la technique intéressante pour le codage large bande, car il serait alors possible de coder l’excitation jusqu’à 3500 Hz seulement, réduisant ainsi l’information transmise. La figure 4.3 illustre le mode de fonctionnement d’un codeur qui utiliserait l’extension de l’excitation afin de ne coder que la bande basse de l’excitation, diminuant ainsi le débit tout en maintenant la qualité de la parole.

La constatation du haut niveau de qualité obtenue pour l’extension de l’excitation avait aussi été faite pour un système utilisant le modèle sinusoïdal[10], rendant les deux modèles équivalents, puisque la qualité du résultat dépend essentiellement de la qualité de l’extension de l’enveloppe spectrale. Le résultat de l’extension de l’excitation peut être observé sur le spectrogramme de la figure 4.4. Tout comme lors de l’écoute, on note très peu de différence entre le spectrogramme du signal original et celui du signal avec extension de l’excitation. Le spectrogramme montre aussi que la structure harmonique du signal dans les hautes fréquences est en général bien reconstruite.

Il est important de savoir que, étant donné le modèle utilisé, le système de codage par extension de l’excitation présenté à la figure 4.3 ne peut fonctionner correctement que pour la parole. Aussi, les résultats de l’extension pour un signal musical sont plutôt mauvais. Toutefois, il est possible d’appliquer la méthode au codage de signaux musicaux haute-fidélité échantillonnés à 44,1 kHz pour faire l’extension entre 11 kHz à 22 kHz. Comme l’oreille



P a r a l l é l i s m e e t o r t h o g o n a l i t é
(Parallélisme et orthogonalité)

FIGURE 4.4 – Résultat de l’extension de l’excitation lorsque l’enveloppe spectrale est préservée. Le spectrogramme du signal de parole reconstruit (a) est comparé à celui du signal original (b).

humaine est très peu sensible à ces fréquences, même des signaux de musique codés ainsi conservent une bonne qualité. Des expériences préliminaires ont montré qu’il était possible d’obtenir une qualité sonore acceptable en n’utilisant que 345 *bits/s* (8 *bits/trame*, pour des trames de 1024 échantillons) pour quantifier l’enveloppe spectrale haute (11 – 22 kHz).

4.3 Extension de l’enveloppe spectrale

L’extension hautes fréquences de l’enveloppe spectrale consiste à estimer un filtre LPC large bande ($F_e = 16$ kHz) à partir d’un filtre LPC en bande téléphonique ($F_e = 8$ kHz) et de quelques paramètres additionnels, calculés aussi sur la bande téléphonique. Ce problème général est connu sous le nom d’*hétéro-association* soit l’association entre un ensemble de formes d’entrée et un ensemble de formes de sortie[14].

Lors de l’extension de l’enveloppe, les coefficients LPC calculés sur la bande téléphonique

sont convertis en une enveloppe spectrale. Cette enveloppe, ainsi que d'autres paramètres, sont utilisés comme entrée de l'algorithme d'extension de l'enveloppe spectrale grâce auquel, on obtient l'enveloppe hautes fréquences. Les deux bandes sont ensuite concaténées pour obtenir une enveloppe spectrale large bande, qui est finalement convertie en un filtre LPC large bande. C'est ce filtre qui sera utilisé, autant pour l'analyse que pour la synthèse.

4.3.1 Mesure de distorsion spectrale

Avant de décrire l'extension de l'enveloppe spectrale, il est nécessaire d'introduire la notion de distorsion spectrale qui sera utilisée comme mesure d'erreur quantitative pour cette partie. De façon générale, pour une trame k donnée, la distorsion spectrale D_k , exprimée en dB, entre la vraie enveloppe spectrale $A_k(\omega)$ et une approximation $\tilde{A}_k(\omega)$ est :

$$D_k = \sqrt{\frac{1}{\omega_2 - \omega_1} \int_{\omega_1}^{\omega_2} \left[20 \log_{10} \left| \frac{A_k(\omega)}{\tilde{A}_k(\omega)} \right| \right]^2 d\omega} \quad (4.2)$$

où $[\omega_1, \omega_2]$ est l'intervalle de fréquence pour lequel on mesure la distorsion spectrale. Par exemple, pour mesurer la distorsion spectrale dans le bande haute, on utilise $\omega_1 = 3500$ Hz et $\omega_2 = 8000$ Hz.

La distorsion spectrale totale pour un ensemble de trames est la moyenne en quadrature des distorsions spectrales individuelles, soit :

$$D = \sqrt{\frac{1}{K} \sum_{k=1}^K [D_k]^2} \quad (4.3)$$

4.3.2 Représentation de l'enveloppe spectrale

Afin de faciliter le traitement de l'enveloppe spectrale, tous les calculs d'extension de l'enveloppe sont effectués dans le domaine fréquentiel plutôt que dans le domaine des coefficients de prédiction a_i . On utilise donc la transformation présentée à l'équation 2.16 pour représenter le filtre de synthèse $\frac{1}{A(z)}$. Lors du traitement, la bande complète 0 – 8000 Hz est divisée en un spectre $S_{lb}(k)$ de 64 points¹, soit à intervalle de $\frac{8000 \text{ Hz}}{64} = 125$ Hz. De la même manière, la bande 0 – 4000 Hz est divisée en un spectre $S_{bt}(k)$ de 32 points, pour conserver le même intervalle entre les points. Pour la bande téléphonique, on n'utilise que les points $S_{bt}(k)$, $2 \leq k \leq 28$, soit la partie correspondant à la bande 250–3500Hz. Pour la bande haute,

1. La transformée de Fourier discrète est donc calculée sur 128 points.

prédite à partir du signal en bande téléphonique, on garde les points $S_{tb}(k)$, $24 \leq k \leq 63$, soit la bande 3000 – 8000 Hz.

Comme le spectre du filtre de synthèse est échantillonné à intervalles de 125 Hz, on doit s'assurer que ses résonances aient une largeur de bande d'au moins 250 Hz afin de bien modéliser l'enveloppe spectrale². Ceci peut être contrôlé par le paramètre β utilisé pour le *lag windowing* (section 2.2.2). De même, afin de réduire la dynamique de l'enveloppe spectrale, on la considère dans le domaine logarithmique. Ceci a comme avantage de placer le problème dans un domaine plus proche du domaine de perception de l'oreille.

Il est souvent désirable de réduire le nombre de dimensions nécessaires pour traiter un signal (dans ce cas, l'enveloppe spectrale). Ceci peut être accompli en utilisant une transformation linéaire ne conservant que les composantes principales du signal. La transformation optimale pour un signal donné peut être obtenue par analyse en composante principale[15]. Cependant, pour l'enveloppe spectrale d'un signal de parole, la transformée en cosinus discrète (DCT) est presque optimale et il existe des algorithmes pouvant calculer cette transformée en un temps $\mathcal{O}(n \log_2 n)$. De plus, la transformée en cosinus du spectre dans le domaine logarithmique n'est autre que le cepstre réel du signal de parole.

Les coefficients c_k de la transformée en cosinus du signal x_i sont :

$$c_k = \begin{cases} \sqrt{\frac{1}{N}} \sum_{i=0}^{N-1} x_i & k = 0 \\ \sqrt{\frac{2}{N}} \sum_{i=0}^{N-1} x_i \cos \frac{\pi(2i+1)k}{N} & k \neq 0 \end{cases} \quad (4.4)$$

Il reste ensuite à déterminer le nombre N de coefficients de la DCT qu'il sera nécessaire de garder. La figure 4.5 montre la quantité d'information perdue (sous forme de distorsion spectrale) en fonction du nombre de coefficients de la DCT que l'on considère. Pour la bande téléphonique, on gardera 10 coefficients, ce qui correspond à une distorsion spectrale de 0,2 dB. On voit clairement que 10 coefficients représentent presque parfaitement l'enveloppe spectrale en bande téléphonique.

Pour la bande haute, on gardera 8 coefficients, ce qui correspond à une distorsion spectrale de 0,8 dB. Bien que plus élevée que pour la bande téléphonique, quelques tests perceptuels ont montré que l'utilisation de plus de 8 coefficients de DCT n'améliore plus la qualité sonore. La figure 4.6 montre, pour une trame donnée la différence entre le spectre réel et le spectre tel que représenté par la DCT avec un 10 coefficients pour la bande téléphonique et 8 coefficients pour la bande haute.

2. Cette condition est semblable à celle imposée pour l'échantillonnage d'un signal temporel, où le signal doit être préalablement filtré à la fréquence de Nyquist, $F_e/2$.

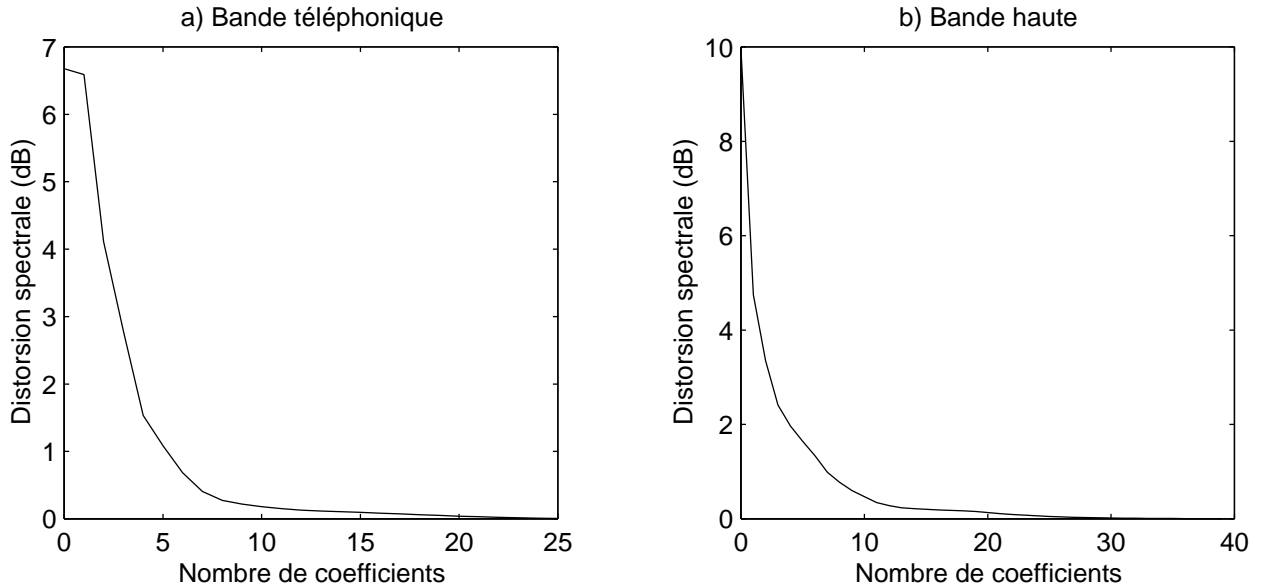


FIGURE 4.5 – Distorsion spectrale obtenue en fonction du nombre de coefficients de la DCT gardés (a) pour la bande téléphonique et (b) pour la bande haute.

Le nombre réduit de coefficients obtenu grâce à la DCT comporte plusieurs avantages. D’abord, le temps de calcul est réduit, étant donné le plus petit nombre de valeurs à traiter. Ensuite, certains systèmes sont sensibles au nombre de dimensions impliquées dans le problème³. C’est le cas des perceptrons multi-couches[15], dont l’entraînement se trouve facilité du nombre réduit de dimensions à traiter.

4.3.3 Extraction de paramètres vocaux

En plus de l’enveloppe spectrale dans la bande téléphonique, d’autres caractéristiques de la voix peuvent être utiles afin de trouver l’enveloppe spectrale aux hautes fréquences. Un de ces paramètres est le gain de pitch. Celui-ci contient de l’information permettant de discriminer facilement les voyelles des autres phonèmes. La période T du pitch elle-même peut aussi être utile pour son information sur le sexe du locuteur, mais comporte certains inconvénients. En effet, la période du pitch n’est définie que pour les trames voisées, ce qui a pour conséquence que pour les trames non voisées ou peu voisées, la valeur est mal définie. On verra plus loin que l’utilisation de la période T peut nuire à l’entraînement du système, selon le modèle utilisé.

En plus des paramètres liés au pitch, on peut extraire de l’information pertinente des variations temporelles du signal. On peut, par exemple calculer la dérivée temporelle de

3. Ce problème est connu sous le nom de *curse of dimensionality*




FIGURE 4.6 – Enveloppe spectrale telle que représentée par (a) 10 coefficients dans le bande téléphonique (b) 8 coefficients dans la bande haute

l'énergie du signal et de la forme du spectre.

Au total, on choisit donc 17 paramètres vocaux soit :

- 10 coefficients cepstraux (DCT) dans la bande téléphonique (coefficients 0 à 9)
- Gain du pitch
- Période du pitch
- Dérivée temporelle de l'énergie de l'excitation (domaine logarithmique)
- 4 coefficients différentiels du cepstre (coefficients 0 à 3)

Le même vecteur de paramètres vocaux est utilisé pour l'entraînement de tous les systèmes, sauf dans les cas où un paramètre nuit visiblement à l'entraînement (ce paramètre est alors ignoré).

4.3.4 État de l'art

L'extension hautes fréquences de l'enveloppe spectrale est, sans contredit, la partie la plus complexe de ce projet. Elle nécessite en effet une hétéro-association entre un vecteur de paramètres vocaux et le vecteur de l'enveloppe spectrale haute. Les approches explorées jusqu'à maintenant se divisent en trois grandes catégories, soit :

- Régressions[5]
- Dictionnaires associatifs (*codebook mapping*)[5, 6]
- Méthodes statistiques[8, 9].

Pour ce qui suit, le vecteur de paramètres vocaux calculé sur la bande téléphonique sera noté par \mathbf{x} et le vecteur de la partie haute de l'enveloppe spectrale sera noté par \mathbf{y} .

La méthode de la régression linéaire est la plus simple et consiste à approximer le vecteur des hautes fréquences $\hat{\mathbf{y}}$ par une combinaison linéaire des paramètres vocaux \mathbf{x} en bande téléphonique⁴, soit :

$$\hat{\mathbf{y}} = \mathbf{W}\mathbf{x} \quad (4.5)$$

où \mathbf{W} est la matrice de régression. Soient \mathbf{X} et \mathbf{Y} des matrices contenant toutes les données d'entraînement et dont les lignes sont respectivement l'ensemble des vecteurs \mathbf{x} et \mathbf{y} , on désire trouver la matrice \mathbf{W} qui minimise $\|\mathbf{Y} - \mathbf{W}\mathbf{X}\|^2$. La solution peut être obtenue grâce à la méthode du pseudo-inverse, soit :

$$\mathbf{W} = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}\mathbf{Y} \quad (4.6)$$

L'article de Epps et Holmes[5] montre que l'extension de l'enveloppe spectrale par un dictionnaire associatif (*codebook mapping*) produit de meilleurs résultats que la régression linéaire, surtout si l'on tient compte du gain de pitch. Un dictionnaire associatif consiste en un quantificateur vectoriel sur des formes d'entrée (paramètres vocaux) qui associe à chaque code un vecteur de sortie pour les hautes fréquences $\hat{\mathbf{y}}$.

À la base d'un dictionnaire associatif se trouve un quantificateur vectoriel sur l'ensemble de départ, soit les paramètres vocaux en bande téléphonique. Le quantificateur vectoriel est alors utilisé comme classificateur, séparant l'espace d'entrée en régions de Voronoï, chacune ayant comme centroïde un des vecteurs représentant \mathbf{x}_i du quantificateur. Le quantificateur vectoriel peut être entraîné par l'algorithme LBG[16].

Chaque région de Voronoï, centrée sur un représentant \mathbf{x}_i de l'ensemble d'entrée, est associée à un vecteur \mathbf{y}_i de l'ensemble d'arrivée (fig. 4.7). Pour chaque vecteur d'entrée \mathbf{x} , on trouve le centroïde \mathbf{x}_i qui minimise la distance $(\mathbf{x} - \mathbf{x}_i)^2$ et on utilise \mathbf{y}_i comme approximation du vecteur hautes fréquences, soit :

$$\hat{\mathbf{y}} = \mathbf{y}_i, \quad i = \min_k (\mathbf{x} - \mathbf{x}_i)^2 \quad (4.7)$$

Les paramètres vocaux aux basses fréquences, utilisés comme « clé » du dictionnaire associatif, peuvent être des coefficients de l'enveloppe spectrale elle-même[5] ou des coefficients MFCC (*Mel frequency cepstral coefficients*) calculés sur l'enveloppe basses fréquences

4. Le vecteur \mathbf{x} est augmenté du coefficient 1 afin d'ajouter un terme constant à la régression linéaire

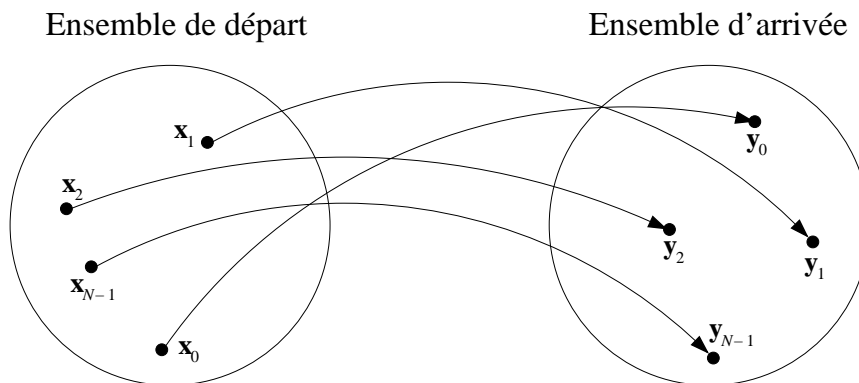


FIGURE 4.7 – Dictionnaire associatif

(200–3500 Hz)[6]. De plus, il a été montré que le fait d'utiliser l'information du pitch améliore les résultats de l'extension[5]. Dans le cas présent, on utilise les mêmes vecteurs de paramètres vocaux que pour la régression, à l'exception de la période du pitch T et des coefficients cepstraux différentiels qui nuisent à la performance du dictionnaire associatif. Aussi, comme le quantificateur vectoriel utilise la mesure de distance euclidienne et que le paramètre de gain de pitch β est de faible dynamique (généralement, $0 \leq \beta \leq 1$), on trouve que le fait d'utiliser 4β comme paramètre produit de meilleurs résultats.

Des méthodes statistiques ont aussi été proposées pour résoudre le problème de l'extension de l'enveloppe. Il s'agit soit de mélanges de gaussiennes (GMM) [8] soit de chaînes de Markov et de GMM[9].

La méthode statistique présentée par Ming, O'Shaughnessy et Mermelstein[8] consiste à quantifier les vecteurs d'enveloppe d'entrée et de sortie et à calculer une fonction de probabilité $f(\mathbf{y}_j | \mathbf{x}_i)$, soit la probabilité d'observer la sortie (hautes fréquences) \mathbf{y}_j , connaissant l'entrée (basses fréquences) \mathbf{x}_i . La fonction $f(\mathbf{y}_j | \mathbf{x}_i)$ est approximée par une mixture de fonctions gaussiennes, soit :

$$f = \sum_{i=0}^{N-1} a_i \exp \left[\frac{(\mathbf{x} - \bar{\mathbf{x}}_i)^2}{\sigma^2} \right].$$

4.3.5 Réseaux de neurones

Une autre méthode, entrant dans la catégorie des régressions non linéaires, est utilisée ici pour l'extension de l'enveloppe spectrale. Il s'agit des réseaux de neurones, ou plus précisément des perceptrons multi-couches. Il est prouvé que les perceptrons utilisant plus d'une couche cachée et respectant certaines contraintes entrent dans la catégorie des approximateurs universels, c'est-à-dire qu'il peuvent approximer avec une précision arbitraire n'importe quelle fonction[15]. L'unité de base d'un perceptron multi-couches est appelée « neurone » ou parfois




FIGURE 4.8 – Neurone, unité de base d’un perceptron. La somme pondérée des entrées est calculée et une fonction d’activation non linéaire est appliquée au résultat pour calculer la sortie

simplement « unité ». Un neurone comporte plusieurs entrées x_i et une sortie y . La sortie y est calculée en appliquant une fonction non linéaire $\phi(x)$, nommée « fonction d’activation », à la somme pondérée de ses entrées x_i (fig. 4.8), soit :

$$y = \phi \left(\sum_{i=0}^{N-1} w_i x_i + b \right) \quad (4.8)$$

où \mathbf{w} est le vecteur de poids et la valeur b est appelée biais. Le biais peut-être considéré comme un poids dont l’entrée correspondante est la constante 1. La fonction d’activation $\phi(x)$ la plus souvent utilisée est la tangente hyperbolique :

$$\phi(x) = \tanh(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (4.9)$$

Toutefois, comme on le verra plus loin, il est dans certains cas préférable d’utiliser une fonction d’activation linéaire ($\phi(x) = x$).

Un perceptron multi-couches est constitué d’un ensemble de neurones arrangés sous forme de couches. Tous les neurones d’une couche sont reliés à tous les neurones de la couche précédente, tel qu’illustré à la figure 4.9. À chaque connexion et à chaque biais est associé un poids w_i et l’entraînement du perceptron consiste à ajuster le vecteur de poids \mathbf{w} de manière à minimiser l’erreur entre la sortie du perceptron et la sortie désirée. On minimise généralement la fonction d’erreur :

$$E = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (\hat{y}_{ij} - y_{ij})^2 \quad (4.10)$$

où M est le nombre d’exemples d’entraînement et N est le nombre de dimensions du vecteur de sortie⁵.

5. Dans le cas présent, $N = 8$ car on garde 8 coefficients de la DCT pour la bande haute.




FIGURE 4.9 – Exemple de perceptron à une couche cachée. Le perceptron comprend 4 entrées, 5 unités sur la couche cachée, et 3 sorties. Les différentes couches sont entièrement connectées.

L'entraînement d'un perceptron multi-couches devient donc un problème d'optimisation du vecteur de poids \mathbf{w} . La méthode d'optimisation la plus employée pour les perceptrons est appelé « algorithme de rétro-propagation » (*back-propagation*) et est en fait l'algorithme itératif de descente du gradient qui s'énonce :

$$w_i^{j+1} = w_i^j - \eta \frac{\partial E}{\partial w_i} \quad (4.11)$$

où w_i^j est le $i^{\text{ème}}$ poids pour l'itération j et η est appelé « pas d'apprentissage » (*learning rate*). Le pas d'apprentissage est un paramètre important de l'algorithme de rétro-propagation. Plus η est élevé, plus le réseau apprend rapidement, mais une valeur trop grande rend l'algorithme d'entraînement instable.

En se référant à la figure 4.9, on voit que pour la couche de sortie, pour un seul exemple d'entraînement donné :

$$\frac{\partial E}{\partial w_{ij}} = \frac{d\phi(z_i)}{dz_i} h_j (\hat{y}_i - y_i) \quad (4.12)$$

où w_{ij} est le poids pour l'entrée j du neurone de sortie i et z_i est la somme pondérée des entrées. Si la fonction d'activation est la tangente hyperbolique, la dérivée s'exprime comme :

$$\frac{d\phi(z)}{dz} = \frac{1}{\cosh^2 z} = 1 - [\phi(z)]^2 \quad (4.13)$$

ce qui facilite les calculs. Bien entendu, si la fonction d'activation est linéaire, alors $d\phi(z)/dz = 1$. Pour les neurones d'une couche cachée, le principe demeure le même, alors que l'on applique la règle de dérivation en chaîne pour trouver $\frac{\partial E}{\partial w}$.

Bien que très simple, l'algorithme de rétro-propagation a une convergence très lente, ce qui rend peu intéressante son utilisation en pratique. C'est pour cette raison qu'on utilise plutôt

l'algorithme *delta-bar-delta* pour lequel un pas d'apprentissage η_i est associé à chaque poids w_i du réseau et peut être adapté au cours de l'entraînement.

Lors de l'entraînement, il est possible de constater que, comme suggéré à la sous-section 4.3.3, l'utilisation de la période du pitch T nuit à la convergence de l'algorithme. Ce paramètre est donc éliminé du vecteur de paramètres vocaux pour l'entraînement des réseaux de neurones.

4.4 Résultats

L'ensemble d'entraînement comprend une heure et quarante minutes de parole large bande sans les silences, alors que l'ensemble de validation comprend quarante minutes de parole, toujours sans les silences.

4.4.1 Régression linéaire

Les résultats obtenus pour l'extension de l'enveloppe spectrale par régression linéaire montrent une distorsion spectrale de 7,28 dB sur l'ensemble d'entraînement et de 7,24 dB sur l'ensemble de validation. Cette méthode, bien que peu performante, est surtout utilisée comme point de référence pour évaluer les résultats des autres méthodes. Par exemple, un réseau de neurones qui n'atteindrait pas au moins les performances de la régression linéaire sur l'ensemble d'entraînement serait rejeté. Cela indiquerait en effet que l'optimisation aurait convergé vers un minimum local bien loin du minimum global.

4.4.2 Dictionnaires associatifs

La figure 4.10 montre les performances d'extension de l'enveloppe pour différents dictionnaires associatifs de taille allant de 4 à 2048 vecteurs. Avec plus de 2048 vecteurs, le modèle devient trop complexe pour être implanté dans un système fonctionnant en temps-réel. Il est tout de même clair que cette méthode performe mieux qu'une simple régression linéaire.

4.4.3 Perceptron multi-couches

La figure 4.11 montre les performances des perceptrons multi-couches. On remarque rapidement que même les perceptrons les plus simples performant mieux que le dictionnaire associatif le plus complexe évalué. On note toutefois qu'avec l'augmentation du nombre d'unités

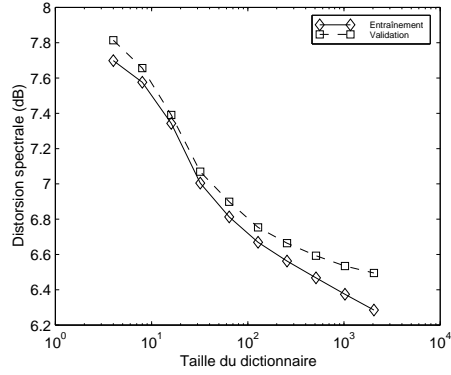


FIGURE 4.10 – Distorsion spectrale dans la bande haute sur l'ensemble d'entraînement et l'ensemble de validation en fonction de la dimension du dictionnaire associatif




FIGURE 4.11 – Performances des perceptrons multi-couches en fonction du nombre d'unités et de couches cachées

cachées dans le perceptron, la différence entre l'erreur sur l'ensemble d'entraînement et l'erreur sur l'ensemble de validation s'accroît. Pour entraîner un perceptron avec plus de 30 unités cachées par couche, il faudrait vraisemblablement augmenter la taille de l'ensemble d'entraînement afin de réduire les effets de sur-généralisation.

4.4.4 Analyse de complexité

Il est toujours possible de diminuer l'erreur de prédiction d'un modèle sur son ensemble d'entraînement en complexifiant le modèle. Toutefois, si on se réfère au rasoir d'Occam, les modèles simples sont souvent les meilleurs⁶. En général, un compromis est nécessaire entre la complexité d'un modèle et la précision de la prédiction. En effet, un modèle trop complexe comporte les inconvénients suivants :

- mémoire nécessaire importante ;

6. « Les choses essentielles ne doivent pas être multipliées sans nécessité »

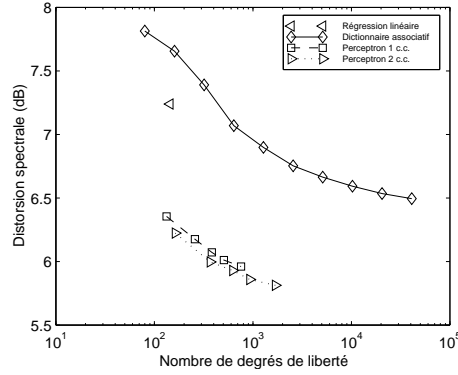


FIGURE 4.12 – Performances des différents modèles en fonction du nombre de degrés de liberté

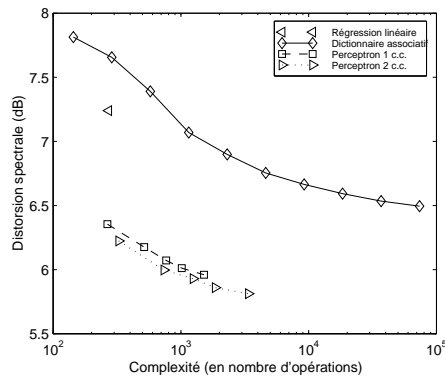



FIGURE 4.13 – Performances des différents modèles en fonction de leur complexité algorithmique

- temps de calcul important ;
- mauvaise généralisation.

Afin de contrôler en partie la capacité de généralisation d'un réseau de neurones, on se réfère toujours à l'erreur de prédiction (distorsion spectrale) sur l'ensemble de validation qui doit contenir des locuteurs différents de l'ensemble d'entraînement. La figure 4.12 montre l'erreur de prédiction obtenue en fonction de la complexité du modèle, telle que donnée par le nombre de degrés de liberté du modèle. La figure 4.13, quant à elle, utilise le nombre d'opérations par trame comme mesure de complexité.

On constate clairement qu'à complexité égale, les réseaux de neurones performant beaucoup mieux que les dictionnaires associatifs. De plus, les réseaux à deux couches cachées performant légèrement mieux que ceux à une seule couche cachée, toujours à complexité égale.



Parallélisme et orthogonalité
(Parallélisme et orthogonalité)

FIGURE 4.14 – Résultat de l’extension de la bande haute. Le spectrogramme du signal de parole reconstruit (a) est comparé à celui du signal dont seule l’excitation a été reconstruite (b) (enveloppe spectrale de l’original).

4.4.5 Reconstruction de la bande haute

Les spectrogrammes à la figure 4.14 illustrent bien l’effet de l’extension de l’enveloppe spectrale haute. Bien qu’en général, l’enveloppe haute reconstruite suit bien l’enveloppe originale, on note certains artefacts. Par exemple, on remarque que dans la reconstruction le /s/ de « parallélisme » manque un peu d’énergie. Ceci est perçu lors de l’écoute comme un son à mi-chemin entre un /s/ et un /f/, ce qui est quelque peu désagréable.

De plus on note que certaines voyelles ont trop d’énergie en hautes fréquences ; c’est le cas du phonème /o/ dans « orthogonalité » (le deuxième « o »). Cet artefact est perçu comme une légère distorsion dans le signal.

4.5 Post-traitement

Afin de réduire certains artefacts produits lors de l’extension, comme ceux notés à la section 4.4.5, on applique quelques modifications au signal reconstruit. Ces modifications ont pour seul but de rendre moins perceptibles ces artefacts.

4.5.1 Lissage des variations dans l’enveloppe spectrale

Afin de réduire certains artefacts désagréables aux hautes fréquences, il est important de lisser les variations de l’enveloppe spectrale dans les hautes fréquences. Ainsi, chaque coefficient du vecteur de paramètres cepstraux de la bande haute est filtré par un FIR à trois coefficients $H(z) = \frac{z+2+z^{-1}}{4}$. Ce filtre simple permet d’éliminer la majorité des artefacts dus aux changements brusques du spectre. Pour cette raison, il n’est pas nécessaire d’utiliser des méthodes plus complexes comme les chaînes de Markov.

4.5.2 Atténuation de la bande haute reconstruite

Tous les systèmes explorés précédemment minimisent le critère d’erreur quadratique (MMSE), ce qui fait que l’enveloppe spectrale estimée est « en moyenne » juste. Toutefois, dans la plupart des cas, l’erreur perceptuelle causée par une sous-estimation de l’énergie dans les hautes fréquences est beaucoup moins importante que celle causée par une sur-estimation, cette dernière étant généralement perçue comme du bruit ou de la distorsion.

Ce sont justement les sur-estimation de l’enveloppe spectrale qui affectent le plus la qualité du signal avec la bande haute reconstruite. L’effet est encore plus marqué lorsque ces sur-estimations se trouvent entre 3500 Hz et 4500 Hz, c’est-à-dire dans une bande où l’oreille est particulièrement sensible.

Une manière d’améliorer la qualité perceptuelle du résultat de l’extension des hautes fréquences consiste à atténuer « artificiellement » les hautes fréquences reconstruites. De plus, comme il a été constaté que le fait de laisser un « trou » dans la bande de 3500 Hz à 4500 Hz n’est que peu perceptible [9], cette bande est coupée (fortement atténuée) de façon à réduire encore les effets des erreurs sur l’enveloppe spectrale haute.

L’effet combiné de l’atténuation et du « trou » dans la bande élimine en bonne partie les artefacts causés lors de l’extension de la bande haute.

4.6 Codage de l'enveloppe

Pour certaines applications, soit celles où on code déjà le signal en bande téléphonique, il peut être avantageux de « dépenser » quelques bits additionnels afin de corriger l'estimation de l'enveloppe spectrale pour la bande haute. Ainsi, en quantifiant l'erreur de prédiction de l'enveloppe spectrale, on peut réduire les artefacts dans la bande haute[13]. Par exemple, l'utilisation d'un quantificateur vectoriel à 256 entrées (soit 8 bits) permet de réduire la distorsion spectrale sur l'ensemble de validation de 5,81 dB à 1,83 dB.

Si on n'utilise pas la prédiction et que l'on code directement la bande haute sur 8 bits, on obtient alors une distorsion spectrale de 2,48 dB. Il faut un quantificateur vectoriel à 11 bits pour obtenir une distorsion spectrale équivalente à celle que l'on obtient avec prédiction (1,90 dB avec 11 bits). La prédiction par un réseau de neurones permet donc d'économiser environ 3 bits d'information lors du codage de l'enveloppe spectrale. Cette valeur peut être considérée comme une approximation de l'information mutuelle entre la bande téléphonique et la bande haute. Une autre évaluation de l'information mutuelle est donnée dans [17].

Chapitre 5

Extension des basses fréquences

5.1 Modèle utilisé

Le problème de l'extension de la bande basse diffère de ce celui de l'extension de la bande haute de trois principales façons :

1. la largeur de bande à reconstruire pour la bande basse est beaucoup plus petite (~ 150 Hz contre ~ 3500 Hz) ;
2. la sensibilité de l'oreille est beaucoup plus importante aux basses fréquences ;
3. le spectre aux basses fréquences est très harmonique.

De plus, il a été observé que la majeure partie de l'information audible aux basses fréquences est représentée seulement par les harmoniques du pitch. On se préoccupe donc seulement de ces harmoniques. Pour toutes ces raisons, le modèle sinusoïdal apparaît comme le plus approprié pour l'extension des basses fréquences. Par modèle sinusoïdal, on entend le fait de représenter un signal $x(t)$ (dans ce cas, les basses fréquences reconstruites) par une somme de N sinusoïdes, soit :

$$x(n) = \sum_{i=0}^{N-1} A_i \sin (\omega_i n + \phi_i) \quad (5.1)$$

Sachant que les harmoniques seront toujours des multiples de la fréquence du pitch ω_0 et que, même pour une voix grave ($\omega_0 \sim 70$ Hz), on trouve au plus deux harmoniques dans la bande 50 – 200 Hz, on peut exprimer la bande basse reconstruite $x_{bf}(n)$ comme :

$$x_{bf}(n) = A_0 \sin (\omega_0 n + \phi_0) + A_1 \sin (2\omega_0 n + \phi_1) \quad (5.2)$$

Le système d'extension de la bande basse doit donc estimer 5 paramètres, soit A_0 , ϕ_0 , A_1 , ϕ_1 , ω_0 . On peut séparer le problème en deux parties :

1. synthèse de deux sinusoïdes d'amplitude unitaire aux bonnes fréquences et phases ;
2. amplification des sinusoïdes à un niveau se rapprochant le plus possible de l'amplitude des sinusoïdes originales contenues dans le signal large bande.

Il faut noter que d'autres travaux sur l'extension de la bande basse ont utilisé un modèle filtre-excitation, plutôt qu'un modèle sinusoïdal[18]. La raison principale du choix d'un modèle sinusoïdal ici est la constatation que la partie stochastique du spectre sous 200 Hz est très peu audible, ce qui rend le modèle sinusoïdal plus adapté (parce que plus simple) que le modèle filtre-excitation.

5.2 Synthèse des sinusoïdes

La fréquence du pitch ω_0 utilisée pour les sinusoïdes peut être facilement estimée à partir de la bande téléphonique. En effet, soit $\omega_0 = \frac{2\pi}{T}$, il s'agit d'effectuer une analyse de pitch sur le signal en bande téléphonique. La méthode présentée à la section 2.3 permet d'évaluer la période T du pitch. Malheureusement, l'application directe de l'équation 2.27 rend l'estimation du pitch sensible à un phénomène appelé *dédoublément du pitch*, où la période du pitch T trouvée est le double de la période réelle. Le dédoublement du pitch affecte peu les codec de type CELP, qui compensent pour ces erreurs lors du codage de l'excitation. Cependant, lors de l'extension des basses fréquences, une erreur dans l'estimation du pitch se traduit directement par une erreur dans la fréquence des harmoniques générés.

Le phénomène de dédoublement du pitch peut être partiellement enrayeré par l'utilisation d'une résolution temporelle plus élevée lors de l'analyse[19, 20]. De plus, en ajoutant à l'algorithme une partie logique favorisant les délais de pitch moins élevés, on peut réduire encore les dédoublements du pitch.

Le problème des phases ϕ_0 et ϕ_1 est plus difficile à résoudre. Toutefois, comme l'oreille ne peut percevoir les phases de façon absolue, une première approximation consiste à imposer comme seule contrainte la cohérence de ϕ_0 et ϕ_1 entre les trames. Ainsi, on obtient deux générateurs sinusoïdaux modulés en fréquence pour « suivre » les deux premiers harmoniques du pitch. Le système complet d'extension des basses fréquences est donc celui montré à la figure 5.1.

5.3 Estimation de l'amplitude des sinusoïdes

Une fois les harmoniques générés, il est nécessaire d'estimer les bonnes amplitudes. Tout comme pour l'extension des hautes fréquences de l'enveloppe spectrale, il s'agit d'un problème

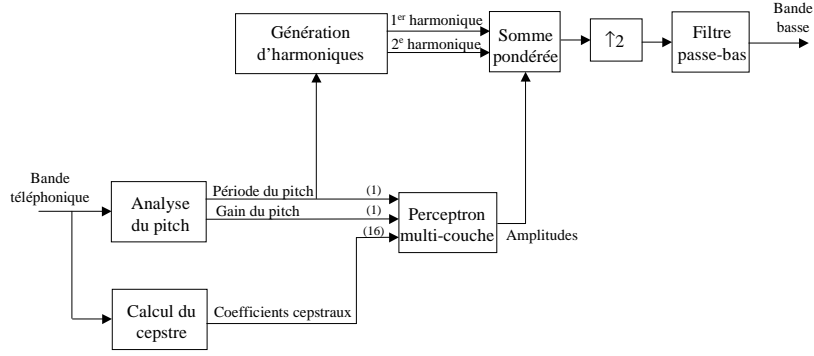


FIGURE 5.1 – Modèle sinusoïdal pour l’extension des basses fréquences

d’hétéro-association entre une forme d’entrée et le vecteur d’amplitude $\mathbf{a} = [A_0 A_1]^T$. Afin de faciliter leur modélisation, le vecteur \mathbf{a} est normalisé par l’énergie de l’excitation et représenté dans le domaine logarithmique, soit :

$$\tilde{\mathbf{a}} = \log \frac{\mathbf{a}}{\|r(n)\|} \quad (5.3)$$

où $r(n)$ est le signal d’excitation.

Lors de l’entraînement il est nécessaire d’évaluer les amplitudes normalisées $\tilde{\mathbf{a}}$ à partir des données originales large bande. Pour ce faire, le signal large bande est fenêtré Hanning avec un recouvrement de 100 %, de sorte à pouvoir utiliser le « recouvrement et addition » (*overlap and add*). Ce signal est représenté par des sinusoïdes fenêtrées de fréquences ω_0 et $2\omega_0$. Une trame fenêtrée \mathbf{x} est approximée par :

$$\tilde{\mathbf{x}} = \frac{1 - \cos \frac{2\pi n}{N}}{2} (g_0 + g_1 \cos \omega_0 n + h_1 \sin \omega_0 n + g_2 \cos 2\omega_0 n + h_2 \sin 2\omega_0 n) \quad (5.4)$$

où les paramètres g_k et h_k sont obtenus par la méthode des moindres carrés¹. Les amplitudes des sinusoïdes sont donc :

$$A_1 = \sqrt{g_1^2 + h_1^2} \quad (5.5)$$

$$A_2 = \sqrt{g_2^2 + h_2^2} \quad (5.6)$$

Par souci de simplicité, l’extension des basses fréquences utilise le même vecteur de paramètres vocaux que l’extension des hautes fréquences. La méthode utilisée pour effectuer l’hétéro-association peut toutefois être différente de celle utilisée pour la bande haute.

1. On ne peut utiliser la transformée de Fourier, car le nombre de périodes de pitch dans une trame n’est pas entier.

Des travaux comparant la méthode de la régression linéaire à celle des dictionnaires associatifs[18] pour l'extension de la bande basse ont conclu que la première méthode produisait des résultats significativement supérieurs à ceux de la seconde. Ces résultats concordent avec certaines expériences préliminaires effectuées avec des dictionnaires associatifs pour la bande basse. Pour ces raisons, seules deux méthodes sont évaluées ici, soit la régression linéaire et les réseaux de neurones.

5.4 Résultats quantitatifs

Le critère d'erreur utilisé (minimisé) pour l'estimation des paramètres basses-fréquences A_1 et A_2 est l'erreur quadratique moyenne $E = \sqrt{\frac{A_1^2 + A_2^2}{2}}$. Cette mesure est similaire à la mesure de distorsion spectrale pour l'enveloppe haute fréquence. Les données d'entraînement et de validation utilisées pour les basses fréquences sont les mêmes que celles utilisées pour les hautes fréquences.

5.4.1 Régression linéaire

En utilisant la régression linéaire, on obtient une distorsion spectrale de 3,65 dB sur l'ensemble d'entraînement et de 3,65 dB sur l'ensemble de validation. Ce résultat est comparable à ceux obtenus par Milet *et al.*[18], compte tenu des différences pouvant exister entre différentes bases de données vocales.

5.4.2 Réseaux de neurones

Comme il n'a pas été possible de faire converger les réseaux de neurones à deux couches cachées, seuls les résultats pour une seule couche cachée sont présentés ici. La figure 5.2 montre la distorsion spectrale obtenue pour différentes tailles de réseaux, lors de l'entraînement et de la validation. Or, il semble que même pour des perceptrons à une couche cachée, il soit difficile de bien faire converger l'apprentissage. Ceci est mis en évidence par le fait que les performances du perceptron à 10 unités cachées soit meilleures que celles du perceptron à 15 unités cachées.




FIGURE 5.2 – Performances des perceptrons multi-couches en fonction du nombre d’unités cachées

5.5 Utilisation des basses fréquences résiduelles

Bien que l’oreille soit insensible à la phase des signaux, la méthode de synthèse des sinusoïdes présentée à la section 5.2 produit d’importants artefacts. Ceci est dû au fait que dans la bande de transition entre la bande téléphonique et la bande basse reconstruite, on additionne une partie d’un harmonique de pitch original au même harmonique reconstruit avec une phase différente. Ceci crée des interférences audibles entre les deux harmoniques.

Bien que l’on considère généralement que la bande téléphonique commence à 200 Hz, on remarque que dans la plupart des cas, la bande 50 – 200 Hz n’est pas totalement atténuée. On retrouve encore, à un niveau plus faible, l’information basse fréquence originale. Il est donc intéressant de pouvoir récupérer cette information afin d’améliorer la qualité du signal de sortie. En effet, même atténuée de 20 dB ou plus, la bande basse contient toujours l’information de phase des harmoniques du pitch.

En calculant les paramètres g_k et h_k de l’équation 5.4 à partir d’une trame en bande téléphonique, on obtient deux sinusoïdes aux mêmes fréquences et phases que dans le signal original. Seules les amplitudes sont corrigées en utilisant l’estimation obtenue par la méthode choisie (section 5.3). Cette méthode réduit considérablement les artefacts dus aux erreurs de phase. Le système d’extension des basses fréquences ainsi modifié est illustré à la figure 5.3.

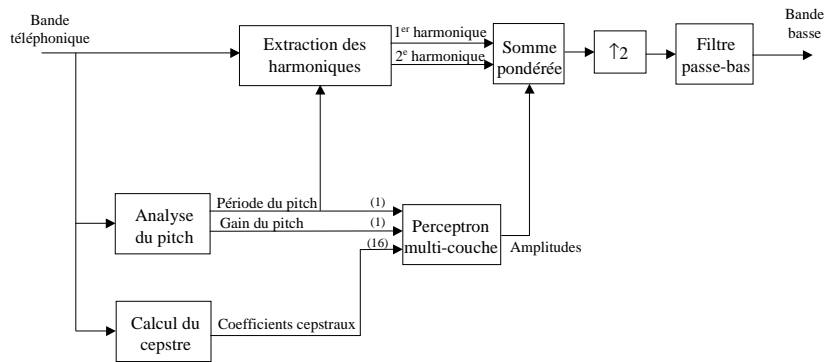


FIGURE 5.3 – Modèle sinusoïdal pour l’extension des basses fréquences avec extraction des harmoniques résiduelles

Chapitre 6

Résultats

6.1 Résultats quantitatifs

Le système d'extension de la bande comporte trois principales parties :

1. extension dans la bande basse (deux harmoniques) ;
2. extension de l'excitation dans la bande haute ;
3. extension de l'enveloppe spectrale dans la bande haute.

De ces trois parties, la deuxième, soit l'extension de l'excitation, ne se prête pas à une évaluation quantitative. En effet, comme le signal d'excitation comporte une grande partie aléatoire, on se contente de reproduire un signal d'excitation « plausible » qui soit agréable pour l'oreille.

Les meilleurs résultats pour l'extension des basses fréquences sont obtenus avec un réseau de neurones à une couche cachée comprenant 20 unités cachées. Dans ces conditions, l'erreur RMS est de seulement 2,49 dB (figure 5.2), ce qui est de beaucoup inférieur à la valeur obtenue par régression linéaire, soit 3,65 dB.

L'extension de la bande haute est de loin la partie la plus difficile à réaliser du système d'extension de la bande. En fait, la meilleure méthode explorée produit une distorsion spectrale de 5,81 dB (figure 4.11). Il s'agit d'un perceptron à deux couches cachées avec 30 unités par couche cachée. Bien que la mesure d'erreur utilisée pour les basses fréquences ne soit pas exactement une mesure de distorsion spectrale, il est clair que l'erreur pour les hautes fréquences est de beaucoup supérieure à celle pour les basses fréquences (5,81 dB pour les hautes fréquences, comparé à 2,49 dB pour les basses fréquences).

6.2 Résultats qualitatifs

Les résultats quantitatifs sont utiles lors de la conception pour comparer facilement différentes méthodes. Cependant, l'évaluation finale de la qualité de l'extension doit se faire de façon qualitative à partir de tests d'audition subjectifs.

6.2.1 Méthode expérimentale

La plupart des évaluations subjectives utilisées pour les codeurs de parole utilisent des tests MOS. Malheureusement, ces tests sont mal adaptés à une situation où l'on tente de comparer des échantillons en bande téléphonique à des échantillons large bande. Il est donc nécessaire de procéder à un autre type de test.

La méthode d'évaluation subjective retenue est la suivante. Pour chaque phrase, l'auditeur doit comparer une paire de phrases traitée avec le processus A à la même paire de phrases traitée avec le processus B. Les traitements A et B sont choisis de façon aléatoire parmi trois traitements possibles, soit :

1. aucun traitement, le signal large bande original est présenté ;
2. le signal est filtré en bande téléphonique avec le filtre IRS modifié ;
3. le signal large bande tel que produit par l'extension de la bande à partir du signal en bande téléphonique.

L'ordre dans lequel les fichiers sont présentés est choisi de façon aléatoire. Pour chaque paire, l'auditeur doit répondre à la question : « Lequel des deux fichiers préférez-vous ? ». Une question aussi générale est choisie parce qu'il existe une différence importante entre les trois différents types d'échantillons présentés. En effet, il est nécessaire que l'écoute ne se fasse pas à partir de critères précis comme la largeur de bande ou le niveau de distorsion, afin de ne pas biaiser les résultats vers un traitement ou un autre.

En plus de choisir le « meilleur » fichier, l'auditeur doit aussi quantifier sa préférence sur une échelle de 1 à 5, où 1 signifie « très légère préférence » et 5 signifie « très importante préférence ».

Le même test est administré avec un casque d'écoute et avec des haut-parleurs. Le test effectué avec casque d'écoute permet d'évaluer la qualité sonore pour des applications de téléphonie. Le test avec haut-parleurs vise à évaluer la qualité de l'extension pour des applications de communications par Internet à partir d'un ordinateur personnel muni de haut-parleurs.

Casque d'écoute	Moyenne	Écart-type	Préférence (%)
Extension vs. bande téléphonique	0,84	2,88	60
Large bande vs. extension	1,92	1,91	79
Large bande vs. bande téléphonique	2,84	1,64	88

TABLE 6.1 – Résultats des tests subjectifs avec écouteurs

Haut-parleurs	Moyenne	Écart-type	Préférence (%)
Extension vs. bande téléphonique	0,51	2,92	59
Large bande vs. extension	1,34	1,82	72
Large bande vs. bande téléphonique	1,84	2,68	76

TABLE 6.2 – Résultats des tests subjectifs avec haut-parleurs

Résultats cumulés	Moyenne	Écart-type	Préférence (%)
Extension vs. bande téléphonique	0,70	2,89	60
Large bande vs. extension	1,68	1,88	76
Large bande vs. bande téléphonique	2,38	2,23	83

TABLE 6.3 – Résultats cumulatifs des tests subjectifs

6.2.2 Résultats expérimentaux

Les résultats des tests perceptuels pour casque d'écoute et haut-parleurs sont présentés respectivement aux tableaux 6.1 et 6.2. Les résultats cumulatifs (casque d'écoute et haut-parleurs ensemble) sont présentés au tableau 6.3. Au total, 16 personnes ont participé aux tests avec casque d'écoute et 13 personnes ont participé aux tests avec haut-parleurs¹.

6.2.3 Analyse des résultats

Pour l'analyse des résultats, comme les résultats avec casque d'écoute sont très semblables aux résultats avec haut-parleurs (compte tenu de marge d'erreur due au nombre de personnes ayant participé aux tests), seuls les résultats combinés des deux expériences seront considérés (tableau 6.3).

D'abord, si on ne considère que les préférences moyennes, on constate que la préférence des signaux large bande, au détriment de la bande téléphonique (2,38), est égale à la somme des deux autres résultats ($0,70 + 1,68 = 2,38$)². On peut estimer que le processus d'extension de la bande retrouve *en moyenne* 30% ($\frac{0,70}{2,38} = 0,29$) de la qualité sonore perdue lors du filtrage dans la bande téléphonique. Un résultat semblable peut aussi être obtenu à partir des « taux

1. Ces deux ensembles ne sont pas disjoints

2. Le fait que le résultat soit parfaitement exact est toutefois l'effet du hasard.




FIGURE 6.1 – Distribution des préférences entre l’extension et la bande téléphonique a) Distribution par fichier écouté b) Distribution par auditeur

de préférence » (dernière colonne du tableau 6.3). En effet, considérant 50% comme taux de préférence neutre, on trouve $\frac{60\% - 50\%}{83\% - 50\%} = 0,30$.

Toutefois, en examinant les résultats, on constate que l’écart-type pour la comparaison entre l’extension et la bande téléphonique est très important, ce qui amène à examiner plus en détail la distribution des résultats. Celle-ci est illustrée à la figure 6.1. Il est clair que la distribution des préférences ne suit pas la courbe normale (gaussienne). On constate plutôt qu’il y a une importante variabilité en fonction de l’auditeur. Ainsi, en observant les résultats pour chaque auditeur, on constate que si le système d’extension avait été en option sur un téléphone, environ la moitié aurait choisi de l’utiliser³. On parle donc d’environ 50% d’*utilisateurs potentiels*. Le tableau 6.4 montre les résultats seulement pour ces personnes. On note que ces utilisateurs potentiels :

- considèrent que l’extension se rapproche plus du large bande que de la bande téléphonique ;
- apprécient plus la parole en large bande que la moyenne des participants (large bande vs. bande téléphonique).

On peut donc supposer que pour environ la moitié des gens, la largeur de bande est le principal facteur de qualité pour la parole, alors que pour l’autre moitié des gens, l’important est de limiter le bruit et la distorsion. En effet, d’après les commentaires de certains participants, les effets de distorsion dans la bande haute constitue la principale raison pour laquelle la bande téléphonique pouvait être préférée à l’extension.

3. On considère ici les auditeurs pour lesquels la moyenne pour la comparaison entre l’extension et la bande téléphonique est supérieure à zéro.

Utilisateurs potentiels	Moyenne	Écart-type	Préférence (%)
Extension vs. bande téléphonique	2,52	1,68	91
Large bande vs. extension	1,68	1,91	80
Large bande vs. bande téléphonique	2,97	1,90	91

TABLE 6.4 – Résultats pour les *utilisateurs potentiels*

Chapitre 7

Discussion et conclusion

Le système d'extension de la bande présenté permet de produire un signal reconstruit en bande AM (50 Hz à 7 kHz) à partir d'un signal d'entrée en bande téléphonique (200 Hz à 3,5 kHz). De plus, ce système peut fonctionner sur un signal filtré « IRS modifié ».

L'extension est effectuée de façon indépendante pour les hautes fréquences et les basses fréquences. La méthode retenue pour l'extension des hautes fréquences (chapitre 4) utilise le modèle filtre-excitation, ce qui divise le problème en deux parties : l'extension de l'excitation et de l'enveloppe spectrale. L'extension de l'excitation est réalisée dans le domaine temporel par une fonction non linéaire produisant des harmoniques aux hautes fréquences. Cette méthode permet d'obtenir un signal d'excitation presque impossible à distinguer de l'original. C'est cette constatation qui rend la technique intéressante pour le codage large bande à bas débit ou le codage « encastré ».

L'extension de l'enveloppe spectrale haute est effectuée dans le domaine cepstral. Plusieurs techniques ont été comparées, soit la régression linéaire, les dictionnaires associatifs et les perceptrons multi-couches. De ces trois techniques, les perceptrons produisent les meilleurs résultats, bien que leur complexité soit relativement faible.

L'extension de la bande basse utilise le modèle sinusoïdal et ne reconstruit que les deux premiers harmoniques du pitch. La fréquence de ces harmoniques est estimée par une analyse du pitch, alors que la phase est estimée à partir de l'information résiduelle dans la bande basse. Enfin, l'amplitude des sinusoïdes est estimée par un perceptron multi-couches.

7.1 Réalisation des objectifs initiaux

Une liste des objectifs visés pour le système d'extension de la bande est présentée à la section 1.4. Voici le degré d'atteinte de chacun de ces objectifs.

7.1.1 Qualité sonore

Les résultats des tests perceptuels montrent que les perceptions de qualité de la parole après extension de la bande varie de façon importante entre les différents participants. En effet, pour la moitié d'entre eux, l'extension de la bande produit une nette amélioration de la qualité alors que pour l'autre moitié, la qualité est réduite.

On pourrait donc envisager un service téléphonique ou un récepteur pour lequel l'extension de la bande serait une option pouvant être activée ou désactivée par l'utilisateur.

7.1.2 Complexité

La complexité totale du système proposé est estimée à environ 20 millions d'opérations en virgule-flottante (simple précision) par seconde. Ceci signifie qu'il est possible d'implanter l'algorithme sur un DSP. De plus, il faut noter que les multiplications sont la plupart du temps suivies d'une addition, ce qui améliore la performance sur la plupart des DSP.

Sur la complexité de 20 millions d'opérations par seconde, environ la moitié est due aux filtres. Tous les filtres utilisés sont des FIR d'ordre élevé et de type non causal. Il serait donc possible de réduire la complexité en optimisant mieux les filtres.

7.1.3 Délai algorithmique

Sauf lors de certaines analyses requérant l'utilisation de trames avec recouvrement et dans certains filtres non causals, le système d'extension décrit ici ne nécessite pas l'utilisation d'échantillons futurs du signal. Le délai algorithmique est donc faible, soit de l'ordre de deux trames, ce qui correspond à environ 32 *ms*. L'algorithme d'extension peut donc être utilisé dans un système de transmission de la parole en temps réel.

7.2 Limitations et perspectives de recherche

Le système d'extension de la bande présenté ici comporte certaines faiblesses. La principale vient du fait qu'il est insensible au contexte. Ainsi, seuls les paramètres de la trame courante sont utilisés pour déterminer l'extension. Or, on sait qu'il est très difficile de faire la reconnaissance de phonèmes de cette façon. C'est pourquoi les systèmes de reconnaissance vocale actuels utilisent des mots entiers, voire des phrases complètes pour effectuer la reconnaissance.

Dans un contexte de communication en temps-réel, il n'est malheureusement pas possible d'attendre la fin d'une phrase avant de faire l'extension. Toutefois, il serait toujours possible d'utiliser l'information sur le passé (système causal), et même ajouter un faible délai (moins d'une seconde).

Pour des applications sans contraintes de temps-réel tels des systèmes de messagerie vocale, il serait possible d'effectuer la reconnaissance de la parole sur chaque phrase et d'ensuite utiliser la segmentation en phonèmes comme entrée supplémentaire au système d'extension. Ceci permettrait entre autres de faire correctement l'extension des phonèmes /s/ et /f/, en utilisant le contexte. Par exemple, même si à partir d'une trame isolée, on ne peut discriminer un /s/ d'un /f/, on sait que le mot « statique » commence par un /s/ et non par un /f/.

Le post-traitement « perceptuel » utilisé dans le système d'extension pourrait aussi être amélioré. En effet, cette partie a fait l'objet de relativement peu de recherche. Une des principales améliorations potentielles consiste à appliquer un traitement différent pour chaque classe phonétique (voyelles, fricatives, ...). Aussi, il serait probablement possible de réduire la complexité du traitement, notamment en optimisant les filtres utilisés et en utilisant un meilleur algorithme de recherche du pitch.

Enfin, il serait intéressant d'évaluer plus en détail certaines applications « secondaires » de l'extension de la bande. Parmi ces applications, on compte l'utilisation de l'extension de l'excitation afin de réduire l'information transmise dans un codeur large bande. Aussi, certaines méthodes de prédiction pourraient être employées pour réduire le débit, comme présenté à la section 4.6.

Bibliographie

- [1] GOLUB, G. H. LOAN, C. F. V. *Matrix Computations*. The JOHN HOPKINS University Press, deuxième édition, 1989.
- [2] KLEIJN, W. B. PALIWAL, K. K. *Speech Coding And Synthesis*. Elsevier, 1995.
- [3] DELLER, R. J. Jr., PROAKIS, J. G., HANSEN, J. H. L. *Discrete-Time Processing of Speech Signal*. Macmillan, 1993.
- [4] TOHKURA, Y., ITAKURA, F., HASHIMOTO, S. Spectral smoothing technique in parcor speech analysis-synthesis. *IEEE Transactions on Acoustics, Speech and Audio Processing*, pages 587–596, 1979.
- [5] EPPS, J. HOLMES, W. H. A new technique for wideband enhancement of coded narrowband speech. *Proc. IEEE Speech Coding Workshop*, pages 174–176, 1999.
- [6] ENBOM, N. KLEIJN, W. B. Bandwidth expansion of speech based on vector quantization of the mel-frequency cepstral coefficients. *Proc. IEEE Speech Coding Workshop*, pages 174–176, 1999.
- [7] CHAN, C. F. HUI, W. Quality enhancement of narrowband CELP-coded speech via wideband harmonic. *Proc. IEEE Int. Conf. on Acoustics, Speech, Signal Processing*, pages 1087–1190, 1997.
- [8] MING, Y., O'SHAUGHNESSY, D., MERMELSTEIN, P. Statistical recovery of wideband speech from narrowband speech. *IEEE Transactions on Speech and Audio Processing*, pages 544–548, 1994.
- [9] JAX, P. VARY, P. Wideband extension of telephone speech using a hidden Markov model. *Proc. IEEE Speech Coding Workshop*, pages 133–135, 2000.
- [10] EPPS, J. HOLMES, W. H. Speech enhancement using stc-based bandwidth extension. *Proc. IEEE Int. Conf. on Spoken Language Processing*, 1998.
- [11] MAKHOUL, J. BEROUTI, M. High-frequency regeneration in speech coding systems. *Proc. IEEE Int. Conf. on Acoustics, Speech, Signal Processing*, pages 428–431, 1979.

- [12] WEINSTEIN, C. J. A linear prediction vocoder with voice excitation. *Proc. EASCON '75*, pages 30A–30G, 1975.
- [13] VALIN, J.-M. Bandwidth extension of narrowband speech for low bit-rate wideband coding. *Proc. IEEE Speech Coding Workshop*, pages 130–132, 2000.
- [14] MEHROTRA, K., MOHAN, C. K., RANKA, S. *Elements of Artificial Neural Networks*. The MIT Press, 1997.
- [15] HAYKIN, S. *Neural Networks A Comprehensive Foundation*. Prentice Hall, deuxième édition, 1999.
- [16] A., Gersho M., Gray R. *Vector Quantization and Signal Compression*. Kluwer Academic Publishers, 1992.
- [17] NILSSON, M., ANDERSON, S., KLEIJN, W. B. On the mutual information between frequency bands in speech. *Proc. IEEE Int. Conf. on Acoustics, Speech, Signal Processing*, 2000.
- [18] MILET, G., GERRITS, A., VALIÈRE, J. C. Low-band extension of telephone-band speech. *Proc. IEEE Int. Conf. on Acoustics, Speech, Signal Processing*, 2000.
- [19] MARQUES, J. S., TRANCOSO, I. M., TRIBOLET, J. M., ALMEIDA, L. B. Improved pitch prediction with fractional delays in CELP coding. *Proc. IEEE Int. Conf. on Acoustics, Speech, Signal Processing*, pages 665–668, 1990.
- [20] FROON, P. ATAL, B. S. Pitch predictors with high temporal resolution. *Proc. IEEE Int. Conf. on Acoustics, Speech, Signal Processing*, pages 661–664, 1990.