



HAL
open science

Reconnaissance de la parole pour l'aide à la communication pour les sourds et malentendants

Luiza Orosanu

► **To cite this version:**

Luiza Orosanu. Reconnaissance de la parole pour l'aide à la communication pour les sourds et malentendants. Traitement du signal et de l'image [eess.SP]. Université de Lorraine, 2015. Français. NNT : 2015LORR0172 . tel-01251128

HAL Id: tel-01251128

<https://inria.hal.science/tel-01251128v1>

Submitted on 5 Jan 2016

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Reconnaissance de la parole pour l'aide à la communication pour les sourds et malentendants

THÈSE

présentée et soutenue publiquement le 11 Décembre 2015

pour l'obtention du

Doctorat de l'Université de Lorraine

(mention informatique)

par

Luiza Orosanu

Composition du jury :

<i>Président :</i>	Bernard GIRAU	Prof., Université de Lorraine, Loria
<i>Rapporteurs :</i>	Laurent BESACIER Georges LINARÈS	Prof., Université J. Fourier, LIG Prof., Université d'Avignon, LIA - CERI
<i>Examineurs :</i>	Régine ANDRÉ-OBRECHT Martine ADDA-DECKER	Prof., Université Paul Sabatier, IRIT DR CNRS, LPP
<i>Directeur de thèse :</i>	Denis JOUVET	DR INRIA, Loria

Remerciements

Mes premiers remerciements vont à mon directeur de thèse, M. Denis Jovet, qui m'a soutenu et encouragé tout au long de cette thèse. Ses compétences, ses conseils et ses remarques ont été d'une aide précieuse pour faire avancer mes recherches. J'ai pu également apprécier sa gentillesse et sa disponibilité malgré son emploi du temps plus que chargé. Je suis très reconnaissante pour toutes les corrections, recorections et rerecorections de ce document.

Je remercie également les membres de l'entreprise eROCCA pour m'avoir donné l'occasion de travailler sur leur projet.

Je souhaite également remercier l'ensemble de l'équipe Multispeech pour m'avoir fourni un cadre de travail enrichissant et agréable.

Enfin, j'aimerais remercier mon petit ami, Luc, pour sa compréhension, son soutien et son aide tout au long de mon travail.

Résumé

Le projet RAPSODIE¹ a été lancé en 2012 avec l'objectif de développer une nouvelle génération de terminaux proposant une reconnaissance vocale spécialisée sur les besoins des personnes sourdes ou malentendantes. Dans ce contexte, l'objectif de cette thèse est d'étudier, d'approfondir et d'enrichir l'extraction d'informations lexicales et para-lexicales à partir de la parole pour aider à la communication avec des personnes sourdes ou malentendantes.

En ce qui concerne la modélisation lexicale, nous nous sommes intéressés au choix des unités lexicales définissant le lexique et au modèle de langage associé. L'optimisation du décodage phonétique nous a conduit à évaluer différentes unités lexicales, comme les phonèmes et les mots, et à proposer l'utilisation des syllabes. Cependant, des entretiens effectués en parallèle avec des personnes sourdes ont révélé l'intérêt d'une reconnaissance en mots qui est plus simple à appréhender et qui ne nécessite pas d'effort supplémentaire de la part du lecteur pour regrouper les différents phonèmes ou syllabes en mots porteurs de sens. Cela nous a amenés à proposer une nouvelle approche reposant sur la combinaison de mots et de syllabes dans un seul modèle de langage, dit hybride. L'utilisation d'un tel modèle de langage hybride vise à assurer une reconnaissance correcte des mots les plus fréquents et à proposer des suites de syllabes pour les segments de parole correspondant à des mots hors vocabulaire.

Afin d'assurer une bonne reconnaissance des mots spécifiques à un certain domaine, nous avons approfondi l'ajout de nouveaux mots dans le modèle de langage sans faire de ré-apprentissage ni d'adaptation du modèle de langage (qui sont des traitements qui nécessitent beaucoup de données). Nous avons donc proposé et évalué une nouvelle approche pour l'ajout de mots qui repose sur un principe de similarité entre mots. Deux mots sont considérés comme similaires s'ils ont des distributions similaires de leurs voisins ; formellement, cela se traduit par un calcul de divergence entre les distributions des mots prédécesseurs et des mots successeurs. L'approche implique ainsi plusieurs étapes : utiliser quelques phrases exemples pour le nouveau mot à ajouter, chercher dans le modèle de langage des mots similaires au nouveau mot, puis définir les n-grammes associés à ce nouveau mot à partir des n-grammes des mots similaires.

Concernant l'extraction d'informations para-lexicales, nous nous sommes intéressés principalement à la détection des questions et des affirmations. Cette détection vise à enrichir la communication avec les personnes sourdes ou malentendantes, de manière à leur signaler quand une question leur est adressée, afin qu'ils puissent y répondre ou intervenir par une demande de répétition ou de clarification. Dans notre étude, plusieurs approches ont été analysées utilisant respectivement seulement des paramètres prosodiques (extraits du signal audio), seulement des paramètres linguistiques (extraits des séquences de mots et de classes grammaticales), ou combinant les deux types d'information. L'évaluation de classifieurs est effectuée en utilisant des paramètres linguistiques et prosodiques extraits à partir de transcriptions automatiques (pour étudier la performance dans des conditions réelles) et de transcriptions manuelles (pour étudier la performance dans des conditions idéales). L'impact d'erreurs sur les frontières des phrases a également été étudié.

Mots clés : reconnaissance de la parole, syllabes, modèles de langage hybrides, mots hors-vocabulaire, mots similaires, détection de questions

1. <http://erocca.com/rapsodie>

Abstract

The RAPSODIE² project was launched in 2012 with the objective of proposing a speech recognition device specialized on the needs of deaf and hearing impaired people. In this context, the aim of the thesis is to study, deepen and enrich the extraction of lexical and para-lexical information from speech in order to help communication with deaf and hearing impaired people.

Regarding the lexical modeling, we focused on optimizing the choice of lexical units (defining the vocabulary and the associated language model). The optimisation of the phonetic decoding led us to evaluate various lexical units, such as phonemes and words, and to propose the use of syllables. However, the interviews conducted in parallel with deaf people showed interest in a word-based recognition, which is the easiest to understand and it does not require additional effort for the reader in order to group up different phonemes or syllables into meaningful words. This led us to propose a new approach based on the combination of words and syllables into a hybrid language model. The use of this hybrid language model aims to ensure proper recognition of the most frequent words and to offer sequences of syllables for speech segments corresponding to out-of-vocabulary words.

In order to ensure proper recognition of specific words in a certain area, we have focused on adding new words into the language model, without re-training or adapting the language model (treatments that require a lot of new data). We have therefore proposed and evaluated a new approach to adding words into the model based on a principle of similarity between words. Two words are considered as similar if they have similar neighbors distributions; formally, this results in the computation of the KL divergence on the distribution of their neighbor words. The approach involves three steps: defining a small set of sentences containing the new word to be added, looking for in-vocabulary words similar to the new word, defining the n-grams associated with the new word based on the n-grams of its similar in-vocabulary words.

Regarding the extraction of para-lexical information, we focused mainly on the detection of questions and statements. This detection aims to enhance communication with deaf and hearing impaired people, in order to inform them when a question is addressed to them because they have to respond or demand a repetition or a clarification. In our study, several approaches were analyzed using only prosodic features (extracted from the audio signal), only linguistic features (extracted from word sequences and sequences of POS tags), or combining both types of information. The evaluation of the classifiers is performed using linguistic and prosodic features (alone or in combination) extracted from automatic transcriptions (to study the performance under real conditions) and from manual transcriptions (to study the performance in ideal conditions). The performance loss when sentence boundaries are not perfect was also evaluated.

Keywords: speech recognition, syllables, hybrid language models, out-of-vocabulary words, similar words, question detection

2. <http://erocca.com/rapsodie>

Table des matières

Introduction générale	1
Contexte	1
Problématique	2
Plan du document	4
I Reconnaissance de la parole	7
1 Introduction	9
1.1 Historique	9
1.2 Applications	11
2 Système de reconnaissance	15
2.1 Analyse du signal audio	15
2.2 Modèle de langage	18
2.3 Modèle de prononciation	22
2.4 Modèle acoustique	23
3 Processus de reconnaissance	29
3.1 Algorithme de décodage	29
3.2 Évaluation des performances	31
3.3 Mesures de confiance	32
4 Conclusions	35
II Modélisation lexicale	37
5 État de l'art	39
5.1 Décodage phonétique	39
5.2 Modèles hybrides	40
5.3 Ajout de nouveaux mots	42
5.4 Nos travaux	46

6	Contexte expérimental	49
6.1	Données de parole	49
6.2	Données textuelles	50
6.3	Configuration	51
7	Décodage phonétique	53
7.1	Unités lexicales	53
7.2	Heuristiques de décodage	61
8	Modèles hybrides	63
8.1	Fabrication des modèles hybrides	64
8.2	Évaluation des modèles hybrides	65
8.3	Interpolation des modèles hybrides	72
9	Ajout de nouveaux mots	75
9.1	Approche	75
9.2	Expérimentations	77
10	Conclusions	83

III Modélisation para-lexicale 87

11	État de l'art	89
11.1	Détection de la modalité des phrases	89
11.2	Nos travaux	93
12	Contexte expérimental	95
12.1	Données textuelles	95
12.2	Données de parole	96
12.3	Classifieurs	97
12.4	Configuration	99
13	Paramètres prosodiques et linguistiques	101
13.1	Paramètres prosodiques	102
13.2	Paramètres linguistiques	105
14	Expérimentations	107
14.1	Utilisation des paramètres prosodiques	108
14.2	Utilisation des paramètres linguistiques	110
14.3	Utilisation des paramètres combinés	111
14.4	Comparaisons entre paramètres	113
14.5	Impact des frontières sur la performance	116

15 Conclusions	119
Conclusions et perspectives	121
Annexes	127
A Modèles de langage	129
B Unités phonétiques	133
C Outil de syllabation	135
D Choix de mots similaires	137
E Nouveaux modèles de langage	141
F Classification question / affirmation	143
Acronyms	148
Bibliographie	149

Table des figures

2.1	Architecture d'un système automatique de reconnaissance vocale	15
2.2	Exemple d'un signal acoustique $s(t)$	16
2.3	Principe de l'analyse cepstrale	16
2.4	Spectrogramme d'un signal audio de parole	17
2.5	Banc de filtres à échelle Mel ; répartition linéaire jusqu'à 1000 Hz, logarithmique au delà	17
2.6	Exemple de HMM utilisé pour modéliser les phonèmes	24
2.7	Principe du partage des densités de probabilité (sénones) entre les états des modèles contextuels des sons (à gauche, pas de partage des densités ; à droite, partage des densités)	27
3.1	Exemple d'une recherche Viterbi avec un modèle HMM de 5 états (3 états émetteurs et 2 états non-émetteurs) sur un signal audio de 7 trames (70 milisecondes) .	30
7.1	Impact du poids du modèle de langage (lw) sur la performance du modèle de langage grand vocabulaire sur le corpus ESTER2	54
7.2	Impact du poids du modèle de langage (lw) sur la performance du modèle de langage phonétique sur le corpus ESTER2	55
7.3	Exemple de syllabation	56
7.4	Nombre de syllabes par rapport à leur fréquence d'occurrence	57
7.5	Impact du poids du modèle de langage (lw) sur la performance du modèle de langage syllabique 'min3occ' sur le corpus ESTER2	58
7.6	Taux d'erreur phonétique obtenus avec les modèles de langage syllabiques sur les corpus ESTER2 et ETAPE	58
7.7	Comparaison des taux d'erreur phonétique obtenus avec les 3 unités lexicales . .	59
7.8	Taux d'erreur phonétique obtenus sur les corpus ESTER2 et ETAPE, en fonction du rapport signal-à-bruit (a) et de la vitesse d'élocution (b)	60
7.9	Taux d'erreur phonétique sur le corpus ESTER2 obtenus avec différentes tailles de modèles acoustiques (tailles exprimées en nombre total de gaussiennes), en utilisant un modèle de langage phonétique (a), syllabique (b) ou grand vocabulaire (c)	62
8.1	Préparation des données pour la fabrication des modèles de langage hybrides . . .	64
8.2	Nombre et couverture des mots dans les modèles de langage hybrides	65
8.3	Nombre de syllabes utilisées dans les modèles de langage hybrides	65
8.4	Taux d'erreur phonétique obtenus avec les modèles de langage hybrides	66
8.5	Comparaison des taux d'erreur phonétique obtenus avec les 4 modèles de langage	66
8.6	Taux de mots dans la séquence de mots et syllabes reconnus par les modèles hybrides	67
8.7	Taux de mots correctement reconnus par les modèles hybrides	67
8.8	Taux de syllabes correctement reconnues par les modèles hybrides	68
8.9	Mots hors-vocabulaire	68

8.10	Analyse du décodage des mots hors vocabulaire sur le corpus ESTER2	69
8.11	Impact du choix du seuil sur la mesure de confiance de mots, pour les modèle de langage hybrides ‘min3occ’ (a), et ‘min300occ’ (b), sur le corpus ESTER2	70
8.12	Impact du choix du seuil sur la mesure de confiance des syllabes pour les modèles de langage hybrides ‘min3occ’ (a) et ‘min300occ’ (b) sur le corpus ESTER2	71
8.13	Taux d’erreur phonétique obtenus avec l’interpolation de deux modèles de langage hybrides ‘min3occ’ et ‘min300occ’	72
8.14	Taux de mots reconnus, de mots correctement reconnus et de syllabes correctement reconnues avec l’interpolation de deux modèles de langage hybrides ‘min3occ’ et ‘min300occ’	73
8.15	Analyse du décodage des mots hors-vocabulaire avec l’interpolation de deux modèles de langage hybrides ‘min3occ’ et ‘min300occ’ sur le corpus ESTER2	74
8.16	Impact du choix du seuil sur la mesure de confiance de mots (a) et de syllabes (b) pour le modèle de langage interpolé $\lambda = 0,4$ entre les modèles hybrides ‘min3occ’ et ‘min300occ’ sur le corpus ESTER2	74
13.1	Étape de post-traitement pour la détection de questions	101
13.2	Courbe de la fréquence fondamentale (en haut) sur la phrase “c’est quoi ?”	102
13.3	Exemple des segments “isolés” des fréquences fondamentales (F0)	104
13.4	Exemple de segments de trames consécutives pour la fréquence fondamentale (F0)	105
14.1	Résultats (moyenne harmonique) obtenus en fonction des différentes zones d’extraction de paramètres prosodiques, lors de l’utilisation des transcriptions automatiques (a) ou des transcriptions manuelles (b)	108
14.2	Performance (moyenne harmonique) obtenue avec les différents types de classifieurs en utilisant les paramètres prosodiques ‘phraseComplexe’ sur les transcriptions automatiques et sur les transcriptions manuelles	109
14.3	Impact du choix des paramètres prosodiques calculés sur la phrase complète, lors de l’utilisation du classifieur LR sur les transcriptions automatiques et du classifieur JRip sur les transcriptions manuelles	109
14.4	Performance (moyenne harmonique) obtenue avec les différents classifieurs utilisant des paramètres linguistiques sur les transcriptions automatiques et sur les transcriptions manuelles	110
14.5	Impact du choix des paramètres linguistiques lors de l’utilisation du classifieur MLP sur les transcriptions automatiques et du classifieur J48 sur les transcriptions manuelles	111
14.6	Performance (moyenne harmonique) obtenue avec les différents classifieurs combinés sur les transcriptions automatiques et manuelles	112
14.7	Impact du choix des paramètres (prosodiques et linguistiques) lors de l’utilisation du classifieur JRip sur les transcriptions automatiques et du classifieur LR sur les transcriptions manuelles	112
14.8	Performance (moyenne harmonique) obtenue sur les transcriptions automatiques (a) et sur les transcriptions manuelles (b), lors de l’utilisation des paramètres prosodiques, linguistiques et combinés	113
14.9	Performance (moyenne harmonique) obtenue avec les différents classifieurs sur les transcriptions automatiques du corpus ETAPE (a) et du corpus ESTER2 (b)	114
14.10	Performances moyennes (moyenne harmonique H, taux de questions correctement classées qCC, taux d’affirmations correctement classées aCC) obtenues avec la combinaison de 5 algorithmes de classification par vote majoritaire sur les transcriptions automatiques et sur les transcriptions manuelles appartenant au corpus ETAPE (a) et au corpus ESTER2 (b)	115

14.11 Performance (moyenne harmonique) obtenue avec le classificateur JRip sur les transcriptions automatiques lors de la modification des frontières prédéfinies . . .	116
---	-----

Liste des tableaux

3.1	Évaluation d'un résultat du décodage	31
3.2	Solutions multiples pour la mise en correspondance d'une hypothèse de reconnaissance avec la transcription de référence	32
6.1	Tailles des corpus de parole (apprentissage, développement et test)	49
6.2	Donées textuelles du corpus EEE-Train	50
7.1	Taux d'erreur phonétique (PER) obtenus avec le modèle de langage grand vocabulaire (basé sur des mots)	54
7.2	Taux d'erreur phonétique (PER) obtenus avec le modèle de langage basé sur phonèmes	55
7.3	Quelques exemples des règles de syllabation	56
7.4	Valeur optimale du poids de modèle de langage pour les 3 unités lexicales sur le corpus ESTER2	59
7.5	Taux d'erreur phonétique obtenus avec les modèles de langage grand vocabulaire sur les corpus ETAPE en fonction du rapport signal-à-bruit et de la vitesse d'élocution	61
7.6	Taille des modèles acoustique	61
8.1	Nombre de mots hors-vocabulaire différents, et pourcentage d'occurrences	69
9.1	Nombre de 2-grammes (a) et de 3-grammes (b) [en millions] dans les nouveaux modèles de langage 'baseline+1-,2-,3-grammes', en fonction du nombre de phrases exemples par nouveau mot (<i>ex</i>) et du nombre de mots similaires pour chaque nouveau mot (<i>mS</i>)	79
9.2	Taille des modèles de langage de référence	80
9.3	Statistiques obtenues sur les modèles de langage de référence	80
9.4	Analyse du taux d'erreur mot (a) et du pourcentage de nouveaux mots correctement reconnus (b) obtenus avec les quatre modèles interpolés (LM-INTERP-1,...,-4) et avec les nouveaux modèles de langage 'baseline+1-,2-,3-grammes', en fonction du nombre de phrases exemples par nouveau mot (<i>ex</i>) et du nombre de mots similaires pour chaque nouveau mot (<i>mS</i>)	81
12.1	Donées textuelles du corpus Gigaword avec les sous-ensembles extraits de questions et d'affirmations	95
12.2	Nombre de 3-grammes dans les modèles de langage calculés sur les questions et sur les affirmations	96
12.3	Description des données utilisées dans nos expériences	97
13.1	Les paramètres prosodiques qui prennent en compte la structure prosodique de la phrase et des informations a priori sur les locuteurs (pour la normalisation)	103

13.2	Les paramètres prosodiques calculés sur la phrase entière, sur les dernières 700ms du signal ou sur les dernières 200ms du signal	104
14.1	Matrice de confusion question/affirmation obtenue avec le classifieur LR sur 22 paramètres prosodiques ('phraseComplète') extraits des transcriptions automatiques	110
14.2	Matrice de confusion question/affirmation obtenue avec le classifieur MLP sur les paramètres linguistiques extraits des transcriptions automatiques	111
14.3	Matrice de confusion question/affirmation obtenue avec le classifieur JRip sur les paramètres combinés extraits des transcriptions automatiques	113
14.4	Description des données d'évaluation par sous corpus	114
14.5	Performance (moyenne harmonique) obtenue avec les 5 classifieurs et avec leur combinaison (par vote majoritaire) sur les transcriptions manuelles et automatiques	117
A.1	Modèles de langage phonétique, syllabiques, grand vocabulaire	129
A.2	Modèles de langage hybrides de mots et syllabes	130
A.3	Interpolation entre deux modèles de langage hybrides de mots et syllabes	131
B.1	Notation des unités phonétique	134
C.1	Classes phonétiques	135
C.2	Règles de syllabation	136
D.1	Mots similaires aux nouveaux mots obtenus sur 5 phrases exemples	138
D.2	Mots similaires aux nouveaux mots obtenus sur 50 phrases exemples	139
E.1	Analyse du taux d'erreur mot (a) et du pourcentage de nouveaux mots correctement reconnus (b) obtenus avec les nouveaux modèles de langage 'baseline+1-grammes', 'baseline+1-,2-grammes' et 'baseline+1-,2-,3-grammes', en fonction du nombre de phrases exemples par nouveau mot (ex) et du nombre de mots similaires pour chaque nouveau mot (mS)	141
F.1	Performance obtenue avec le classifieur JRip utilisant des paramètres combinés sur les transcriptions automatiques appartenant au corpus ESTER2	143
F.2	Performance obtenue avec un classifieur qui répond au hasard (50%-50%)	144
F.3	Performance obtenue avec les différents classifieurs utilisant des paramètres prosodiques (P), linguistiques (L) ou combinés (C) sur les transcriptions automatiques appartenant au corpus ETAPE et au corpus ESTER2	145
F.4	Performance obtenue avec les différents classifieurs utilisant des paramètres prosodiques (P), linguistiques (L) ou combinés (C) sur les transcriptions manuelles appartenant au corpus ETAPE et au corpus ESTER2	146

Introduction générale

Sommaire

Contexte	1
Problématique	2
Plan du document	4

Contexte

La parole est le mode de communication le plus naturel. Grâce à elle nous pouvons donner une voix à notre volonté et à nos pensées. Nous pouvons l'utiliser pour exprimer des opinions, des idées, des sentiments, des désirs ou pour échanger, transmettre, demander des informations. Et aujourd'hui, nous ne l'utilisons pas uniquement pour communiquer avec d'autres humains, mais aussi avec des machines.

La reconnaissance de la parole est la technique qui permet l'analyse des sons captés par un microphone pour les transcrire sous forme d'une suite de mots exploitables par les machines. Depuis son apparition dans les années 1950, la reconnaissance automatique de la parole a été constamment améliorée avec l'aide des phonéticiens, linguistes, mathématiciens et ingénieurs, qui ont défini les connaissances acoustiques et linguistiques nécessaires pour bien comprendre la parole d'un humain. Cependant, les performances atteintes ne sont pas parfaites et dépendent de nombreux critères. Les conditions favorables pour la reconnaissance de la parole impliquent une parole native, appartenant à un seul locuteur ayant une diction propre (ne présentant pas une pathologie de voix), enregistrée dans un environnement calme et non bruité, basée sur un vocabulaire commun (mots connus par le système). La performance du système diminue lorsque l'on traite des accents non-natifs, différents dialectes, des locuteurs qui présentent une pathologie de voix, des mots inconnus par le système (généralement des noms propres), des signaux audio bruités (faible rapport signal-à-bruit), etc.

Les applications de la reconnaissance de la parole sont très diversifiées et chaque système a sa propre architecture et son propre mode de fonctionnement. Plus le domaine d'application est vaste, plus les modèles de reconnaissance doivent être grands (pour pouvoir comprendre les discours spontanés et la diversité des locuteurs). De nos jours, de nombreuses recherches sur la reconnaissance de la parole sont effectuées dans le seul but d'imiter un assistant personnel : chercher des informations sur internet, noter des rendez-vous, envoyer des sms, contrôler différents équipements de la maison, etc. Mais très peu

de recherches s'intéressent au bien-être de personnes handicapées, en particulier aux personnes sourdes ou malentendantes.

Problématique

L'entreprise eROCCA a lancé en 2012 le projet RAPSODIE³ (**R**econnnaissance **auto**-matique de la **parole** pour les personnes **sourdes** ou **handicapées**) pour développer une nouvelle génération de terminaux proposant la reconnaissance vocale (initialement prévue en mode embarqué) dans le but d'améliorer la communication entre les sourds et leur entourage proche (dans la sphère privée ou professionnelle). La contrainte d'une reconnaissance embarquée a par la suite été relâchée au profit d'une implémentation en mode serveur. La liste des partenaires comprend le CEA - spécialisé dans les nanotechnologies, Castorama - magasin de bricolage avec une forte politique d'emploi des personnes handicapées (fournissant les conditions d'évaluation dans une situation réelle de travail) et INRIA - spécialisé dans la reconnaissance de la parole.

Partie intégrante du projet RAPSODIE, les travaux réalisés dans cette thèse concernent la génération des transcriptions automatiques de la parole, avec un affichage adapté aux personnes sourdes. Les solutions proposées dans notre étude ont dû prendre en considération différentes contraintes imposées sur le mode de fonctionnement du système de reconnaissance (contexte initial embarqué), ainsi que les résultats des entretiens effectués dans le projet avec des personnes sourdes (concernant l'affichage des transcriptions) et tenir compte du contexte applicatif (magasin de bricolage).

Les partenaires du projet ont choisi d'utiliser les outils Sphinx3 et PocketSphinx pour le décodage de la parole, en raison de leur applicabilité en système embarqué (ces outils ajoutent une nouvelle contrainte sur les modèles de langage qui ne peuvent être que de type trigramme).

Mode de fonctionnement

Les contraintes imposées sur le système de reconnaissance automatique de la parole dépendent du mode de fonctionnement : embarqué (en local) ou mis en œuvre sur des serveurs (à distance). Dans le cas de reconnaissance à distance, l'enregistrement de la voix (fait sur un appareil) est envoyé (via le réseau) à des serveurs situés souvent à plusieurs centaines ou milliers de kilomètres. C'est là que de puissants ordinateurs vont transformer la parole en texte, qui va être ensuite renvoyé (via le réseau) à l'appareil. Cette solution assure la meilleure précision de reconnaissance aujourd'hui (grâce à l'utilisation d'importantes puissances de calcul et à des modèles appris sur de grosses bases de données), mais c'est cet aller-retour qui rend la reconnaissance vocale sur la plupart des appareils lente (en particulier sur les connexions cellulaires les plus lentes). De plus, il est impossible de l'utiliser hors-ligne. D'autre côté, les systèmes embarqués sont contraints par les ressources disponibles sur l'appareil : une capacité mémoire limitée et une puissance de calcul limitée. Mais ils ont l'avantage d'être accessibles à tout moment, sans être dépendants d'internet ou de serveurs distants. En conséquence, un système de reconnaissance

3. <http://erocca.com/rapsodie/>

automatique de la parole entièrement embarqué doit utiliser des modèles de reconnaissance assez performants (pour assurer la satisfaction de ses utilisateurs), mais en même temps assez petits, pour répondre aux contraintes de mémoire et de calcul, et générer des réponses rapides.

Compte tenu du contexte initial embarqué du système de reconnaissance automatique de la parole, nous avons choisi d'effectuer une étude et une analyse détaillée sur la performance de différents modèles "compacts". Nous avons considéré en particulier le choix des unités lexicales pour obtenir le meilleur compromis entre le coût de calcul et l'utilisabilité des résultats.

Contexte de la surdit 

Le d fi est de r pondre aux besoins des personnes sourdes, ce qui implique une prise en compte de leurs habitudes, de leurs modes de communication, de leur savoir-faire et des probl mes qu'elles rencontrent au quotidien. Mais pour savoir comment aider les personnes sourdes, il faut d'abord comprendre leur "handicap" et leur histoire.

Dans le pass , l'on pensait que les personnes qui ne pouvaient pas entendre ne pouvaient pas comprendre [MOORE et BRUDER 2013]. Leur image a commenc    changer seulement   partir des ann es 1500, quand les premi res langues de signes apparaissent [LANE 1996]. En France, la premi re personne qui s'est int ress e aux personnes sourdes est Charles Michel De l' p e en 1760. Il est le fondateur de la premi re  cole gratuite pour les sourds, et ses m thodes d'apprentissage sont bas es sur l'utilisation de gestes naturels pour coder l'alphabet fran ais mais aussi pour s'exprimer avec l'aide de gestes naturels selon la syntaxe du fran ais [CHARLES MICHEL DE L'  P E 1776 ; CHARLES MICHEL DE L'  P E 1784]. Son mod le a  t  suivi par d'autres pays et plusieurs m thodes d'apprentissage pour les sourds ont  t  invent es ult rieurement (en utilisant la langue de signes, la lecture labiale ou l'oralisme). Le temps passe et les entendants continuent   envisager les personnes sourdes comme des personnes handicap es, qui ont besoin d'aide pour devenir "moins sourdes". Mais toutes les personnes sourdes ne se consid rent pas comme  tant handicap es, mais plut t comme appartenant   une culture   part, bas e sur la "langue des sourds". La langue de signes a  t  interdite aux personnes sourdes pendant une centaine d'ann es en France (entre 1880 et 1977). Ils ont  t  forc s   oraliser, c'est- -dire   apprendre comment parler (sans m me entendre) en utilisant la lecture labiale et en imitant les mouvements de la bouche et les modes de respiration. Mais la r ussite de cette m thode d pend de plusieurs facteurs : du profil de la surdit , du milieu familial, de la m thode d' ducation choisie, de la r education, des appareillages et de l' ge de l'appareillage. Certaines personnes sourdes ne pourront jamais oraliser de fa on compr hensible, ce qui s'est traduit par une forte augmentation du taux des sourds illettr s durant cette p riode. De nos jours, les personnes sourdes ont appris   utiliser tous les types d'information disponibles afin de pouvoir comprendre et communiquer : le langage corporel, la lecture labiale, la langue de signes et la langue fran aise. Certains d'entre eux savent lire,  crire et m me parler. Malgr  tous les efforts d'adaptation au monde des entendants, il y aura toujours de grandes diff rences entre la vie d'un "entendant" et la vie d'un "sour-d". Il y a beaucoup de probl mes simples pour un entendant, mais compliqu s pour une personne sourde. Elles ont souvent du mal   trouver un emploi,   l'exercer et   le garder.

C'est pour ça, et plus encore, que beaucoup des personnes sourdes se sentent exclues du monde des entendants [VIROLE 1999 ; DELAPORTE 2002].

La reconnaissance automatique de la parole pourrait apporter une compensation à ce handicap. Une transcription automatique pourrait aider les personnes sourdes à mieux comprendre leur entourage ou une émission de télévision ou une vidéo sur internet et cela sans faire aucun excès de concentration, sans se sentir gêné et sans avoir besoin d'un interprète de la langue de signes. La seule, mais importante, condition sera d'avoir une bonne maîtrise du français écrit (pour pouvoir comprendre la transcription automatique).

Pour répondre à ce défi, nous nous sommes intéressés à l'extraction d'informations lexicales et para-lexicales à partir de la parole pour aider à la communication avec des personnes sourdes ou malentendantes.

Plan du document

Ce document est constitué de trois grandes parties.

La première partie présente les systèmes de reconnaissance de la parole. Tout d'abord, nous rappelons leur historique et nous donnons quelques exemples d'applications qui mettent en avant leur utilité pour aider les personnes handicapées. L'architecture des systèmes automatiques de reconnaissance de la parole est également présentée, avec la paramétrisation du signal et les modèles de reconnaissance associés. Nous détaillons les modèles et les techniques d'apprentissage utilisés dans nos travaux (modèles de langage n-grammes, modèles acoustiques HMM-GMM), et présentons brièvement les autres. La description du processus de reconnaissance complète cette partie, avec l'algorithme de décodage, l'évaluation des performances et l'utilité des mesures de confiance.

La deuxième partie porte sur les aspects de modélisation lexicale. Nous nous sommes intéressés premièrement à la comparaison de différentes approches de décodage phonétique. Différentes unités lexicales ont été évaluées, comme les phonèmes et les mots, et nous avons proposé l'utilisation des syllabes. Nous avons ensuite proposé une approche de modélisation hybride, basée sur un lexique combinant mots et syllabes, pour permettre la reconnaissance des mots les plus fréquents, et l'affichage de mots hors vocabulaire sous forme de suites de syllabes. Pour répondre au besoin d'ajouter de nouveaux mots dans le modèle de langage, dans le but d'assurer une bonne reconnaissance de mots spécifiques à un certain domaine, une nouvelle approche basée sur un principe de similarité entre mots a été proposée et étudiée.

La troisième partie porte sur l'extraction d'informations complémentaires, para-lexicales, importantes pour la communication inter-personnes. Nous nous sommes intéressés principalement à la détection des questions et des affirmations, visant à enrichir la communication avec les personnes sourdes ou malentendantes, de manière à leur signaler quand une question leur a été adressée, car, dans ces cas, ils doivent répondre ou demander des précisions supplémentaires. Dans notre étude, plusieurs approches sont analysées : la création d'un classifieur avec seulement des paramètres prosodiques (extraits du signal audio), d'un classifieur avec seulement des paramètres linguistiques (extraits des séquences de mots et des séquences de classes grammaticales) ou d'un classifieur qui

combine les deux types d'information. L'extraction des informations est faite à partir des signaux audio et des transcriptions automatiques ou des transcriptions manuelles, ce qui permet de comparer les performances des classifieurs dans ces deux conditions (avec ou sans erreurs sur les mots). Les premières expériences considèrent une segmentation de phrases parfaite (prédéfinie). Ensuite, nous évaluons la perte de performance lorsque les frontières de phrases ne sont pas parfaitement identifiées.

Pour finir, nous présentons les conclusions et les perspectives de ce travail.

Les différentes annexes fournissent quelques informations complémentaires sur les modèles et les outils utilisés dans nos travaux.

Première partie

Reconnaissance de la parole

1	Introduction	9
1.1	Historique	9
1.2	Applications	11
2	Système de reconnaissance	15
2.1	Analyse du signal audio	15
2.2	Modèle de langage	18
2.3	Modèle de prononciation	22
2.4	Modèle acoustique	23
3	Processus de reconnaissance	29
3.1	Algorithme de décodage	29
3.2	Évaluation des performances	31
3.3	Mesures de confiance	32
4	Conclusions	35

Chapitre 1

Introduction

Ce chapitre présente un bref historique des systèmes de reconnaissance automatique de la parole et énumère quelques applications (pour le grand public ou pour des personnes handicapées).

Sommaire

1.1	Historique	9
1.2	Applications	11

1.1 Historique

Au cours des années cinquante, les recherches en reconnaissance de la parole étaient principalement consacrées à la composante acoustique de la parole [LINDGREN 1965]. Avec l'aide d'un outil appelé spectrographe, qui affiche l'image des spectres de la parole, ils ont pu définir les caractéristiques articulatoires principales afin de pouvoir distinguer les différents sons de la parole [DREYFUS-GRAF 1950]. Basé sur cette reconnaissance visuelle des sons, le dispositif électrique créé au sein du laboratoire Bell en 1952 pouvait reconnaître les dix chiffres prononcés par un seul locuteur, en comparant les paramètres acoustiques du signal audio avec des modèles de référence [DAVIS et al. 1952].

Cependant, la réussite des expériences repose sur des conditions très strictes : vocabulaire réduit, phonèmes / mots isolés, peu de locuteurs, enregistrements dans des conditions de laboratoire, etc [LINDGREN 1965]. Les méthodes acoustiques seules sont donc insuffisantes pour la parole continue et multi-locuteur [FATEHCHAND 1960]. En conséquence, les informations linguistiques commencent à être prises en compte dans les systèmes de reconnaissance, pour ajouter du contexte au phonèmes / mots à reconnaître et ainsi améliorer la performance de reconnaissance [DENES 1959 ; FORGIE 1959 ; DENES et MATHEWS 1960 ; REDDY 1966 ; ALTER 1968].

En 1971 l'agence DARPA (*Defense Advanced Research Projects Agency*) des États-Unis lance un projet de 5 ans pour tester la faisabilité de la compréhension automatique de la parole continue, ce qui favorise la création de trois nouveaux systèmes [MEDRESS 1976]. Les systèmes "Hearsay-II" de CMU (*Carnegie Mellon University*) [LESSER et ERMAN 1977] et "HWIM" (*Hear What I Mean*) de BBN (*Bolt Beranek and Newman*)

Inc) [WOLF et WOODS 1977] sont basés sur l'intelligence artificielle : la reconnaissance de la parole est formulée comme un problème de recherche heuristique parmi de multiples sources de connaissances. Le système "Harpy" de CMU pouvait reconnaître jusqu'à 1011 mots en utilisant un algorithme de recherche en faisceau qui trouve la meilleure solution parmi un réseau d'états finis de phrases possibles (les phrases ayant été préalablement segmentées pour réduire le nombre de mises à jour nécessaires) [LOWERRE 1976]. D'autres événements importants ont eu lieu dans les années 1970 : les premières approches statistiques pour la reconnaissance vocale implémentées dans le système DRAGON [BAKER 1975] et dans le système IBM Tangora [JELINEK et al. 1975], ainsi que le nouveau système multi-locuteurs de Bell [RABINER et al. 1979].

À partir des années 1980 les chercheurs se focalisent sur la reconnaissance des mots connectés [FURUI 2005]. Le plus grand changement de l'époque est défini par le passage des systèmes basés sur des règles au systèmes basés sur des modèles statistiques [ARORA et SINGH 2012]. Le signal de parole commence à être représenté en termes de probabilités grâce aux HMM (modèles de Markov cachés, *Hidden Markov Models*) [BAUM et PETRIE 1966 ; BAUM et EAGON 1967], ce qui permet de combiner des informations linguistiques avec des réalisations acoustiques temporelles des sons de la parole [RABINER 1989 ; RABINER et JUANG 1993]. Cela motive également l'apparition des modèles statistiques de langage, dits n-grammes [JELINEK 1985 ; JELINEK et al. 1990]. L'innovation dans l'analyse acoustique du signal consiste dans la combinaison entre les coefficients cepstraux (définis dans la section 2.1) et leurs dérivés temporelles de première et de deuxième ordre [FURUI 1986].

Ces méthodes ont été prédominantes dans la suite des recherches [LEE et al. 1990a] et continuent à être utilisées même de nos jours, avec des améliorations supplémentaires constantes. Grâce à un nouveau projet de DARPA plusieurs systèmes de reconnaissance de la parole ont été construits sur ces paradigmes, comme "BYBLOS" de BBN [CHOW et al. 1987], "Lincoln" de Lincoln Labs [PAUL 1989], "DECIPHER" de SRI [WEINTRAUB et al. 1989], "SUMMIT" de MIT [ZUE et al. 1989] et "Sphinx" de CMU [LEE et al. 1990b]. Le système Sphinx II a été le premier à traiter la parole continue, multi-locuteur, avec un grand vocabulaire.

À partir des années 1990 les chercheurs se focalisent sur la minimisation des erreurs de reconnaissance [JUANG et FURUI 2000]. Le programme DARPA continue avec un vif intérêt pour le langage naturel. Son plus grand défi est associé au corpus "Switchboard" qui s'intéresse à la parole spontanée et conversationnelle [FURUI 2005]. L'université de Cambridge a créé et diffusé un ensemble d'outils appelé HTK (*Hidden Markov Model Tool Kit*) [YOUNG et al. 2006] qui est l'un des logiciels les plus largement adoptés pour traiter la reconnaissance automatique de la parole.

Dans les années 2000, le programme DARPA porte sur la détection des frontières de phrases, des bruits ou des disfluences, l'obtention de résumés ou de traductions dans un contexte de parole spontanée et multi-langues [FURUI 2005]. Des méthodes pour évaluer la confiance (fiabilité) des hypothèses de reconnaissance ont également été étudiées durant cette période [JIANG 2005].

Les réseaux de neurones ont fait leur apparition dans les années 1950 [McCULLOCH et PITTS 1943], mais ils n'ont pas pu être utilisés en raison de problèmes pratiques. Ils

ont été réintroduits vers la fin des années 1980 [LIPPMANN 1987 ; WAIBEL et al. 1989 ; KATAGIRI 2003], mais ils n’ont pas pu apporter une amélioration suffisante par rapport aux systèmes HMM. C’est seulement à partir des années 2010 que les réseaux de neurones dépendants du contexte arrivent à surpasser les systèmes HMM-GMM [DAHL et al. 2012]. Cette amélioration est due à l’utilisation des nombreuses couches cachées (*Deep Neural Network*), rendue possible grâce à un algorithme efficace de pré-entraînement non supervisé [HINTON et OSINDERO 2006]. De plus, l’architecture de calcul utilisant des processeurs graphiques (GPU) permet de paralléliser efficacement l’apprentissage et le décodage de la parole.

Les réseaux de neurones sont également de plus en plus utilisés dans la modélisation lexicale [BENGIO et al. 2003 ; SCHWENK 2007 ; MIKOLOV et al. 2010] ; les modèles récurrents fournissent des améliorations significatives par rapport aux modèles n-gramme back-off classiques [MIKOLOV et al. 2011b].

Un nouvel ensemble d’outils appelé Kaldi [POVEY et al. 2011] rend possible d’utiliser les techniques de l’état de l’art pour la reconnaissance vocale.

De nos jours les chercheurs s’intéressent de plus en plus à rendre les systèmes capables de répondre à tous les types de besoins : traduction automatique, apprentissage de langues étrangères, assistant personnel, aide aux personnes handicapées ou âgées, etc. Quelques exemples des recherches courantes concernent la détection de frontières de phrases [READ et al. 2012], la reconnaissance de la parole en milieu bruité [TU et JUANG 2012], la détection de phrases de détresse [AMAN et al. 2013], de commandes [VACHER et al. 2014] ou de mots clés [JOTHILAKSHMI 2014], etc. La communication multimodale, qui prend en compte des informations complémentaires sur le visage, le mouvement des lèvres et/ou l’articulation, commence également à être prise en compte [NGIAM et al. 2011 ; GALATAS et al. 2012 ; REGENBOGEN et al. 2012].

1.2 Applications

Pour le grand public

La reconnaissance de la parole a été commercialisée pour la première fois en 1987 sous la forme d’une poupée appelée *Julie* (fabriquée par la compagnie *Worlds of Wonder*) [MARKOWITZ 2013]. Son système de traitement du signal numérique, développé par Texas Instruments, lui permettait de reconnaître huit phrases (*Julie, yes, no, ok, pretend, hungry, melody, be quiet*) et de générer des réponses. Les enfants pouvaient ainsi lui apprendre à reconnaître leur voix : “enfin, la poupée qui vous comprend”. Depuis, il y a eu d’autres poupées de type humanoïde (par exemple, *Brian the Brain*¹ - un compagnon numérique conçu pour divertir et éduquer les enfants), ainsi que des jouets qui ne ressemblent pas à l’homme. Dès nos jours, la compagnie ToyTalk² crée des applications pour smartphones qui permettent aux enfants d’interagir avec des personnages animés (dragons, unicorns et fées).

1. http://www.hammacher.com/publish/74335.asp?promo=new_items

2. <http://www.wired.com/2014/09/toytalk/>

En 1990 l'entreprise Dragon a lancé le premier outil intégrant une solution de reconnaissance vocale, *Dragon Dictate*³, qui pouvait reconnaître la parole dictée de manière discrète (i.e. avec une pause après chaque mot). Son successeur, *Dragon Naturally Speaking*, sorti en 1997 pouvait reconnaître de la parole continue, mais nécessitait un apprentissage de 45 minutes.

L'entreprise BellSouth a lancé en 1996 son système VAL⁴ - un service téléphonique interactif de reconnaissance vocale qui était censé donner des informations en fonction des demandes des utilisateurs. Son exemple a été suivi par beaucoup d'autres services téléphoniques partout dans le monde.

De nos jours, la reconnaissance vocale se trouve dans les voitures⁵ - pour exécuter des commandes simples comme lancer un appel téléphonique, envoyer un message, sélectionner les stations de radio, jouer de la musique à partir d'un smartphone ou commander et contrôler un GPS (Tom-Tom⁶, Magellan⁷); dans la médecine⁸ - pour simplifier la génération des rapports; dans l'armée⁹ - pour sélectionner les fréquences radio, contrôler le système de pilote automatique et l'affichage de vol; avec les smartphones - comme un assistant personnel (Siri¹⁰, Google Now¹¹, Cortana¹²) qui exploite les informations sur les utilisateurs pour personnaliser au mieux ses réponses et ses actions; dans l'éducation¹³ - pour soutenir l'apprentissage des personnes en difficulté ou pour apprendre une langue étrangère, etc.

Pour les personnes handicapées

En ce qui concerne l'aide aux personnes handicapées, l'utilisation des technologies de traitement de la parole est étudiée depuis de nombreuses années [NOYES et FRANKISH 1992; TANG et al. 1994; SCHÖNBÄCHLER 2003]. Les personnes sans mobilité peuvent contrôler leur fauteuil roulant électrique à travers des commandes vocales [SIMPSON 2002]. Les personnes aveugles utilisent la synthèse de la parole (conversion texte-parole) pour entendre la vocalisation de chaque mot qu'elles tapent au clavier [KLATT 1987] et la reconnaissance de la parole pour contrôler l'ordinateur à travers de commandes vocales. Le contrôle d'un ordinateur par le biais de commandes vocales est aussi utile pour les utilisateurs qui ont des difficultés à bouger les bras ou les doigts.

Les aspects ergonomiques et les conditions d'utilisation de la reconnaissance vocale pour aider les personnes sourdes ont été analysés dans [WOODCOCK 1997]. Les différentes aides apportées aux sourds comprennent des travaux sur la reconnaissance de traits

3. <http://en.wikipedia.org/wiki/DragonDictate>

4. <http://realpages.com/sites/infobyvoice/page2.html>

5. <https://technology.ihs.com/427146/>

6. <http://www.tomtom.com/news/category.php?ID=4&NID=368&Lid=1>

7. <http://www.magellangps.com/Store/All-Maestro/Magellan-Maestro-4700>

8. <http://www.medscape.com/viewarticle/487524>

9. <http://www.stephanepigeon.com/Docs/TR-IST-037-ALL.pdf>

10. <https://www.apple.com/ios/siri/>

11. <http://www.gthisgthat.com/100-tips-and-tricks-for-google-now/>

12. <http://www.windowsphone.com/en-us/how-to/wp8/cortana/meet-cortana>

13. http://www.brainline.org/content/2010/12/speech-recognition-for-learning_pageall.html

phonétiques pour aider la lecture labiale [SOKOL 1996], l’affichage de signes en langage des signes grâce à un avatar [COX et al. 2002] et l’affichage des sous-titres générés d’une manière semi-automatique ou entièrement automatique.

IBM a testé le sous-titrage en phonétique du discours d’un orateur dans une école pour enfants sourds avec le système monocuteur appelé LIPCOM [COURSANT-MOREAU et DESTOMBES 1999]. L’application était basée sur un décodage phonétique (sans aucun vocabulaire préalablement défini) et le résultat était affiché en phonèmes codés sur une ou deux lettres.

Un système de traduction automatique parole-langage de signes et langage de signes - parole en Espagnol est décrit dans [LÓPEZ-LUDEÑA et al. 2014]. Leur système a été conçu pour un scénario précis : l’accueil des personnes sourdes dans un hôtel. Il utilise deux ordinateurs portables pour faire la traduction dans les deux sens. Un temps d’adaptation est nécessaire pour que les personnes sourdes acceptent et comprennent comment utiliser le système proposé.

Le système SiSi¹⁴ (*say it, sign it*) crée par IBM génère la traduction automatique son - texte - animations 3D du langage de signes britannique et peut être utilisé sur n’importe quel écran (ordinateur portable, ordinateur fixe, téléviseur, l’écran d’une salle de réunion ou d’un auditorium, etc).

Les personnes sourdes ont appris avec le temps à utiliser tous les moyens de communication à leur disposition (en fonction des situations), mais la diversité de ces moyens leur rend la tâche encore plus difficile. Certains sourds utilisent les assistants personnels de leurs smartphones (incluant une reconnaissance vocale en-ligne) pour transcrire la parole de leur entourage, mais ça ne répond pas à tous leurs besoins. Ils sont donc toujours à l’attente d’une solution plus personnalisée.

14. <http://www-03.ibm.com/press/us/en/pressrelease/22316.wss>

Chapitre 2

Systeme de reconnaissance

Ce chapitre presente les composantes principales d'un systeme automatique de reconnaissance de la parole : la parametrisation du signal et les modeles mises en oeuvre dans les systemes de reconnaissance.

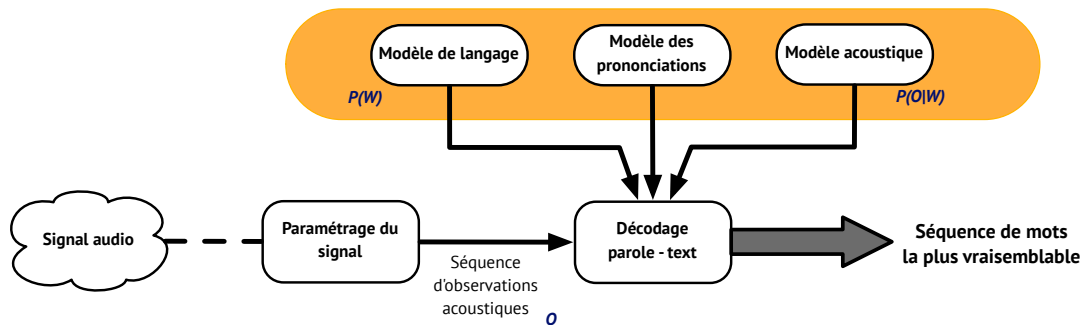


FIGURE 2.1 – Architecture d'un systeme automatique de reconnaissance vocale


Sommaire

2.1	Analyse du signal audio	15
2.2	Modele de langage	18
2.3	Modele de prononciation	22
2.4	Modele acoustique	23

2.1 Analyse du signal audio

Le signal audio est enregistre avec l'aide d'un ou plusieurs microphones, dont la position et la qualite sont cruciales pour la performance du systeme de reconnaissance vocal. La presence de plusieurs microphones places a differents endroits peut servir a localiser le locuteur, a debruiter le signal, a ameliorer la performance de reconnaissance, etc [KUMATANI et al. 2012 ; SWIETOJANSKI et al. 2013 ; BRUTTI et al. 2014 ; WOLF et NADEU 2013 ; VINCENT et al. 2015].

L'enregistrement d'un signal vocal suit les variations de la pression d'air dans le temps (Fig. 2.2). L'echantillonnage du signal est generalement fait a 16kHz pour une prise de son en direct, et a 8 kHz pour les sons transmis par telephone.


 FIGURE 2.2 – Exemple d'un signal acoustique $s(t)$

Le paramétrage du signal est effectué sur des trames successives de signal de courte durée (pour lesquelles le signal peut être considéré comme étant quasi stationnaire, typiquement 25 ms). Les trames successives se recouvrent et le décalage entre deux trames successives est typiquement de 10 ms [PICONE 1993]. Un ensemble des paramètres acoustiques est extrait sur chaque trame. Cette extraction a pour but de sélectionner les paramètres les plus importants de la parole, tout en réduisant la dimensionnalité des données.

2.1.1 Analyse MFCC

L'analyse acoustique MFCC (*Mel Frequency Cepstrum Coefficients*) [DAVIS et MERMELSTEIN 1980] (fréquemment utilisée et également utilisée dans nos travaux) implique plusieurs traitements sur le signal audio :




FIGURE 2.3 – Principe de l'analyse cepstrale

1) La pré-accentuation privilégie les sons aigus (hautes fréquences) :

$$s_1(t) = s(t) - 0,98 \cdot s(t-1) \quad (2.1)$$

2) Le fenêtrage de Hamming permet de réduire les discontinuités dans le signal :

$$h(n) = \begin{cases} 0,54 - 0,46 \cdot \cos(2\pi \frac{n}{N-1}), & \text{si } 0 \leq n \leq N-1 \\ 0, & \text{sinon} \end{cases} \quad (2.2)$$

où N est la taille de la fenêtre. Le signal devient :

$$s_2(t) = s_1(t) \cdot h(t) \quad (2.3)$$

3) La transformée de Fourier est appliquée sur chaque trame

$$S_3(f) = \sum_{n=0}^{N-1} s_2(n) e^{-i2\pi \frac{f}{N} n} \quad (2.4)$$




FIGURE 2.4 – Spectrogramme d'un signal audio de parole

Cela donne un spectre fréquentiel à court terme. Le spectrogramme montre l'évolution temps-fréquence du signal (Fig. 2.4) ; les maxima d'énergie sont indiqués par des zones sombres.

4) Les filtres triangulaires uniformément espacés sur l'échelle Mel (cf. Fig. 2.5) réduisent le nombre de bandes de fréquence, par rapport à la FFT (transformée de Fourier) et modélisent la nonlinéarité de la perception audio humaine au niveau des fréquences. Chaque filtre fournit un coefficient qui donne l'énergie du signal dans la bande qu'il couvre.




FIGURE 2.5 – Banc de filtres à échelle Mel ; répartition linéaire jusqu'à 1000 Hz, logarithmique au delà

5) Le passage dans le domaine log-spectral permet de déconvoluer le signal et de le compresser.

6) Un ensemble de M coefficients cepstraux (en général, M choisit entre 10 et 15) sont alors calculés grâce à la transformée en cosinus discrète :

$$c_i = \sum_{j=1}^{N_f} S(j) \cos \left(\pi \cdot i \cdot \frac{j - \frac{1}{2}}{N_f} \right) \text{ pour } i = \{1, \dots, M\} \quad (2.5)$$

où N_f indique le nombre de filtres Mel utilisés, M indique le nombre de coefficients et $S(j)$ est le logarithme de l'énergie dans le filtre j .

Généralement, seuls les 13 premiers coefficients MFCC (de C_0 à C_{12}) sont retenus. Parfois le paramètre C_0 peut être remplacé par le logarithme de l'énergie de la trame. La prise en compte des dérivées temporelles premières et secondes permet d'obtenir une amélioration notable des performances (pour un total de 39 paramètres).

2.1.2 Autres types d'analyse

Un type particulier d'analyse cepstrale est l'analyse MFCC Aurora [SORIN et al. 2004], qui a été développée pour la reconnaissance distribuée dans le cadre d'une normalisation à l'ETSI (*European Telecommunications Standards Institute*). Dans un premier temps l'analyse acoustique a été rendue robuste au bruit en y incluant une étape de débruitage [MACHO et al. 2002]. Les travaux suivants (dans le cadre de l'ETSI) ont porté sur l'introduction du calcul du pitch (nécessaire pour le traitement des langues tonales, et aussi pour reconstruire un signal de parole compréhensible à partir des coefficients acoustiques) [SORIN et al. 2004].

D'autres types d'analyses acoustiques existent, notamment les paramètres PLP (*perceptual linear predictive*) [HERMANSKY 1990] ou les paramètres PNCC (*power-normalized cepstral coefficients*) [KIM et STERN 2012], ou des techniques qui réduisent la dimensionnalité des vecteurs acoustiques (dans le but de les décorréler) comme la LDA (*linear discriminant analysis*) [SCHLUTER et NEY 2001; ZOLNAY et al. 2005], la HLDA (*heteroscedastic linear discriminant analysis*) [KUMAR et ANDREOU 1998], la NCA (*neighbour component analysis*) [SINGH-MILLER et al. 2007], la PCA et l'ICA (*principal / independent component analysis*) [HUANG et al. 2001], etc. Des réseaux de neurones peuvent également être utilisés dans la phase d'extraction de paramètres pour calculer les paramètres 'bottleneck' [GRÉZL et al. 2007; YU et SELTZER 2011; GEHRING et al. 2013].

2.2 Modèle de langage

Les modèles de langage statistiques sont des processus qui permettent d'estimer les probabilités des différentes séquences de mots $P(W) = P(w_1, w_2, \dots, w_{m-1}, w_m)$. Ces modèles servent à 'mémoriser' des séquences de mots à partir d'un corpus textuel d'apprentissage.

Dans le contexte de la reconnaissance de la parole, les modèles de langage servent à guider et à contraindre la recherche parmi les hypothèses de mots alternatives.

2.2.1 Modèles n-grammes

Les modèles de langage les plus utilisés (et également utilisés dans notre travail) sont des modèles n-grammes. Les modèles de langage n-grammes se basent sur l'approximation que la probabilité d'un certain mot w_k dépend seulement de ses $n - 1$ mots précédents $P(w_k | w_{k-(n-1)}, w_{k-(n-2)}, \dots, w_{k-1})$; leur apprentissage nécessite un grand corpus de texte.

La probabilité $P(W)$ est décomposée d'abord avec la règle d'enchaînement :

$$\begin{aligned} P(W) &= P(w_1, w_2, \dots, w_{m-1}, w_m) \\ &= P(w_1) \cdot P(w_2 | w_1) \cdot P(w_3 | w_1, w_2) \cdot \dots \cdot P(w_m | w_1, w_2, \dots, w_{m-1}) \end{aligned} \quad (2.6)$$

et ensuite avec l'approximation n-gramme, qui limite l'historique à seulement $n - 1$ mots :

$$P(w_m|w_1, w_2, \dots, w_{m-1}) \cong P(w_m|w_{m-(n-1)}, \dots, w_{m-1}) \quad (2.7)$$

Dans un modèle 3-gramme (1 mot courant, 2 mots pour décrire l'historique) la probabilité $P(W)$ se calcule avec la formule :

$$P(W) \cong P(w_1) \cdot P(w_2|w_1) \cdot P(w_3|w_1, w_2) \cdot \dots \cdot P(w_m|w_{m-2}, w_{m-1}) \quad (2.8)$$

Diverses méthodes d'estimation

Pour estimer les probabilités des n-grammes, plusieurs approches ont été considérées au fil des années.

L'estimation du maximum de vraisemblance est basée seulement sur les fréquences d'occurrence des suites de mots. Une grande probabilité est associée aux séquences de mots qui sont fréquentes dans le corpus d'apprentissage, une très faible probabilité - aux séquences de mots peu fréquentes et une probabilité nulle aux événements inconnus.

$$P(w_k|w_{k-2}, w_{k-1}) = \frac{\text{count}(w_{k-2}, w_{k-1}, w_k)}{\text{count}(w_{k-2}, w_{k-1})} \quad (2.9)$$

Les techniques de *smoothing*, *discounting* et *back-off* essaient d'améliorer la capacité de généralisation d'un apprentissage fait sur un corpus textuel. Les connaissances apprises sont forcément liées aux corpus et les informations comprises dans ce corpus ne reflètent pas nécessairement la réalité, l'actualité, ni tous les domaines possibles. Si une séquence de mots est peu fréquente ou même absente dans un corpus, ça ne signifie pas forcément qu'elle n'est pas importante.

La méthode "*add- α smoothing*" ajoute " α " occurrences fictives dans l'équation de l'estimation du maximum de vraisemblance pour augmenter la probabilité des séquences inconnues (absentes dans le corpus d'apprentissage) :

$$P(w_k|w_{k-2}, w_{k-1}) = \frac{\text{count}(w_{k-2}, w_{k-1}, w_k) + \alpha}{\text{count}(w_{k-2}, w_{k-1}) + \alpha V} \quad (2.10)$$

où V est la taille du vocabulaire et $0 < \alpha \leq 1$.

Les méthodes "*intuition smoothing*" de Good-Turing, Kneser-Ney et Witten-Bell se basent sur l'intuition que les séquences de mots qui ont été vues une seule fois aident à estimer la fréquence d'occurrence des séquences jamais vues. Elles introduisent une nouvelle notation :

N_c = le nombre des n-grammes vus c fois dans le corpus

Par exemple, la méthode Good-Turing [Good 1953] estime la probabilité des séquences inconnues :

$$P_{GT}(\text{séquence inconnue}) = \frac{N_1}{N} \quad (2.11)$$

(où N est le nombre total d'occurrences) et réactualise ("*discounting*") les probabilités

des séquences connues :

$$P_{GT}(\text{n-gramme vu } c \text{ fois}) = \frac{N_c^*}{N} = \frac{(c+1)N_{c+1}}{N} \quad (2.12)$$

Les méthodes de “*back-off*” traitent la diversité des événements inconnus, auxquels les méthodes classiques de lissage (*smoothing*) attribuent la même probabilité. Pour cela, elles proposent de prendre en compte un historique plus court pour les événements moyennement fréquents. La probabilité “*back-off*” du modèle devient :

$$p_n^{BO}(w_k | w_{k-(n-1)}, \dots, w_{k-1}) = \begin{cases} \alpha_n(w_k | w_{k-(n-1)}, \dots, w_{k-1}), & \text{si } \text{count}_n(w_{k-(n-1)}, \dots, w_{k-1}) > 0 \\ d_n(w_{k-(n-1)}, \dots, w_{k-1}) p_{n-1}^{BO}(w_k | w_{k-(n-2)}, \dots, w_{k-1}), & \text{sinon} \end{cases} \quad (2.13)$$

où $\alpha_n(w_k | w_{k-(n-1)}, \dots, w_{k-1})$ est le modèle de prédiction ajusté et $d_n(w_{k-(n-1)}, \dots, w_{k-1})$ est la fonction d’actualisation (*discounting function*).

Dans le cas de modèles trigrammes, les méthodes d’interpolation impliquent la combinaison des 1-grammes, 2-grammes, 3-grammes pour estimer la probabilités des séquences de mots.

L’interpolation conditionnelle sur le contexte :

$$\begin{aligned} \hat{P}(w_k | w_{k-2}, w_{k-1}) &= \lambda_{w_{k-2}, w_{k-1}, w_k} P(w_k | w_{k-2}, w_{k-1}) \\ &+ \lambda_{w_{k-1}, w_k} P(w_k | w_{k-1}) \\ &+ \lambda_{w_k} P(w_k) \end{aligned} \quad (2.14)$$

associe différents indices de confiance (à travers les valeurs λ) au différentes probabilités en fonction de leur contexte (historique).

Méthode d’estimation la plus utilisée

En pratique, la méthode la plus utilisée est celle de Chen-Goodman [CHEN et GOODMAN 1998] qui propose une modification de la méthode de Kneser-Ney [NEY et al. 1995]. La méthode Kneser-Ney (cf. l’équation 2.15) considère que la probabilité d’un unigramme ne doit pas être proportionnelle au nombre d’occurrences des mots, mais au nombre de différents mots qu’il suit (pour éviter d’attribuer une grande probabilité au mots qui sont fréquents mais qui suivent toujours le même mot).

$$P_{KN}(w_k | w_{k-(n-1)}^{k-1}) = \frac{\max\{\text{count}(w_{k-(n-1)}, \dots, w_k) - D, 0\}}{\text{count}(w_{k-(n-1)}, \dots, w_{k-1})} + \frac{D}{\text{count}(w_{k-(n-1)}, \dots, w_{k-1})} N_{1+}(w_{k-(n-1)}^{k-1} \bullet) P_{KN}(w_k | w_{k-(n-2)}^{k-1}) \quad (2.15)$$

La notation $N_{1+}(w_{k-(n-1)}^{k-1} \bullet)$ désigne le nombre de mots uniques qui suivent au

moins une fois le contexte $w_{k-(n-1)}^{k-1}$; n indique l'ordre du modèle.

$$N_{1+} \left(w_{k-(n-1)}^{k-1} \bullet \right) = |\{w_k : \text{count}(w_{k-(n-1)}, \dots, w_{k-1}, w_k) \geq 1\}| \quad (2.16)$$

La valeur D optimale est $D = N_1 / (N_1 + 2N_2)$.

La méthode Chen-Godman utilise à la place d'un seul paramètre d'actualisation D , trois paramètres d'actualisation D_1, D_2, D_{3+} qui sont appliqués sur les n -grammes avec une, deux et trois occurrences ou plus (cf. l'équation 2.17). Ils considèrent que l'actualisation moyenne idéale pour les n -grammes vus une ou deux fois est sensiblement différente de l'actualisation moyenne idéale pour les n -grammes avec des fréquences plus élevées.

$$P_{CG} \left(w_k | w_{k-(n-1)}^{k-1} \right) = \frac{\text{count}(w_{k-(n-1)}, \dots, w_k) - D(\text{count}(w_{k-(n-1)}, \dots, w_k))}{\text{count}(w_{k-(n-1)}, \dots, w_{k-1})} + \gamma \left(w_{k-(n-1)}^{k-1} \right) P_{CG} \left(w_k | w_{k-(n-2)}^{k-1} \right) \quad (2.17)$$

Les variables $D(c)$ et $\gamma \left(w_{k-(n-1)}^{k-1} \right)$ sont définies par :

$$D(c) = \begin{cases} 0 & \text{if } c = 0 \\ D_1 = 1 - 2 N_2 / N_1 Y & \text{if } c = 1 \\ D_2 = 2 - 3 N_3 / N_2 Y & \text{if } c = 2 \\ D_{3+} = 3 - 4 N_4 / N_3 Y & \text{if } c \geq 3 \end{cases}$$

où $Y = N_1 / (N_1 + 2N_2)$

$$\gamma \left(w_{k-(n-1)}^{k-1} \right) = \frac{D_1 N_1 \left(w_{k-(n-1)}^{k-1} \bullet \right) + D_2 N_2 \left(w_{k-(n-1)}^{k-1} \bullet \right) + D_{3+} N_{3+} \left(w_{k-(n-1)}^{k-1} \bullet \right)}{\text{count}(w_{k-(n-1)}, \dots, w_{k-1})}$$

Les variables $N_1 \left(w_{k-(n-1)}^{k-1} \bullet \right)$, $N_2 \left(w_{k-(n-1)}^{k-1} \bullet \right)$ et $N_{3+} \left(w_{k-(n-1)}^{k-1} \bullet \right)$ sont définies de manière analogue à l'équation 2.16.

2.2.2 Autres modèles

Une limitation importante des modèles n -grammes surgit du fait que les liens entre les mots dépendent strictement de leur position dans la phrase. Une taille n plus grande permet de retrouver un nombre plus important des liens entre les mots, mais nécessite de plus grands corpus pour leur apprentissage. Dans l'état de l'art, la taille optimale d'un modèle n -gramme est égale à 5 (à condition d'avoir une quantité suffisante de données d'apprentissage). Dans la pratique, les modèles 3-grammes et 4-grammes sont les plus répandues.

Les autres techniques de modélisation statistique du langage incluent des modèles de langage basés sur des classes [GOODMAN 2001], des modèles n -grammes cache [JELINEK

et al. 1991], des modèles structurés [CHELBA et JELINEK 2000], des modèles basés sur une forêt aléatoire (mélange de plusieurs arbres de décision) [XU et JELINEK 2007], des modèles basés sur un réseau de neurones [BENGIO et al. 2003; SCHWENK 2007; MIKOLOV et al. 2010; MIKOLOV et al. 2011b; IRIE et al. 2015; MASUMURA et al. 2015] ou une combinaison de plusieurs types de modèles [MIKOLOV et al. 2011a].

Les modèles de langage basés sur un réseau de neurones sont appliqués dans la reconnaissance automatique de la parole (notamment les modèles récurrents) [MIKOLOV et al. 2011b] et dans la traduction automatique [VASWANI et al. 2013], et fournissent des améliorations significatives par rapport aux modèles n-gramme back-off classiques.

Les modèles de langage basés sur un réseau de neurones récurrent (*recurrent neural network based language model*, *RNNLM*) utilisent une couche d'entrée, une couche cachée (la couche du contexte) et une couche de sortie. La couche d'entrée au temps t contient le vecteur des mots (un vecteur de taille N qui contient $N - 1$ valeurs nulles et une seule valeur égale à 1 pour indiquer quel mot est couramment traité dans la liste de N mots du vocabulaire), complété par le vecteur représentant la couche cachée précédente (au temps $t - 1$). La couche cachée est une fonction d'activation sigmoïde. Le vocabulaire contient généralement entre 30K mots et 200K mots. La couche cachée contient entre 30 et 500 unités cachées, en fonction de la taille du corpus d'apprentissage. La couche de sortie donne la distribution de probabilités du mot suivant (fonction d'activation *softmax*), basée sur le mot courant et le contexte précédent.

2.2.3 Évaluation

La qualité d'un modèle de langage (sa *perplexité*) est évaluée sur un ensemble de phrases d'un corpus de test avec la formule de l'entropie croisée :

$$perplexity(W) = 2^{H(W)} = 2^{\frac{1}{n} \log_2 P(W)} \quad (2.18)$$

où n indique le nombre de mots dans l'ensemble de phrases W du corpus. Plus la perplexité est faible, meilleure est la qualité du modèle.

La métrique du taux d'erreur de mots WER (voir section 3.2) peut également évaluer la qualité d'un modèle de langage dans le contexte de la reconnaissance automatique de la parole.

2.3 Modèle de prononciation

Le lexique d'un système de reconnaissance vocale précise une ou plusieurs prononciations pour chaque mot. Pour le français, les prononciations multiples sont en partie dues aux événements de liaison ou de réduction, dans le cadre desquels un locuteur peut prononcer ou pas un certain phonème dans un certain contexte. Les accents et les dialectes peuvent aussi générer diverses variantes de prononciations.

La liaison implique la prononciation d'un phonème de liaison entre deux mots. Pour donner un exemple : les mots "les oiseaux" se prononcent séparément "l e" et "w a z o" (en notation API), alors qu'ensemble ils se prononcent "l e z w a z o".

La réduction implique l’omission d’un phonème a priori présent dans la prononciation standard d’un mot, comme dans le cas de “ce” qui se prononce normalement “c ə”, mais qui peut également être prononcé simplement “c” dans le cas d’une prononciation rapide.

Les variantes de prononciation peuvent être obtenues manuellement, avec l’expertise des linguistes, ou automatiquement - avec des convertisseurs graphèmes-phonème basés sur des techniques comme les JMM (*joint-multigram models*) ou les CRF (*conditional random fields*) [ILLINA et al. 2011; JOUVET et al. 2012]. Le graphème est une lettre ou un ensemble de lettres représentant un phonème. Les règles de correspondance entre graphèmes et phonèmes sont complexes, irrégulières et spécifiques à chaque langue. En général, la conversion graphèmes-phonèmes peut être exprimée comme $\tilde{Q} = \underset{Q}{\text{ArgMax}} P(Q, G)$, où G est l’orthographe du mot (séquence de graphèmes) et Q est une prononciation candidate.

La méthode JMM [BISANI et NEY 2008] applique un modèle de langage sur des couples {séquence de graphèmes, séquence de phonèmes}. L’algorithme d’apprentissage vise à déterminer l’ensemble optimal des séquences de graphèmes et de phonèmes ainsi que le modèle de langage associé, de façon incrémentale : un passage initial crée un modèle très simple, ensuite, chaque nouvelle passe d’apprentissage affine le modèle en agrandissant les séquences (si possible).

La méthode CRF [WANG et KING 2011] modélise la distribution des probabilités conditionnelles d’une séquence d’étiquettes (la séquence de phonèmes) étant donnée une séquence d’observation (la séquence de graphèmes). En l’absence d’un corpus de données pré-étiquetées, les modèles HMM discrets peuvent être utilisés pour aligner les phonèmes avec les lettres.

2.4 Modèle acoustique

Le modèle acoustique est un modèle statistique qui estime la probabilité qu’un phonème ait généré une certaine séquence de paramètres acoustiques. Une grande variété de séquences de paramètres acoustiques sont observées pour chaque phonème en raison de toutes les variations liées à la diversité des locuteurs, à leur âge, leur sexe, leur dialecte, leur état de santé, leur état émotionnel, etc.

2.4.1 Modèles HMM

Dans notre travail, les modèles acoustiques sont basés sur les modèles de Markov cachés (*Hidden Markov Models*, HMM) qui définissent la répartition temporelle des paramètres acoustiques pour chaque phonème [RABINER 1989; PICONE 1990].

Les modèles de Markov d’ordre 1 sont des automates probabilistes à états finis qui se basent sur l’hypothèse que “le futur ne dépend que de l’état présent”. L’état du modèle au temps t ne dépend donc que de l’état du modèle au temps $t - 1$: $P(q_t | q_1, q_2, \dots, q_{t-1}) \cong P(q_t | q_{t-1})$ où q_t est l’état du système au temps t . À chaque étape temporelle, le modèle évolue suivant la fonction de transition et passe potentiellement dans un nouvel état ; l’évolution du système n’est connue qu’à travers des statistiques.




FIGURE 2.6 – Exemple de HMM utilisé pour modéliser les phonèmes

Un modèle de Markov caché (HMM) est un modèle de Markov avec des états non observés (cachés).

Plus formellement, les modèles de Markov cachés sont définis par :

- un ensemble fini d'états $\{1, \dots, N\}$
- l'évolution du système $Q = (q_1, \dots, q_t, \dots, q_T)$, où $q_t \in \{1, \dots, N\}$ est l'état du système à l'instant t
- la matrice de transitions $A : Q \times Q \rightarrow [0, 1]$ où $a_{ij} = P(q_t = j | q_{t-1} = i)$, pour les états $i, j \in \{1, \dots, N\}$ et $\sum_{j=1}^N a_{ij} = 1, \forall i$
- l'ensemble de densités d'observations $B = \{b_j(o_t)\} = P(o_t | q_t = j)$, où $o_t \in \mathbb{R}^d$ est le vecteur d'observation à l'instant t , et d est la dimension de l'espace des attributs
- la distribution initiale de probabilités $\pi_i = P(q_0 = i)$ pour chaque état initial q_0

En reconnaissance de la parole, les HMMs sont utilisés pour répondre à la question : “Ayant un signal acoustique O , quel est la phrase ayant la plus grande probabilité d'avoir été prononcée?”. Une phrase est composée de mots, les mots sont composés des phonèmes, les phonèmes sont observés à travers des paramètres acoustiques. Dans ce contexte :

- le signal de parole est produit par une suite d'états ; un modèle de Markov est associé à chaque phonème, leur concaténation représentant les mots et les phrases
- le modèle est stationnaire : $P(q_t = j | q_{t-1} = i) = P(q_{t+\nu} = j | q_{t+\nu-1} = i)$
- les observations sont indépendantes : $P(o_t | q_1 \dots q_t, o_1 o_2 \dots o_{t-1}) = P(o_t | q_1 \dots q_t)$
- l'émission d'une observation dépend seulement de l'état courant : $P(o_t | q_t q_{t-1} \dots q_1) = P(o_t | q_t)$
- la distribution des probabilités d'émission est approchée par un mélange de k lois gaussiennes de la forme :

$$b_j(o_t) = \sum_{k=1}^K \frac{c_{jk}}{\sqrt{(2\pi)^d |\Sigma_{jk}|}} \exp\left(-\frac{1}{2}(o_t - \mu_{jk})^T \Sigma_{jk}^{-1} (o_t - \mu_{jk})\right)$$

où μ_{jk} et Σ_{jk} sont la moyenne et la matrice de covariance de la k^{me} loi normale de la densité b_j , c_{jk} est la pondération de la loi k (avec $\sum_{k=1}^K c_{jk} = 1$) et $|\Sigma_{jk}|$ est le déterminant de la matrice Σ_{jk} .

Les modèles HMM qui utilisent une distribution multi-gaussienne des probabilités

d'émission sont couramment qualifiés de HMM-GMM dans la littérature [RABINER et JUANG 1993].

Apprentissage de modèles HMM-GMM

L'apprentissage d'un modèle acoustiques consiste à trouver les meilleures correspondances et le meilleur alignement entre les paramètres acoustiques des signaux audio (chaque intervalle de 10ms du signal audio est associé à un vecteur de paramètres acoustiques) et les transcriptions correspondantes (séquence de mots correspondant à la phrase prononcé). Les frontières entre les mots (et en conséquence entre les phonèmes composants les mots) ne sont pas connues à l'avance.

L'algorithme de Baum-Welch, basé sur la technique de l'estimation du maximum de vraisemblance, améliore itérativement la solution et garantit de trouver les valeurs optimales des paramètres (optimum local) [BAUM et PETRIE 1966]. À partir d'un modèle initial Λ_0 et d'une observation O , un nouveau modèle Λ' est généré, qui améliore la vraisemblance des données d'apprentissage. Le processus se répète en considérant le nouveau modèle obtenu comme modèle initial, jusqu'à la validation de la condition d'arrêt (atteinte d'un optimum ou nombre maximum d'itérations).

L'algorithme utilise deux variables $\gamma_t(i)$ et $\xi_t(i, j)$:

— la probabilité d'être dans l'état i au temps t

$$\gamma_t(i) = P(q_t = i | O, \Lambda) = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^N \alpha_t(i)\beta_t(i)}$$

— la probabilité d'être dans l'état i au temps t et dans l'état j au temps $t + 1$

$$\begin{aligned} \xi_t(i, j) &= P(q_t = i, q_{t+1} = j | O, \Lambda) \\ &= \frac{\alpha_t(i)a_{ij}b_j(o_{t+1})\beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i)a_{ij}b_j(o_{t+1})\beta_{t+1}(j)} \end{aligned}$$

La variable $\alpha_t(i) = P(o_1 \dots o_t, q_t = i | \Lambda)$ (variable "forward") indique la probabilité d'émettre les t premières observations et d'être à l'état i à l'instant t . Pour la calculer :

— initialisation $\alpha_1(i) = \pi_i b_i(o_1)$

— induction $\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1})$ où $1 \leq i \leq N$, $t = 1, \dots, T - 1$

— terminaison $P(O | \Lambda) = \sum_{i=1}^N \alpha_T(i)$

La variable $\beta_t(j) = P(o_{t+1} \dots o_T | q_t = j, \Lambda)$ (variable "backward") indique la probabilité d'émettre les observations de $t + 1$ à T en partant de l'état j à l'instant t . Pour la calculer :

— initialisation $\beta_T(i) = 1$

— induction $\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)$ où $1 \leq i \leq N$, $t = T - 1, \dots, 1$

— terminaison $P(O|\Lambda) = \sum_{i=1}^N \pi_i b_i(o_1) \beta_1(i)$

Les lois de mises à jour des paramètres pour le nouveau modèle $\Lambda' = \{\bar{\Pi}, \bar{A}, \bar{B}\}$:

— la distribution initiale de probabilités $\bar{\pi}_i = \gamma_1(i)$

— la matrice de transitions $\bar{a}_{ij} = \frac{\sum_{t=1}^T \xi_t(i,j)}{\sum_{t=1}^T \gamma_t(i)}$

— la moyenne de la gaussienne de l'état i (dans cas monogaussien) :

$$\mu_i = \frac{\sum_{t=1}^T \gamma_t(i) o_t}{\sum_{t=1}^T \gamma_t(i)}$$

— la covariance de la loi normale de l'état i (dans cas monogaussien) :

$$\Sigma_i = \frac{\sum_{t=1}^T \gamma_t(i) (o_t - \mu_i)(o_t - \mu_i)^T}{\sum_{t=1}^T \gamma_t(i)}$$

Détails de modélisation

Typiquement, chaque phonème de la langue est associé à un modèle HMM à 3 états. Dans la pratique, comme les réalisations acoustiques des sons sont fortement influencées par des phénomènes de coarticulation avec les sons voisins, les modèles pour les sons sont définis en contexte. Par exemple le phonème /a/ aura un modèle pour [p]_a_[r] (i.e. /a/ précédé de /p/ et suivi de /r/), un modèle pour [b]_a_[d], un modèle pour [b]_a_[s], etc. Comme le nombre total de combinaisons possibles devient très grand, les densités de probabilité multi-gaussiennes sont partagées entre les modèles contextuels. Cela permet d'ajuster le nombre total de paramètres à estimer en fonction des corpus disponibles pour leur estimation et des ressources qui seront disponibles lors de la reconnaissance. Dans les outils Sphinx, ces densités partagées sont qualifiées de "sénones".

Les deux principaux paramètres qui influent sur la taille globale du modèle acoustique (i.e. incluant tous les phonèmes en contexte) sont donc le nombre total de sénones - i.e. le nombre de densités de probabilité partagées entre les modèles contextuels des sons, et le nombre de gaussiennes par densité - un nombre élevé de gaussiennes permet de mieux modéliser les variantes de réalisation acoustique des sons, réalisations qui varient selon les locuteurs (sexe, âge, état de santé, etc), l'environnement (calme, bruité), etc.

2.4.2 Autres modèles

Les méthodes les plus récentes de modélisation acoustique proposent des réseaux de neurones profonds dépendants du contexte (*context dependent deep neural network*, *CD-DNN*) à la place des distributions multi-gaussiennes des probabilités d'émission, et

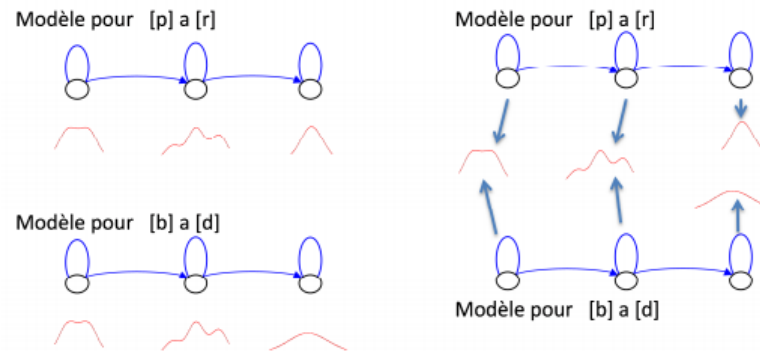


FIGURE 2.7 – Principe du partage des densités de probabilité (sénones) entre les états des modèles contextuels des sons (à gauche, pas de partage des densités ; à droite, partage des densités)

fournissent des améliorations significatives par rapport aux modèles HMM-GMM [DAHL et al. 2012 ; HINTON et al. 2012,]. Leur succès provient de l'utilisation de plusieurs couches cachées (généralement entre 5 et 7), chacune ayant environ 2048 unités avec un sigmoïde non-linéaire. La couche de sortie a une non-linéarité *softmax* et un nombre d'unités de sortie égal au nombre d'états HMM. De plus, l'architecture de calcul utilisant des processeurs graphiques (*GPU*) permet de paralléliser efficacement l'apprentissage et le décodage de la parole.

Les extensions récentes des modèles DNN incluent les réseaux de neurones convolutifs [ABDEL-HAMID et al. 2012] et les réseaux de neurones récurrents [SAK et al. 2014].

Chapitre 3

Processus de reconnaissance

Ce chapitre présente l'algorithme de décodage, les métriques pour évaluer la performance du système et les mesures de confiance.

Sommaire

3.1	Algorithme de décodage	29
3.2	Évaluation des performances	31
3.3	Mesures de confiance	32

3.1 Algorithme de décodage

Le processus de reconnaissance automatique de la parole (également connu sous le nom de décodage de la parole) détermine la séquence de mots \hat{W} la plus vraisemblable étant donné une séquence d'observations acoustiques O :

$$\hat{W} = \underset{W}{\text{ArgMax}} P(W|O) = \underset{W}{\text{ArgMax}} \frac{P(O|W)P(W)}{P(O)} \cong \underset{W}{\text{ArgMax}} P(O|W)P(W)$$

où $P(O|W)$ est la probabilité acoustique et $P(w)$ est la probabilité linguistique.

La formule pour la reconnaissance de la parole suggère que la probabilité du modèle acoustique et la probabilité du modèle de langage peuvent être combinées à travers une simple multiplication. En pratique il est nécessaire d'effectuer une pondération. Sans cela, la contribution d'un des modèles est négligeable à cause de la différence d'ordre de grandeur de leurs probabilités. En effet, les probabilités du modèle acoustique (qui sont en fait les valeurs de densités de probabilité continues multi-gaussiennes) sont beaucoup plus petites que celles du modèle de langage : $P(O|W) \ll P(W)$. La solution la plus couramment utilisée pour atténuer ce problème consiste à ajouter un poids, noté lw (*linguistic weight*), au modèle du langage. La nouvelle formule pour la reconnaissance de la parole devient alors :

$$\underset{W}{\text{ArgMax}} P(W|O) \cong \underset{W}{\text{ArgMax}} P(O|W)P(W)^{lw}$$

Le processus de reconnaissance doit trouver la meilleure séquence d'états (de phonèmes) qui pourrait donner la suite d'observations correspondant à la prononciation d'une certaine phrase (séquence de mots). Deux inconnues doivent être gérées dans le cas d'une reconnaissance de parole continue : le nombre de mots que contient la phrase prononcée et les "frontières" de chaque mot.

Les modèles HMM des mots sont obtenus en concaténant les modèles HMM des phonèmes (par rapport à leur prononciations définies dans le lexique). Les modèles HMM des séquences de mots sont obtenus en concaténant les modèles HMM des mots (l'état final d'un mot est concaténé à l'état initial du mot suivant). La séquence d'observations acoustiques O est extraite à partir du signal audio (cf. section 2.1).

Les informations disponibles sont le vocabulaire de N mots, les modèles HMM des phonèmes : M_1, M_2, \dots, M_p et la séquence d'observations acoustiques $O = (o_1, o_2, \dots, o_T)$.

La solution optimale, fournie par l'algorithme de Viterbi [VITERBI 1967], peut être implémentée par une matrice $T \times N$ contenant les valeurs $\delta_t(i)$ qui définissent la vraisemblance du meilleur chemin qui finit à l'état i au temps t :

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P(q_1, q_2, \dots, q_t = i, o_1, o_2, \dots, o_t | \Lambda) \quad (3.1)$$




FIGURE 3.1 – Exemple d'une recherche Viterbi avec un modèle HMM de 5 états (3 états émetteurs et 2 états non-émetteurs) sur un signal audio de 7 trames (70 millisecondes)

Le calcul peut être implémenté par récurrence :

- initialisation : $\delta_0^k(i) = \pi_i^k$, avec k désignant l'un des mots du vocabulaire pouvant commencer une phrase (d'après le modèle de langage)
- hypothèse de récurrence :
 - état non initial du mot k :

$$\delta_t^k(j) = \max_i (\delta_{t-1}^k(i) \cdot a_{ij}^k) \cdot b_j^k(o_t)$$
 - état initial du mot k :

$$\delta_t^k(i) = \max \left(\delta_{t-1}^k(i) \cdot a_{ii}^k, \max_l (\delta_{t-1}^l(\text{état final}(l)) * P(w_k | w_l)) \right) \cdot b_i^k(o_t)$$
- terminaison : $P = \max_k (\delta_T^k(i))$

Une structure supplémentaire est utilisée pour mémoriser l'état qui a donné le maximum de vraisemblance à chaque pas, afin de retrouver la séquence de mots.

Le système de reconnaissance fournit généralement la phrase la plus probable (séquence de mots ayant la plus grande vraisemblance δ_T) comme seule et unique solution.

Cependant, d'autres formes de représentation de résultats de reconnaissance existent, comme la liste de n meilleurs résultats ou le graphe de mots, qui sont générées avec plusieurs passes de décodage (une première utilisant des modèles moins précis pour restreindre l'espace de recherche, et les autres avec des modèles plus détaillés pour re-estimer les scores). La liste de n meilleurs résultats (*n-best list*) est constituée d'un sous-ensemble de phrases hypothèses générées par le décodeur suivant les meilleurs scores de vraisemblance ; la plupart de phrases ne diffèrent entre elles que d'un mot. Le graphe de mots mémorise les multiples chemins possibles du début à la fin de la phrase, indexés par rapport au temps (*frame positioned word graph*) ou par rapport à la position de mots dans la phrase (*word positioned word graph*, autrement connus sous le nom de réseaux de confusion).

3.2 Évaluation des performances

L'évaluation de la reconnaissance de la parole est donnée par le critère du taux d'erreur de mots WER (*Word Error Rate*) qui mesure le rapport du nombre d'erreurs de reconnaissance sur le nombre total de mots prononcés (cf. l'équation 3.2). Il y a trois types d'erreurs de reconnaissance : substitution (S), omission (O) et insertion (I). La vérification des erreurs de reconnaissance nécessite une transcription de référence, qui est généralement créé manuellement.

$$WER = \frac{S + O + I}{N_{mots}} \quad (3.2)$$

Une autre mesure d'évaluation est fournie par le critère du taux d'erreur de phonèmes PER (*Phoneme Error Rate*), mesuré au niveau des phonèmes :

$$PER = \frac{S + O + I}{N_{phonèmes}} \quad (3.3)$$

Dans l'exemple donné dans le tableau 3.1, le système de reconnaissance a fait 3 erreurs : 1 omission (du mot 'qui') et 2 substitutions (de mots 'a' et 'été'). Le taux d'erreur de mots est de $3/8 = 37.50\%$.

Référence :	c'	est	son	bureau	qui	a	été	perquisitionné
Hypothèse :	c'	est	son	bureau		c'	était	perquisitionné
Évaluation :					O	S	S	

TABLE 3.1 – Évaluation d'un résultat du décodage

La comparaison entre deux séquences (de mots) $A = a_1, a_2, \dots, a_m$ et $B = b_1, b_2, \dots, b_n$ est effectuée avec l'algorithme "edit distance" de programmation dynamique de Wag-

ner–Fischer [WAGNER et FISCHER 1974], qui calcule le coût minimum de mise en correspondance.

Référence :	c' est son bureau qui a été perquisitionné
Hypothèse :	c' est son bureau c' était perquisitionné
Solution1 :	omission(qui) + substitution(a → c') + substitution(été → était)
Solution2 :	substitution(qui → c') + omission(a) + substitution(été → était)
Solution3 :	substitution(qui → c') + substitution(a → était) + omission(été)

TABLE 3.2 – Solutions multiples pour la mise en correspondance d’une hypothèse de reconnaissance avec la transcription de référence

Plusieurs chemins peuvent avoir le même coût minimum (cf. le tableau 3.2). C’est seulement ce coût qui établit la performance de reconnaissance.

3.3 Mesures de confiance

L’algorithme de décodage est un processus probabiliste qui recherche la meilleure adéquation entre un signal audio et une séquence de mots. Cependant, cette adéquation risque de contenir des erreurs de reconnaissance même dans les meilleures conditions d’application. Ces erreurs de reconnaissance peuvent être liées au modèle de langage (le plus souvent à cause des mots hors-vocabulaire), au modèle de prononciation (prononciation non-définie pour un mot connu) ou au modèle acoustique (bruits inconnus, locuteurs trop différents). L’algorithme de reconnaissance affiche simplement le message décodé, mais il ne peut pas dire de lui même (de manière certaine) si le message contient des erreurs, ni où se trouvent ces erreurs.

Sachant que les systèmes de reconnaissance font assez souvent des erreurs, les chercheurs ont introduit diverses mesures pour donner une indication de la pertinence de la reconnaissance, connues sous le nom des “mesures de confiance” [JIANG 2005 ; RAZIK 2007]. Ces mesures sont calculées soit sur les unités reconnues (mots, phonèmes, ...), soit sur les phrases entières, en fonction de l’objectif de l’application. Les trois types de mesures de confiance les plus courantes sont celles fondées sur une combinaison des paramètres prédictifs [WESSEL et al. 1999 ; ZHANG et RUDNICKY 2001], sur le rapport de vraisemblance [ROSE et al. 1995 ; WEINTRAUB et al. 1997] ou sur la probabilité a posteriori [RUEBER 1997 ; KEMP, SCHAAF et al. 1997 ; WESSEL et al. 2001].

Les sources d’information utilisées pour la conception des paramètres prédictifs incluent les informations issus du décodage : les scores acoustiques par trame, les scores du modèle de langage, l’occurrence des mots parmi les N meilleures hypothèses, l’occurrence des mots parmi les hypothèses obtenues en variant le poids du modèle de langage, le nombre de solutions alternatives par arc dans le graphe de mots, etc.

Les mesures fondées sur le rapport de vraisemblance utilisent deux hypothèses : H_0 - le message est correctement reconnu et son modèle acoustique associé est le correct, H_1 - le message n’est pas correctement reconnu et son modèle acoustique associé n’est pas le bon. Les hypothèses alternatives peuvent être obtenues avec l’aide des “anti-modèles”

(appris sur des alignement incorrects, e.g. erreurs de reconnaissance sur un ensemble d'apprentissage).

Les mesures de confiance a posteriori des mots sont calculés avec la formule :

$$P(w|O) = \frac{P(O|w)P(w)}{P(O)} \cong \frac{P(O|w)P(w)}{\sum_{w'} P(O|w')P(w')}$$

La probabilité $P(w|O)$ désigne une bonne mesure de confiance, à condition que le produit entre la probabilité du modèle acoustique $P(O|w)$ et la probabilité du modèle de langage $P(w)$ soit bien normalisée par la probabilité acoustique $P(O)$. Le calcul de la probabilité acoustique $P(O)$ doit tenir compte de toutes les hypothèses (de mots / phonèmes / bruits / ...) possibles pouvant générer la séquence de paramètres acoustiques O , ce qui est impossible dans la pratique. Comme solutions alternatives pour calculer la probabilité acoustique, des chercheurs ont proposé une reconnaissance purement phonétique (avec un modèle acoustique, un modèle de langage et un lexique à base de phonèmes), ou l'utilisation de graphes de mots ou de la liste de N meilleures hypothèses (générés par le décodeur comme solutions alternatives), etc.

La mesure de confiance d'un mot calculée sur la liste de N meilleurs résultats est basée sur l'estimation de la probabilité $P(O)$ et sur la normalisation des probabilités a posteriori de toutes les phrases hypothèses contenant le mot recherché (dans la même position dans la phrase) par rapport à toutes les phrases hypothèses [WEINTRAUB et al. 1997]. La mesure de confiance d'un mot calculée sur le graphe de mots utilise les probabilités acoustiques et linguistiques des mots présents dans le graphe de mots avec l'algorithme *forward-backward* de [WESSEL et al. 2001] (qui tient compte des instants début et fin de chaque mot).

Les mesures de confiance a posteriori apprises sur les graphes de mots offrent généralement la meilleure performance [JIANG 2005].

Chapitre 4

Conclusions

Cette partie a débuté avec une présentation de l'évolution des systèmes de reconnaissance de la parole et de quelques uns de leur domaines d'application. Partant de la simple reconnaissance de 10 chiffres prononcés par un locuteur connu, la reconnaissance de la parole a beaucoup évolué et peut désormais reconnaître des milliers de mots prononcés par différents locuteurs et dans différents environnements. Cependant, sa performance n'est toujours pas parfaite. Les systèmes actuels ne peuvent pas tout reconnaître (toutes les langues, tous les dialectes, toutes les personnes, toutes les variations de la parole liées aux sexe, âge ou maladie, tous les bruits, tous les mots, tous les noms, ...). C'est pour cette raison que les applications courantes essayent de répondre à une seule problématique à la fois, en optimisant le système pour l'application visée. Les différentes aides étudiées pour les personnes sourdes ou malentendantes comprennent des travaux sur la reconnaissance de traits phonétiques pour aider la lecture labiale, la traduction son - langage des signes grâce à un avatar et l'affichage des sous-titres. Mais à l'heure actuelle il n'y a toujours pas de vraie solution pour eux.

Ensuite nous avons présenté le fonctionnement d'un système automatique de reconnaissance de la parole, en donnant plus des détails sur les techniques utilisées dans nos expériences (analyse acoustiques MFCC, modèles de langage n-grammes, modèles acoustiques HMM-GMM) et en mentionnant des autres techniques, notamment les techniques actuelles (à base de réseaux de neurones).

Plus brièvement, nous avons rappelé l'algorithme de décodage de la parole qui fournit la phrase la plus probable ayant été prononcée, et les métriques utilisés pour l'évaluation des hypothèses fournies par le décodeur. Enfin, nous avons mentionné différentes techniques de calcul des mesures de confiances utilisées pour évaluer la pertinence du message décodé.

Deuxième partie

Modélisation lexicale

5	État de l'art	39
5.1	Décodage phonétique	39
5.2	Modèles hybrides	40
5.3	Ajout de nouveaux mots	42
5.4	Nos travaux	46
6	Contexte expérimental	49
6.1	Données de parole	49
6.2	Données textuelles	50
6.3	Configuration	51
7	Décodage phonétique	53
7.1	Unités lexicales	53
7.2	Heuristiques de décodage	61
8	Modèles hybrides	63
8.1	Fabrication des modèles hybrides	64
8.2	Évaluation des modèles hybrides	65
8.3	Interpolation des modèles hybrides	72
9	Ajout de nouveaux mots	75
9.1	Approche	75
9.2	Expérimentations	77
10	Conclusions	83

Chapitre 5

État de l’art

Le premier défi du projet porte sur l’optimisation de la modélisation pour l’extraction d’informations lexicales. Nous nous intéressons à l’optimisation des heuristiques de décodage et du choix des unités lexicales (pour définir le lexique et le modèle de langage associé), en vue de faire face aux problématiques liées à la taille de modèles et à la diversité et à l’évolution de domaines d’application.

Ce chapitre présente l’état de l’art relatif au choix des unités lexicales pour le modèle de langage (considérées seules ou combinées) et à la possibilité d’ajuster le modèle de langage pour pouvoir reconnaître des mots a priori inconnus. Nos travaux sont ensuite positionnés par rapport aux objectifs du projet et à l’état de l’art.

Sommaire

5.1	Décodage phonétique	39
5.2	Modèles hybrides	40
5.3	Ajout de nouveaux mots	42
5.4	Nos travaux	46

5.1 Décodage phonétique

En complément de la section 2.2 qui traite les différents types de modèles de langage et les différentes méthodes d’estimation de probabilités entre les mots du vocabulaire, cette section s’intéresse aux différentes unités lexicales sur lesquelles un modèle de langage peut être appris.

Les modèles de langage phonétiques sont rarement utilisés pour la reconnaissance de la parole. Les liens entre les diverses unités phonétiques sont difficiles à modéliser avec un lexique si limité (moins de 40 phonèmes pour la langue française), peu importe la taille du corpus d’apprentissage. De plus, un affichage complet en phonèmes est dur à interpréter sans aucun indice sur les frontières des mots. Ils peuvent néanmoins être utilisés avec d’autres objectifs : pour identifier la langue d’une phrase [YAN et BARNARD 1995], pour identifier le locuteur [JIN et al. 2002], pour détecter les mots hors-vocabulaire [SZÖKE et al. 2008], etc.

La syllabe a été étudiée en tant qu’unité acoustique - pour la reconnaissance de la pa-

role continue avec un grand vocabulaire [CERF-DANON et al. 1989 ; WU et al. 1998 ; ZHANG et EDMONDSON 2002 ; TACHBELIE et al. 2012], généralement en combinaison avec des phonèmes dépendants du contexte [GANAPATHIRAJU et al. 2001 ; HÄMÄLÄINEN et al. 2005] ou en tant qu'unité acoustique et lexicale [LE BLOUCH et COLLEN 2006]. Dans [WU et al. 1998], la syllabe a été décrite comme une unité attrayante pour la reconnaissance grâce à sa plus grande stabilité, à son lien naturel entre l'acoustique et l'accès lexical et à sa capacité d'intégrer les informations prosodiques dans la reconnaissance. Dans [LE BLOUCH et COLLEN 2006], la coarticulation a été modélisée entre les phonèmes à l'intérieur de la syllabe, mais aucune modélisation dépendante du contexte n'a été prise en compte entre les syllabes, de plus le modèle de langage appliqué au niveau de la syllabe était un bigramme. Pour obtenir les syllabes, plusieurs approches peuvent être considérées : des heuristiques de découpage des chaînes de phonèmes [LE BLOUCH et COLLEN 2006], le principe de la sonorité [BARTLETT et al. 2009], des règles de syllabation [BIGI et al. 2010], etc.

Les modèles de langage à base de morphèmes (la plus petite composante linguistique d'un mot qui a un sens) sont utilisés avec succès pour la reconnaissance de la parole amharique, polonaise ou allemande (langues morphologiquement riches) [TACHBELIE et al. 2014 ; SHAIK et al. 2011b ; MOUSA et al. 2011].

Les modèles de langage basés sur les mots (aussi appelés des modèles grand vocabulaire) sont les plus performants et les plus utilisés [MÉRIALDO 1987 ; CERF-DANON et al. 1989 ; YOUNG 1996]. Avoir une quantité importante de mots dans le vocabulaire et dans le modèle de langage favorise la bonne reconnaissance de ceux-ci.

Cependant, tous les modèles de langage ont une limite ; ils sont incapable de reconnaître les mots qui n'appartiennent pas à leur vocabulaire (mots hors-vocabulaire). Compte tenu de la quantité limitée des données d'apprentissage, et aussi de la capacité mémoire et de la puissance de calcul limitées des systèmes de traitement (en particulier, pour des systèmes intégrés dans un dispositif portable), il est impossible de concevoir un système de reconnaissance qui couvre tous les mots, et encore moins tous les noms propres et toutes les abréviations.

5.2 Modèles hybrides

Une solution pour diminuer les erreurs liées aux mots hors vocabulaire vise à étendre les lexiques de mots avec des fragments de mots.

La méthode proposée dans [YAZGAN et SARACLAR 2004] utilise un modèle de langage hybride anglais qui combine des mots avec des unités de sous-mots, tels que les phonèmes ou les syllabes, dans le but de détecter les mots hors-vocabulaire. Leur modèle de langage hybride est appris sur un corpus combinant les deux types d'unités : les N mots les plus fréquents sont conservés tels quels, et les mots moins fréquents sont décomposés en phonèmes ou en syllabes. La séquence correspondante de phonèmes représente la prononciation du mot (par rapport aux variantes de prononciation définies dans le lexique). La séquence de syllabes est construite sur la séquence de phonèmes en suivant le principe de l'attaque maximale (*maximum onset principle*). Trois vocabulaires différents sont éva-

lués : parmi les 5K mots les plus fréquents, les premiers 2K mots sont conservés tels quels, et les autres sont décomposés en phonèmes ou en syllabes ; idem pour les vocabulaires de 10K et 20K mots les plus fréquents, les 5K premiers mots sont conservés tels quels, et les autres sont décomposés en phonèmes ou en syllabes. Une étude pour récupérer la bonne identité (orthographe des mots) avec la bonne prononciation des mots hors-vocabulaire est effectuée, mais seule une petite quantité de mots hors-vocabulaire est correctement trouvée.

Les vocabulaires ouverts ont été également étudiés dans [BISANI et NEY 2005], où les mots et des fragments de mots sont mélangés conjointement dans un modèle de langage hybride (anglais). Les fragments de mots sont des “graphones” $q = (g, \varphi)$, c’est-à-dire des ensembles d’une séquences de lettres g et une séquences de phonèmes φ (séquences ayant des longueurs éventuellement différentes). Trois vocabulaires différents sont évalués : les 5K mots les plus fréquents, les 20K mots les plus fréquents et les 64K mots les plus fréquents. Les modèles graphème-phonème sont appris séparément pour chaque vocabulaire avec un modèle trigramme, en utilisant des séquences de lettres et de phonèmes de longueurs variables (entre 2 et 6). Les graphones obtenus avec cette méthode sont ensuite ajoutés au vocabulaire : entre 1K et 4K graphones pour le vocabulaire de 5K mots, entre 1K et 15K graphones pour le vocabulaire de 20K mots, et entre 3K et 29K graphones pour le vocabulaire de 64K mots. Le modèle de langage hybride est appris sur un corpus combinant les deux types d’unités : les N mots les plus fréquents sont conservés tels quels, tous les autres mots étant remplacés par la séquence de graphones la plus probable. Une analyse de l’impact des mots hors-vocabulaire sur le taux d’erreur de reconnaissance de mots est effectuée, en utilisant les différents lexiques. Les résultats obtenus avec les modèles hybrides surpassent ceux des modèles classiques (basés uniquement sur des mots) : l’amélioration est plus importante quand il y a une grande quantité de mots hors-vocabulaire.

Dans [RASTROW et al. 2009b], les unités de sous-mots correspondent à des séquences de phonèmes de longueurs variables, déterminées automatiquement à partir de données (anglaises). Six vocabulaires différents sont évalués, en choisissant les {10K, 20K, 30K, 40K, 60K ou 84K} mots les plus fréquents. Le corpus d’apprentissage est converti en phonèmes en utilisant le lexique de prononciations associé à chaque vocabulaire (les mots hors-vocabulaire sont donc exclus). Ce corpus est utilisé pour apprendre un modèle de langage phonétique 5-gramme, qui va ensuite fournir les séquences de phonèmes de longueur variable (jusqu’à 5). Le modèle de langage hybride est appris sur un corpus combinant les deux types d’unités : les N mots les plus fréquents sont conservés tels quels, tous les autres mots étant remplacés par une suite des fragments (séquences de phonèmes). L’algorithme de recherche commence par affecter le fragment le plus long possible et continue de manière itérative à ajouter le plus long fragment suivant, jusqu’à ce que la prononciation complète du mot soit représentée par des unités de sous-mots (les séquences de phonèmes utilisées appartiennent au modèle de langage phonétique 5-gramme associé au lexique courant). Un ensemble de 20K fragments (séquences de phonèmes) est ajouté à tous les vocabulaires hybrides. Une telle extension fournit de meilleures correspondances acoustiques sur les parties hors-vocabulaire du signal de parole (comparé au modèles basés uniquement sur des mots), ce qui réduit le taux d’erreur phonétique. De

plus, les régions des mots hors-vocabulaire sont détectées en utilisant la probabilité postérieure des unités de sous-mots à l'intérieur des réseaux de confusion obtenus avec le modèle hybride [RASTROW et al. 2009a].

Des études plus récentes [SHAIK et al. 2011a] ont examiné la combinaison de plus de deux types d'unités lexicales (allemandes) dans le même vocabulaire et modèle de langage : des mots, des morphèmes (la plus petite composante linguistique d'un mot qui a un sens) ou des syllabes, et des graphones à base de morphèmes (un ensemble considérant une séquence de morphèmes avec une séquence de phonèmes) ou des graphones à base de syllabes (un ensemble considérant une séquence de syllabes avec une séquence de phonèmes). Deux lexiques considérant les trois unités lexicales sont évalués : le premier combinant 5K mots, 95K morphèmes et 200K graphones à base de morphèmes, et le deuxième - 10K mots, 90K syllabes et 200K graphones à base de syllabes. Le modèle de décomposition en morphèmes est appris avec l'outil *Morfessor* qui utilise le principe de la longueur de description minimale (*minimum description length, MDL*), sur une liste de mots ayant une fréquence d'au moins 5 occurrences. Les mots sont décomposés en syllabes avec l'outil *KombiKor* utilisant des règles phonologiques. Chaque modèle graphème-phonème est appris avec un modèle 3-gramme, en utilisant une longueur optimale de la séquence de lettres et de la séquence de phonèmes (qui minimise le taux d'erreur de phonèmes). Pour créer les graphones à base de morphèmes ou de syllabes, la séquence de lettres est convertie en morphèmes ou en syllabes (un alignement lettres-phonèmes permet de récupérer les séquences de phonèmes associées aux morphèmes ou aux syllabes). Le modèle de langage hybride est appris sur un corpus combinant les trois types d'unités : les N mots les plus fréquents sont conservés tels quels, les mots moins fréquents (dans un vocabulaire de 100K mots) sont remplacés par des morphèmes ou par des syllabes ; les mots hors-vocabulaire sont remplacés par des "graphones" (à base de morphèmes ou de syllabes). Les meilleurs résultats sont obtenus avec la combinaison de mots, morphèmes et "graphones" à base de morphèmes. Pour récupérer facilement les mots à partir des unités des sous-mots, un symbol "+" est attaché à la fin de chaque unité de sous-mots non-finale. Ainsi, environ 40% de mots hors-vocabulaire sont correctement identifiés.

5.3 Ajout de nouveaux mots

D'autres solutions peuvent être envisagées pour reconnaître des mots qui sont inconnus pour le système.

La solution la plus classique suggère une adaptation du modèle de langage [DEMORI et FEDERICO 1999 ; BELLEGARDA 2004] afin d'apprendre les probabilités des n -grammes associés aux nouveaux mots. Les trois techniques principales pour adapter un modèle de langage sont : l'interpolation, l'utilisation de contraintes et l'extraction de méta-données. Dans le cas de l'interpolation, un nouveau modèle de langage est appris sur un nouveau corpus (représentant les mots manquants ou un nouveau domaine d'application) et il est ensuite combiné avec le modèle initial. La solution de [LIU et al. 2008] propose une interpolation entre plusieurs modèles de langage avec des poids d'interpolation

dépendants du contexte, rendant ainsi possible l'adaptation d'un modèle de langage à une tâche particulière. Concernant l'utilisation de contraintes, divers paramètres peuvent être extraits à partir du nouveau corpus (un historique de mots, probabilités des 1-grammes, ...) et utilisés pour modifier les probabilités du modèle initial. Les informations liées à la thématique, à la sémantique ou à la syntaxe d'un nouveau corpus (méta-données) peuvent aussi servir pour l'adaptation du modèle initial. Cependant, le bon fonctionnement des techniques d'adaptation est directement lié à l'utilisation d'une grande quantité de nouvelles données (ces données ne sont pas toujours faciles à trouver).

Les fréquences de 2-grammes inconnus peuvent aussi être estimées sur les données disponibles sur internet [KELLER et LAPATA 2003].

Une autre approche implique l'utilisation des modèles de langage basés sur des classes [BROWN et al. 1992; SUHM et WAIBEL 1994] : les nouveaux mots sont simplement ajoutés dans une classe. Dans le passé, les scientifiques laissaient l'utilisateur choisir la meilleure classe pour le nouveau mot [ASADI et al. 1991], mais la classe peut aussi être choisie automatiquement, en se basant sur la similarité entre le nouveau mot et les mots de la classe. La similarité entre deux mots peut être estimée avec diverses méthodes.

Dans [PRAŽÁK et al. 2007], les mots sont associés à une classes par rapport à des étiquettes morphologiques (15 symboles représentant diverses informations sur les classes grammaticales, le genre, le nombre, le temps du verbe, le degré de comparaison, négation, etc). Les étiquettes sont attribuées automatiquement par un analyseur morphologique tchèque. Leur modèle contient 112K mots repartis en 1,5K classes (1,5K étiquettes morphologiques uniques).

L'approche de [NAPTALI et al. 2012] propose d'utiliser un modèle de langage basé sur des classes, pour lequel chaque mot du vocabulaire fait partie d'une classe singleton ; les mots hors-vocabulaire (mais présents dans le corpus d'apprentissage) sont associés à la classe de leurs mots similaires présents dans le vocabulaire (basé sur la mesure du cosinus de la similarité entre les vecteurs représentant les mots), et les autres mots n'ayant pas de données représentatives sont associés à la classe générale <unk>. Des documents représentant les mots hors-vocabulaire sont récupérés en ligne (100 pages web pour chaque nouveau mot) et une représentation matricielle de ces documents est conçue pour chaque nouveau mot, par rapport aux mots connus (les 20K mots les plus fréquents) et au nouveau mot courant. Deux types de représentations matricielles sont considérés. La première matrice $A = (n + 1) \times (m)$ contient $n + 1$ lignes (les n mots connus les plus fréquents et un seul nouveau mot) et m colonnes (le nombre de documents récupérés en ligne), dont les éléments $\{a_{ij}\}$ indiquent la fréquence d'occurrence du mot w_i dans le document d_j . La deuxième matrice $A = (n + 1) \times (n + 1)$ contient $n + 1$ lignes et $n + 1$ colonnes (les n mots connus les plus fréquents et un seul nouveau mot), dont les éléments $\{a_{ij}\}$ indiquent le nombre de fois que le mot w_i suit le mot w_j . Chaque mot w_k (connu ou nouveau) est ensuite représenté par un vecteur $w_k = A^T c_k$, où c_k est un vecteur discret ayant le k ième élément égal à 1 et les autres égaux à 0 (vecteur de dimension $n + 1$). La similarité entre un nouveau mot et les mots connus est ensuite calculée par le produit entre le cosinus de la similarité entre les vecteurs de mots et l'importance du mot connu dans le corpus d'apprentissage : $sim(w_i, w_{oov_j}) = \cos(w_i, w_{oov_j}) \text{idf}(w_i)$. Chaque nouveau mot est associé à la classe de son mot connu le plus similaire $C_{oov_j} = \text{Argmax}_{w_i \in IV} sim(w_i, w_{oov_j})$. Leur

approche dépasse la performance des modèles baseline, surtout lorsqu'un nouveau mot est associé à plusieurs classes.

D'autres méthodes permettent d'ajouter de nouveaux mots dans le modèle de langage sans réapprendre le modèle, en utilisant très peu de données associées aux nouveaux mots [ALLAUZEN et GAUVAIN 2005], ou même sans données associées aux nouveaux mots [MARTINS et al. 2008]. La méthode proposée dans [ALLAUZEN et GAUVAIN 2005] utilise un modèle de langage n-gramme basé sur des mots et sur des classes grammaticales, et l'ajout de nouveaux mots se fait sans modifier le modèle de langage baseline. Une liste de 20 classes grammaticales POS (les plus fréquentes, auxquelles sont ajoutés des discriminations singulier / pluriel) est définie à partir d'un sous-corpus du corpus d'apprentissage. Par rapport au corpus d'apprentissage complet et au vocabulaire de référence, les mots connus (dans le vocabulaire) sont utilisés tels quels, les mots inconnus (hors-vocabulaire) ayant une classe grammaticale fréquente (dans la liste de 20 classes sélectionnées) sont remplacés par leurs étiquettes POS, et les autres mots inconnus sont remplacés par l'étiquette générale <unk>. Une liste de nouveaux mots (qui ne sont pas connus par le système, mais qui doivent être reconnus) est définie à partir des méta-données associées aux fichiers audio, qui incluent la date et l'heure de l'enregistrement, des détails techniques, les noms des locuteurs et un résumé de l'émission. Cette liste comprend principalement des noms propres, des verbes conjugués et des substantifs. Le résumé est utilisé pour récupérer les classes grammaticales POS de nouveaux mots. Les nouveaux mots sont ensuite inclus dans le vocabulaire en tant que membres de leurs classes grammaticales. La probabilité d'un nouveau mot w étant donné un historique h est calculée par $P(w|h) = P(c_w|h)P(w|c_w)$, où c_w représente la classe grammaticale du mot w . Les fréquences d'occurrence de nouveaux mots dans le résumé sont les seules informations utilisées pour le calcul de la probabilité $P(w|c_w)$. Avec cette technique, 80% de nouveaux mots sont bien reconnus, et le taux d'erreur de mots diminue de 0.60% (par rapport au modèle baseline). L'approche de [MARTINS et al. 2008] propose d'utiliser un modèle de langage unigramme basé sur des classes grammaticales POS et des informations morpho-syntaxiques pour estimer les probabilités des 1-grammes des nouveaux mots ; ces probabilités sont ensuite introduites dans le modèle de langage n-gramme baseline. Une liste de 11 classes grammaticales POS est définie sur les mots du vocabulaire avec l'aide d'un outil morpho-syntaxique (qui attribuent plusieurs étiquettes aux mots, e.g. les diverses classes grammaticales, le genre, la forme singulière ou plurielle). Deux corpus textuels sont utilisés, les deux étant étiquetés avec leurs classes grammaticales POS (avec un outil morpho-syntaxique qui tient compte du contexte). Le premier corpus est utilisé pour apprendre un modèle de langage unigramme basé sur des classes et sert à calculer les probabilités $P(c_i)$ des classes grammaticales (avec la méthode de lissage modifiée de Kneser-Ney). Le deuxième corpus sert à calculer les probabilités $P(w|C_i) = \frac{N(w;c_i)}{N(c_i)}$ pour tous les mots w du corpus et pour toutes les classes grammaticales c_i (avec la méthode de lissage de Laplace). La probabilité unigramme des nouveaux mots w_0 est définie comme $P(w_0) = \sum_{c_i \in C(w_0)} P(w_0|c_i)P(c_i)$. Pour calculer la probabilité $P(w_0|c_i)$, la fréquence d'occurrence de nouveaux mots dans le contexte c_i ($N(w_0; c_i)$) est remplacée par la valeur maximale des fréquences d'occurrence de ses mots similaires ($\max_{w_s \in S} (N(w_s; c_i))$); deux mots sont similaires s'ils ont la même étiquette morpho-syntaxiques. Cette tech-

nique permet de reconnaître 78% de nouveaux mots et produit une réduction relative de 4% du taux d'erreur de mots (par rapport au modèle baseline).

Les séquences n-grammes de nouveaux mots peuvent également être définies à partir des séquences n-grammes des mots inconnus en considérant plusieurs classes des mots inconnus de différentes catégories morphosyntaxiques [OGER 2011]. Les nouveaux mots sont associés à une classe en fonction de leur étiquette morphosyntaxique. L'estimation de la probabilité d'un nouveau mot dans la classe peut se calculer par le rapport entre sa fréquence d'occurrence dans le corpus d'adaptation et le nombre de nouveaux mots ajoutés au vocabulaire initial. L'utilisation de plusieurs classes de mots inconnus modélise avec plus de précision le comportement des mots inconnus insérés dans le modèle de langage (par rapport à l'utilisation d'une seule classe de mots inconnus), mais elle s'appuie sur des données imprécises (les probabilités des nouveaux mots dans les classes et le probabilités des classes de mots).

Une solution alternative propose de chercher une liste des n-grammes représentant les nouveaux mots et de calculer les probabilités de ces nouveaux n-grammes en se basant sur les probabilités des n-grammes connus (dans un modèle de langage baseline) [LECORVÉ et al. 2011]. La recherche des n-grammes représentant les nouveaux mots est basée sur un principe de similarité entre mots : deux mots sont considérés comme étant similaires s'il existe une relation sémantique entre leurs lemmes et s'ils ont la même classe grammaticale. La relation sémantique entre deux lemmes est définie comme la mesure du cosinus entre leurs vecteurs de contexte. Un vecteur de contexte est calculé pour chaque lemme en glissant une fenêtre de 20 mots sur tout le texte (d'un corpus textuel) ; il contient les fréquences de mots vus avec ce lemme dans la même fenêtre. Les mots les plus similaires avec un nouveau mot sont ceux ayant les plus grandes valeurs de cosinus (seulement les dix premiers sont considérés). Ensuite, un score est calculé pour chaque n-gramme sur les nouveaux mots en prenant en compte la fréquence des n-grammes équivalents sur ses mots similaires (même séquence de mots, dont le nouveau mot est remplacé par un de ses mots similaires) et leur taux de similarité. Seulement les n-grammes ayant un score supérieur à la moyenne sont conservés. La dernière étape consiste à associer une probabilité aux nouveaux n-grammes, avant de les intégrer dans le modèle de langage. Un point de départ consiste à calculer pour chaque nouveau n-gramme la moyenne des probabilités de ses n-grammes équivalents. Ensuite, en utilisant la loi de Bayes, les probabilités conditionnelles sont calculées, les probabilités des historiques du modèle sont renormalisées et les poids back-off sont réévalués. Si la recherche des n-grammes pour un nouveau mot ne produit aucun résultat, le nouveau mot reçoit seulement une probabilité 1-gramme (ayant une valeur par défaut, 10^{-8}). Cette méthode atteint des performances similaires à celles obtenues avec un modèle de langage hybride combinant mots et classes grammaticales, mais elle offre une meilleure intégration sémantique des mots hors-vocabulaire.

Les mesures de similarité entre mots sont également étudiées dans la littérature avec d'autres objectifs (autre que les association mot-classe ou mot-mot pour ajouter des nouveaux mots dans un modèle de langage).

L'objectif de [DAGAN et al. 1999] est de prouver que les modèles basés sur les similarités entre mots dépassent la performance des modèles back-off. L'hypothèse de cette étude est la suivante : si un mot w'_1 est similaire avec un mot w_1 , alors w'_1 peut fournir des

informations sur la probabilité des paires inconnues comportant le mot w_1 . Leurs mesures de similarité basées sur la fréquence de co-occurrence entre mots sont calculées avec la divergence de Kullback-Leibler (KL), la divergence de Jensen-Shannon, la norme L1 et les probabilités de confusion sur les probabilités des différents bigrammes.

Les approches de sémantique distributionnelle [TURNNEY et PANTEL 2010 ; MIKOLOV et al. 2013] sont appliquées sur de nombreuses tâches du traitement automatique du langage naturel. Dans ces études, les mots sont considérés comme étant similaires s'ils apparaissent dans les mêmes contextes. Le mot est représenté par un vecteur des contextes d'usage, vecteur qui indique combien de fois chaque mot du vocabulaire apparaît dans le même contexte que lui (dans la même phrase ou dans la même fenêtre de N mots). Seulement les mots lexicaux qui ont une relation syntaxique avec le mot cible sont considérés comme contextes. Ces vecteurs considèrent donc les co-occurrences locales entre mots et n'utilisent aucune information d'ordre. La similarité entre deux mots est calculée comme la mesure du cosinus entre leurs vecteurs de contexte.

5.4 Nos travaux

La première étude a porté essentiellement sur la comparaison de différentes approches de décodage phonétique. Différentes unités lexicales ont été évaluées, comme les phonèmes et les mots, et nous avons proposé l'utilisation des syllabes ; le choix des unités lexicales définit le vocabulaire et influe sur le modèle de langage. Ces travaux ont fait ressortir l'intérêt des modèles syllabiques qui, pour un faible encombrement mémoire et un faible coût en calculs, donnaient de bonnes performances de décodage phonétique.

Cependant, des entretiens effectués en parallèle avec des personnes sourdes ont révélé l'intérêt d'une reconnaissance en mots [PIQUARD-KIPFFER et al. 2015]. En effet, cette solution est la plus simple à appréhender et, contrairement à la reconnaissance en syllabes, elle ne nécessite pas d'effort supplémentaire de la part du lecteur pour regrouper les différentes syllabes en mots porteurs de sens. Cependant, à cause de la taille finie du lexique, il faut pouvoir traiter les mots hors vocabulaire. Cela a amené à combiner des mots et des syllabes dans un seul modèle de langage, dit hybride. L'utilisation d'un tel modèle de langage hybride vise à assurer une reconnaissance correcte des mots les plus fréquents et à proposer des suites de syllabes pour les segments de parole correspondant à des mots hors vocabulaire. Il est alors possible d'ajuster la taille du modèle en choisissant une liste plus ou moins importante de mots fréquents, et l'ajout de syllabes devrait faciliter la compréhension des segments de parole hors vocabulaire, du moins plus facilement que de devoir interpréter une suite de petits mots dont l'une des variantes de prononciation correspond au segment de parole hors vocabulaire (ce qui est le cas le plus fréquent lorsque le lexique et le modèle de langage n'utilisent pas d'unités sous-lexicales).

Pour se positionner par rapport aux travaux précédents, il faut préciser que nous voulons maximiser la compréhension de la transcription résultante pour la communauté de personnes sourdes. Pour ce faire, nous avons cherché à modéliser les suites de sons, plutôt que les suites de lettres, avec une solution qui prenne en compte la prononciation ou non du e-muet ou des phonèmes de liaison, pour mieux représenter les prononciations

effectives. Ce qui explique notre choix final de fabriquer des modèles de langage hybrides basés sur la transcription de prononciations de parole (au niveau mots, et au niveau phonèmes en passant par un alignement forcé). Les mesures de confiance sont également évaluées en adéquation avec le mode d'affichage choisi : notre approche est de conserver les mots ayant une bonne probabilité d'être corrects (pour maximiser la compréhension du message) et de remplacer les autres avec une suite de phonèmes ou de syllabes. Pour essayer de mieux modéliser les syllabes à l'intérieur d'un modèle hybride, l'interpolation entre deux modèles hybrides a été également analysée.

Dans le contexte du projet, il est aussi nécessaire de pouvoir ajouter de nouveaux mots dans le modèle de langage, afin d'assurer une bonne reconnaissance des mots spécifiques à un certain domaine (par exemple mots utiles dans un magasin de bricolage, qui est le contexte applicatif choisi dans le projet pour la validation et l'expérimentation ; l'ajout de nouveaux mots permettra de tenir compte de l'arrivée de nouveaux produits ou services).

L'ajout de nouveaux mots doit pouvoir se faire sans ré-apprentissage ni adaptation du modèle de langage (qui sont des traitements qui nécessitent beaucoup de données). Nous avons donc proposé et évalué une nouvelle approche pour l'ajout de nouveaux mots qui est basée sur un principe de similarité entre mots. L'idée est de considérer que deux mots sont similaires s'ils ont des distributions similaires des voisins (des mots prédécesseurs et successeurs) ; ce qui veut dire que le remplacement d'un mot par un autre mot (qui lui est similaire) dans une phrase génère une nouvelle phrase correcte. Notre approche implique ainsi plusieurs étapes : utiliser quelques phrases exemples contenant le nouveau mot, chercher des mots connus similaires au nouveau mot (ayant des distributions similaires de voisins), puis transposer les probabilités n-grammes des mots similaires sur les nouveaux mots. Formellement, la similarité entre deux mots est calculée ici par la divergence entre les distributions des mots prédécesseurs et des mots successeurs. L'information d'ordre est importante dans la définition de la similarité entre mots, car nous allons utiliser les listes de mots similaires pour définir les entrées n-grammes associées aux nouveaux mots.

Chapitre 6

Contexte expérimental

Ce chapitre décrit les différentes données et outils utilisés lors de nos expériences.

Sommaire

6.1	Données de parole	49
6.2	Données textuelles	50
6.3	Configuration	51

6.1 Données de parole

Les corpus de parole utilisés dans nos expériences proviennent des campagnes d'évaluation ESTER2 [GALLIANO et al. 2009] et ETAPE [GRAVIER et al. 2012], et du projet EPAC [ESTÈVE et al. 2010]. Les données d'ESTER2 et d'EPAC sont des bulletins d'informations français recueillis auprès de diverses stations de radio, ils contiennent de la parole "préparée" et de la parole spontanée (par exemple les interviews). Une grande partie des données de parole est de qualité studio, et certaines parties sont de qualité téléphonique. Les données d'ETAPE correspondent à des débats, et ont été collectées auprès de diverses chaînes de radio et de télévision. Il s'agit essentiellement de parole spontanée.

Les durées d'enregistrements et de parole de ces différents corpus dans les ensembles d'apprentissage, de développement et de test sont indiquées dans le tableau 6.1.

	Corpus	# émissions	durée enreg.	durée parole transcrite
Apprentissage	ESTER2	292	195 h	182 h
	ETAPE	44	27 h	21 h
	EPAC	129	342 h	89 h
Développement	ESTER2	11	5 h	3 h
	ETAPE	15	9 h	7 h
Test	ESTER2	17	6 h	5 h
	ETAPE	15	9 h	7 h

TABLE 6.1 – Tailles des corpus de parole (apprentissage, développement et test)

Les données de parole de l'ensemble d'apprentissage d'ESTER2 et d'ETAPE, ainsi

que les données transcrites du corpus EPAC, ont été utilisées pour apprendre les modèles acoustiques. Les données d'apprentissage s'élèvent à environ 300 heures de parole et près de 4 millions de mots.

6.2 Données textuelles

Évaluation des modèles grand vocabulaire, phonétique, syllabique et hybride

Le modèle de langage grand vocabulaire a été fabriqué à partir d'une grande base de données textuelles : plus de 500 millions de mots correspondants à des journaux publiés entre 1987 et 2007 ; plusieurs millions de mots correspondants à des transcriptions d'émissions radiophoniques ; plus de 800 millions de mots du corpus français Gigaword [MENDONÇA et al. 2011] recueilli entre 1994 et 2008 ; et plus de 300 millions de mots correspondants à des données web recueillies en 2011 auprès de diverses sources web.

Les modèles de langage phonétique, syllabique et hybride (composés de mots et de syllabes) ont été appris sur les transcriptions manuelles des ensembles d'apprentissage des corpus d'ESTER2, d'ETAPE et d'EPAC (par la suite appelés 'corpus EEE'). Le tableau 6.2 précise le nombre total de mots et le nombre de mots uniques dans les transcriptions manuelles de l'ensemble d'apprentissage du corpus EEE. Les modèles de langage phonétique, syllabique et hybride (mots et syllabes) ont été appris sur ces corpus après alignement forcé. Les transcriptions phonétiques contiennent environ 12 millions de phonèmes et les transcriptions syllabiques - environ 6 millions de syllabes.

Corpus	#mots	#mots uniques
ESTER2-Train	2 228 172	50 558
ETAPE-Train	269 717	15 288
EPAC	1 109 524	33 187
EEE-Train	3 607 413	62 154

TABLE 6.2 – Données textuelles du corpus EEE-Train

Les variantes de prononciation des mots ont été extraites du lexique BDLEX [CALMÉS et PÉRENNOU 1998] et des lexiques internes disponibles. Pour les mots non présents dans ces lexiques, les variantes de prononciation ont été obtenues automatiquement en utilisant des convertisseurs graphème-phonème à base de JMM et CRF [ILLINA et al. 2011 ; JOUVET et al. 2012].

L'évaluation de performances de différents modèles de langage et de différents modèles acoustiques est effectuée sur les ensembles de développement des corpus ESTER2 et ETAPE.

Expériences sur l'ajout de nouveaux mots

Les expériences sur l'ajout de nouveaux mots nécessitent diverses données textuelles. La grande base de données textuelles mentionnée précédemment (1.7Md de mots, 74M de

phrases) sert à fabriquer le modèle de langage grand vocabulaire utilisé comme référence (modèle ORACLE) pour l'ajout de nouveaux mots. Une partie de cette base de données (1.3Md de mots, 58M de phrases) sert également à fabriquer le modèle de langage base-line. Compte tenu des différentes sources de données et des différentes tailles de données, les modèles de langage sont fabriqués par interpolation ; les poids d'interpolation optimales sont estimés sur l'ensemble de données de développement d'ETAPE.

Les corpus textuels Wikipedia [SAJOUS 2008] et GigaWord [MENDONÇA et al. 2011] sont utilisés pour extraire des phrases fournissant des exemples d'utilisation des nouveaux mots. Le corpus Wikipedia est également utilisé pour la recherche de mots similaires aux nouveaux mots.

L'évaluation de performances de différentes modèles de langage est effectuée sur l'ensemble de développement du corpus ESTER2.

6.3 Configuration

Annotation avec classes grammaticales

TreeTagger [SCHMID 1994] est utilisé pour annoter les phrases du corpus Wikipedia avec leurs classes grammaticales et leurs lemmes.

Fabrication de modèles de langage

La création des fichiers de compteurs et la fabrication de modèles de langage n-grammes sont effectuées avec les outils SRILM [STOLCKE 2002]. Ce sont des modèles trigrammes appris avec la méthode Chen-Goodman [CHEN et GOODMAN 1998] (i.e. méthode Kneser-Ney modifiée), qui stockent aussi les n-grammes d'ordre inférieure (1-grammes et 2-grammes). Les modèles de langage au format SRILM sont ensuite convertis au format Sphinx3 avec les outils Sphinx3 [PLACEWAY et al. 1996].

Fabrication de modèles acoustiques

Les modèles acoustiques HMM-GMM des phonèmes dépendantes du contexte sont fabriqués avec les outils Sphinx3 [PLACEWAY et al. 1996], en variant le nombre de séquences (2500, 5000 ou 7500) et le nombre de gaussiennes par densité (8, 16, 32 ou 64). Une adaptation à la parole des hommes et des femmes a été également considérée.

Décodage de la parole

Le décodage de la parole est réalisé avec les outils Sphinx3 [LEE et al. 1990b ; PLACEWAY et al. 1996] et PocketSphinx [HUGGINS-DAINES et al. 2006]. PocketSphinx est utilisé pour calculer les mesures de confiance sur les unités reconnues.

Ces outils ont été choisis par les partenaires du projet en raison de leur applicabilité en système embarqué. Ils apportent néanmoins des contraintes : l'utilisation des modèles de langage de type trigramme et l'impossibilité d'utiliser des modèles acoustiques SGMMs (*sub-space gaussian mixture models*).

Pour information, les outils développés précédemment au LORIA pour la transcription de parole dans le cadre des campagnes d'évaluation ESTER et ETAPE utilisent plusieurs passes de décodage, ce qui ne permet pas leur utilisation pour un traitement en temps réel.

Évaluation des systèmes de reconnaissance

Nos différents modèles de langage sont basés sur différentes unités lexicales. Aussi, pour pouvoir comparer leurs performances, toutes les unités reconnues par le décodeur sont décomposés en phonèmes (pour les mots - en fonction de la variante de prononciation choisie par le décodeur ; pour les syllabes - en fonction de sa description en phonèmes) et l'évaluation de performances se base sur le taux d'erreur phonétique (PER) :

$$PER = \frac{S + D + I}{N_{\text{phonèmes}}}$$

Le logiciel CoALT [FOHR et MELLA 2012] est utilisé pour l'analyse des taux d'erreur de phonèmes. Les fichiers comparés sont le fichier des hypothèses de reconnaissance .ctm (résultant du processus de décodage) avec le fichier de référence .stm. Le fichier CTM se compose d'une succession de phonèmes ayant des informations temporelles (temps début et temps fin). Le fichier STM (*segment time marked*) stocke l'annotation manuelle des signaux audio ; les enchaînements de phonèmes correspondants sont obtenus par alignement forcé.

Les modèles de langage basés uniquement sur des mots sont également évalués par rapport à leur taux d'erreur de mots (WER) :

$$WER = \frac{S + D + I}{N_{\text{mots}}}$$

Le logiciel 'asr-eval' (créé pour évaluer les performances de différents systèmes sur le corpus ETAPE [GRAVIER et al. 2012]) est utilisé pour l'analyse des taux d'erreur de mots. Dans ce cas, la comparaison entre le fichier d'hypothèse .ctm et le fichier de référence .stm est faite au niveau de mots.

L'évaluation des modèles hybride comprend en plus le calcul du taux de mots produits par le décodeur (dans la séquence de mots et de syllabes), du taux de mots correctement reconnus (par rapport à la transcription de référence), du taux de syllabes correctement reconnus (par rapport à l'alignement forcé de la transcription de référence) et du taux de mots hors-vocabulaire reconnus par des syllabes. Les mesures de confiance sur les mots et sur les syllabes sont également évaluées.

Poids modèle de langage

Les variantes du poids modèle langage évaluées dans le chapitre suivant sont : {5 ; 6 ; 7 ; 7,5 ; 8 ; 8,5 ; 9 ; 10}.

Chapitre 7

Décodage phonétique

Ce chapitre analyse les performances de différentes approches de décodage phonétique et propose l'utilisation d'unités lexicales syllabiques.

Cette partie du travail est publiée dans deux articles de conférence [OROSANU et JOUVET 2013a ; OROSANU et JOUVET 2013b].

Sommaire

7.1	Unités lexicales	53
7.2	Heuristiques de décodage	61

7.1 Unités lexicales

Les unités lexicales étudiées dans notre analyse sont : les phonèmes - la plus petite unité linguistique, les syllabes - les “blocs de construction” phonologiques des mots, et les mots - la plus grande unité linguistique et, en même temps, le plus petit élément linguistique qui comporte une vraie signification. Le choix des unités lexicales définit le vocabulaire et influe sur le modèle de langage.

7.1.1 Mots

Le modèle de langage grand vocabulaire basé sur 97 000 mots à été appris sur des données textuelles comprenant environ 1,7 milliard de mots. Il contient 97K 1-grammes, 43M 2-grammes et 79M 3-grammes (cf. le tableau A.1 en annexe).

Pour calculer le taux d'erreur phonétique (nécessaire aux comparaisons entre les divers modèles de langage), chaque mot est décomposé en une séquence de phonèmes, en fonction de la variante de prononciation choisie par le décodeur.

Les taux d'erreur phonétique obtenus avec différents poids du modèle de langage grand vocabulaire sur le corpus ESTER2 sont affichés dans la figure 7.1. La meilleure valeur pour le poids du modèle de langage est égale à 8.

Pour information, en ce qui concerne le taux d'erreur mot (WER), la meilleure valeur pour le poids du modèle de langage est égale à 9 (24,26% WER sur ESTER2, 29.65% WER sur ETAPE).




FIGURE 7.1 – Impact du poids du modèle de langage (lw) sur la performance du modèle de langage grand vocabulaire sur le corpus ESTER2

Le tableau 7.1 compare les performances de décodage phonétique obtenues sur les deux corpus audio ESTER2 et ETAPE, en utilisant un poids du modèle de langage égal à 8. Une différence de performance de 4% (en absolu) est observée entre le contexte de parole préparée (ESTER2) et le contexte de parole spontanée (ETAPE). Il y a un manque d’adéquation entre les données textuelles utilisées pour apprendre le modèle de langage et les discours spontanés : d’un coté les modèles de langage sont appris sur des données textuelles correctes pour assurer la plus grande cohérence entre les mots reconnus par le système, et de l’autre coté une parole spontanée inclut des hésitations, répétitions, manque ou perte de cohérence.

Corpus	PER	Ins	Del	Sub
ESTER2	12,80%	2,40%	4,84%	5,56%
ETAPE	16,78%	2,57%	7,02%	7,19%

TABLE 7.1 – Taux d’erreur phonétique (PER) obtenus avec le modèle de langage grand vocabulaire (basé sur des mots)

Le modèle de langage grand vocabulaire est utilisé dans cette analyse comme la référence d’une performance maximale. Un tel modèle ne peut pas être utilisé dans un système embarqué en raison de sa taille trop importante, mais il établit la performance cible.

7.1.2 Phonèmes

Un modèle de langage phonétique a été appris à partir des transcriptions phonétiques des ensembles d’apprentissage des corpus ESTER2, ETAPE et EPAC (corpus EEE). Les transcriptions phonétiques sont obtenues par alignement forcé entre les sources audio et les transcriptions manuelles correspondantes (en mots). L’alignement forcé sélectionne pour chaque mot la variante de prononciation qui correspond le mieux au signal (respectant ainsi la réalisation par le locuteur des événements français de liaison et réduction), et identifie les segments temporels correspondant à chaque mot (et à chaque phonème) présent dans la transcription manuelle de référence. La liste des phonèmes français est présentée dans le tableau B.1 en annexe.

Le modèle de langage résultant contient 40 1-grammes, 1 343 2-grammes et 29 978 3-grammes (cf. le tableau A.1 en annexe).

Les taux d'erreur phonétique obtenus avec différents poids du modèle de langage phonétique sur le corpus ESTER2 sont affichés dans la figure 7.2. La meilleure valeur pour le poids du modèle de langage est égale à 5.




FIGURE 7.2 – Impact du poids du modèle de langage (lw) sur la performance du modèle de langage phonétique sur le corpus ESTER2

Le tableau 7.2 compare les performances du décodage phonétique obtenues sur les deux corpus audio ESTER2 et ETAPE, en utilisant un poids du modèle de langage égal à 5. La différence de performance entre le contexte de parole préparée (ESTER2) et le contexte de parole spontanée (ETAPE) est de 1,5%.

Corpus	PER	Ins	Del	Sub
ESTER2	32,06%	3,06%	10,30%	18,70%
ETAPE	33,56%	2,90%	12,17%	18,50%

TABLE 7.2 – Taux d'erreur phonétique (PER) obtenus avec le modèle de langage basé sur phonèmes

L'utilisation de ce type d'unité lexicale minimise la taille du vocabulaire (moins de 40 unités phonétiques pour la langue française) et donc la taille du modèle de langage. Ce type de modèle pourrait être utilisé dans un système embarqué, mais malheureusement, il n'offre pas des bonnes performances.

7.1.3 Syllabes

La syllabe est une unité lexicale plus grande que le phonème, composée de phonèmes et qui modélise la manière de prononcer les mots.

Pour obtenir une liste de syllabes, des règles de syllabation ont été appliquées sur les suites de phonèmes résultant de l'alignement forcé du corpus d'apprentissage EEE, respectant ainsi les prononciations réelles (qui permettent de prendre en compte la prononciation ou non du e-muet, les liaisons et les réductions de manière réaliste).

La syllabation employée repose sur les règles de syllabation décrites dans [BIGI et al. 2010] qui précisent qu'une syllabe contient une seule voyelle et qu'une pause désigne

la frontière d’une syllabe. Les règles sont associées à différentes séquences de classes phonétiques (séquences commençant et se terminant par une voyelle) et définissent la position de la frontière entre syllabes. L’application de ces règles sur une suite de phonèmes permet d’obtenir une suite de syllabes.

Une classe phonétique contient des sons qui partagent au moins une caractéristique phonétique. Généralement, les phonèmes sont répartis dans les classes suivantes : voyelles, semi-voyelles, liquides, nasales, occlusives, affriquées et fricatives [LADEFOGED et MADIESON 1996]. Dans l’approche mise en œuvre, seulement 5 classes sont utilisés : voyelles (V), semi-voyelles (G), liquides (L), obstruents (O) et bruits/silences (#).

Type de règle	Séquence de phonèmes	Position de coupure	Séquence de syllabes
GENRULE	VV	0	V V
GENRULE	VXV	0	V XV
GENRULE	VXXV	1	VX XV
EXCRULE	VGGV	0	V GGV

TABLE 7.3 – Quelques exemples des règles de syllabation

Le tableau 7.3 donne quelques exemples de règles de syllabation (plus de détails sur l’outil de syllabation sont disponibles dans l’annexe C). Dans les règles générales (GENRULE) la lettre V indique un phonème appartenant à la classe phonétique de voyelles et la lettre X indique un phonème appartenant à n’importe quelle autre classe. Dans les règles des exceptions (EXCRULE) la position de coupure dépend aussi de la classe phonétique des non-voyelles. Si une séquence de phonèmes correspond à une règle d’exception, c’est celle ci qui est appliquée et non la règle générale.




FIGURE 7.3 – Exemple de syllabation

Prenons l’exemple donné dans la figure 7.3. La séquence de mots “ce qui c’est passé c’est que” est décomposée en phonèmes par alignement forcé. La séquence des phonèmes correspondant à la prononciation des mots, “s k i s e p a s e s e k”, est ensuite annotée

avec ses classes phonétiques “O O V O V O V O V O V O”. Pour déterminer les règles de syllabation à appliquer, les séquences qui commencent et se terminent par une voyelles sont identifiées. Cet exemple contient seulement des séquences de type “V O V”. En l’absence d’une règle d’exception concernant une occlusion entourée par des voyelles (“V O V”), la règle générale “VXV \rightarrow 0 \rightarrow V XV” est appliquée. La séquence de syllabes résultante est “_s_k_i _s_e _p_a _s_e _s_e_k”. La notation des syllabes repose sur des tirets bas entre les phonèmes composants ; un tiret bas est aussi utilisé comme préfixe pour différencier les mots de syllabes (comme par exemple le mot ‘a’ et la syllabe ‘_a’).

Cette approche est facile à utiliser. Cependant, elle pose quelques problèmes.

Un premier problème est lié aux segments de silence ou de bruit reconnus par le décodeur. Selon les règles de syllabation, un segment de non parole (silence ou bruit) désigne la frontière d’une syllabe. En conséquence, les silences/bruits divisent la séquence de phonèmes en plusieurs sous-séquences de phonèmes (entourées par des silences ou des bruits). Il peut arriver que le décodeur reconnaisse un petit mot entre deux silences et que la prononciation de ce petit mot corresponde à une consonne (par exemple ‘ce \rightarrow s’). En conséquence, ce mot isolé va être considéré (à tort) comme une syllabe, alors qu’il ne contient pas de voyelle. Pour résoudre ce problème, les séquences sans voyelles ne sont pas incluses dans le lexique des syllabes et sont traitées comme des unités inconnues <unk> par le modèle de langage.

Un deuxième problème est lié à l’absence de voyelles. En regardant l’exemple précédent (figure 7.3) de plus près, nous pouvons remarquer que certains phonèmes manquent dans la transcription phonétique, et plus précisément, certaines voyelles (e-muets), en raison d’une vitesse d’élocution trop élevée ou d’une erreur de l’alignement forcé. C’est le cas du mot ‘ce’ - qui n’est représenté que par la consonne ‘s’, et du mot ‘que’ - qui n’est représenté que par la consonne ‘k’. Étant donné que les règles de syllabation sont principalement basées sur la position des voyelles, et qu’il y a des voyelles manquantes dans la transcription phonétique, la séquence de syllabes résultante présente quelques “anomalies”. La syllabe ‘_s_k_i’ devrait normalement être séparée en deux syllabes ‘_s_ə’ et ‘_k_i’, et pareil pour la syllabe ‘_s_e_k’ - ‘_s_e’ et ‘_k_ə’. En conséquence, en appliquant les règles de syllabation, nous pouvons obtenir non seulement des syllabes, mais aussi des pseudo-syllabes, qui peuvent être définies comme des groupes de phonèmes qui ne devraient pas appartenir à une seule syllabe. Dans nos expériences, ces pseudo-syllabes atteignent des longueurs supérieures à 6 phonèmes.

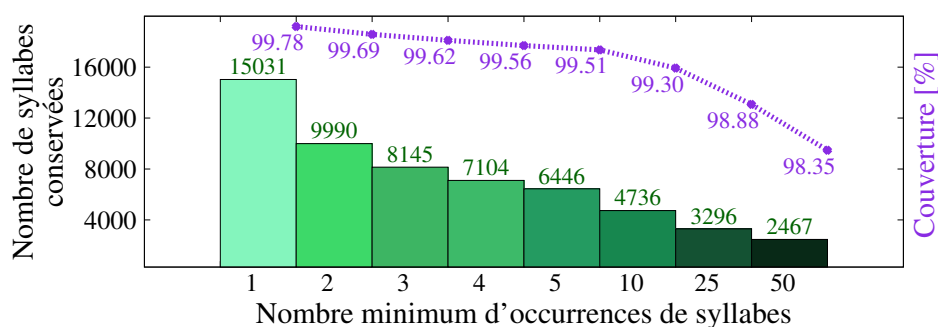


FIGURE 7.4 – Nombre de syllabes par rapport à leur fréquence d’occurrence

Pour réduire le nombre de ces pseudo-syllabes, nous avons choisi de filtrer les syllabes par rapport à leur nombre d’occurrences, et de ne conserver que les plus fréquentes. Dans les expériences, les syllabes vues au moins {1, 2, 3, 4, 5, 10, 25 ou 50} fois dans le corpus d’apprentissage sont conservées et les autres sont ignorées.

Le nombre de syllabes et la couverture obtenue en fonction du seuil sur le nombre minimum d’occurrences de syllabes sont affichés dans la figure 7.4. Le nombre de syllabes conservées varie entre 15 000 et 2 000 syllabes, avec une couverture de 99,78% à 98,35% des occurrences. Les syllabes qui ont été vues moins de 3 fois dans le corpus d’apprentissage représentent presque la moitié du nombre total de syllabes différentes (46%), mais elles ont un faible impact sur la couverture de syllabes (0,16%). En les ignorant, nous pouvons conserver un nombre restreint de syllabes (8 100 syllabes) tout en assurant une bonne couverture (99,62% des occurrences).




FIGURE 7.5 – Impact du poids du modèle de langage (lw) sur la performance du modèle de langage syllabique ‘min3occ’ sur le corpus ESTER2

Les taux d’erreur phonétique obtenus avec différents poids du modèle de langage syllabique basé sur les syllabes qui ont une fréquence d’au moins 3 occurrences (‘min3occ’) sur le corpus ESTER2 sont affichés dans la figure 7.5. La meilleure valeur pour le poids du modèle de langage est égale à 7.

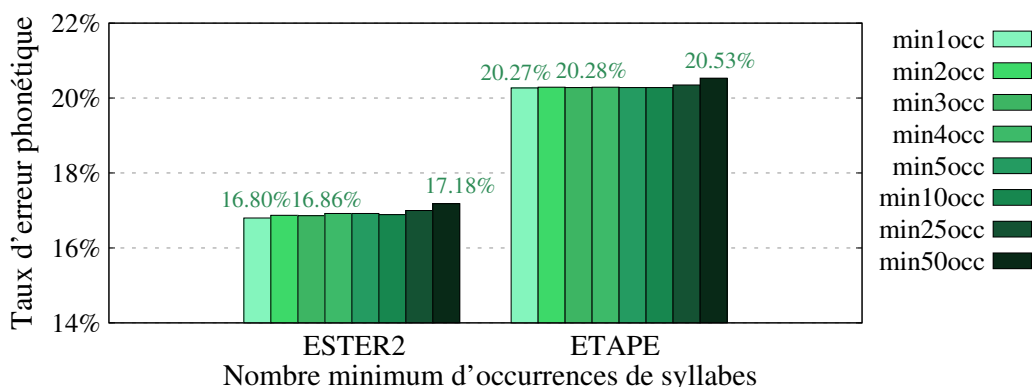


FIGURE 7.6 – Taux d’erreur phonétique obtenus avec les modèles de langage syllabiques sur les corpus ESTER2 et ETAPE

Nous avons ensuite analysé les taux d’erreur phonétique obtenus avec les différents modèles de langage syllabiques sur les corpus ESTER2 et ETAPE, en utilisant un poids

du modèle de langage égal à 7 (cf. Fig. 7.6). La performance du modèle de langage syllabique semble peu sensible au nombre de syllabes dans le lexique : il y a une différence de performance de seulement 0,33% entre le modèle de langage comprenant toutes les syllabes ('min1occ') et le modèle de langage comprenant les syllabes ayant une fréquence de minimum 50 occurrences ('min50occ'). La différence de performance entre le contexte de parole préparée (ESTER2) et le contexte de parole spontanée (ETAPE) est de 3,5%.

L'utilisation de ce type d'unité lexicale conduit à une taille raisonnable pour le lexique (8 100 syllabes vues au moins 3 fois) et pour le modèle de langage. Ce type de modèle peut être utilisé dans un système embarqué, tout en offrant de bonnes performances de décodage phonétique (~17% PER).

7.1.4 Comparaison des 3 unités lexicales

L'impact des modèles de langage et des choix de lexique a été étudié en vue d'établir le meilleur compromis pour une solution embarquée.

Modèle de langage	meilleur poids
ML=phonèmes	lw=5
ML=syllabes	lw=7
ML=mots	lw=8

TABLE 7.4 – Valeur optimale du poids de modèle de langage pour les 3 unités lexicales sur le corpus ESTER2

Le poids de modèle de langage qui minimise le taux d'erreur phonétique pour chaque type d'unité lexicale est rappelé dans le tableau 7.4. La valeur optimale du poids du modèle augmente avec la taille des unités lexicales : $lw = 5$ pour le modèle phonétique, $lw = 7$ pour le modèle syllabique 'min3occ' et $lw = 8$ pour le modèle grand vocabulaire. Ces valeurs indiquent l'importance du modèle de langage par rapport au modèle acoustique : le système privilégie les modèles de langage seulement quand ils sont détaillés.

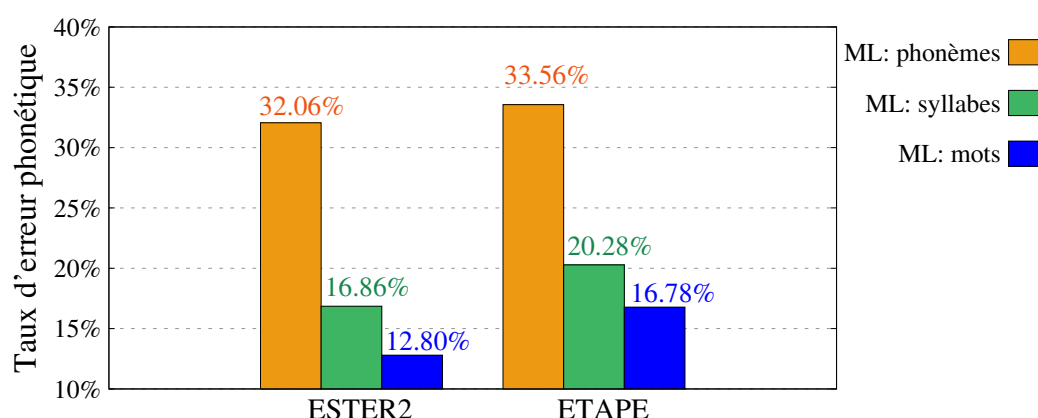


FIGURE 7.7 – Comparaison des taux d'erreur phonétique obtenus avec les 3 unités lexicales

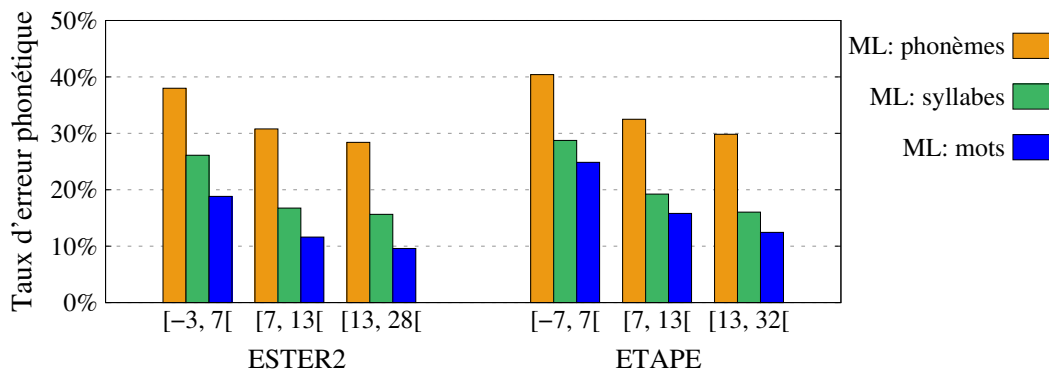
Les taux d'erreur de reconnaissance (mesurés sur les phonèmes) obtenus sur les données de développement des corpus ESTER2 et ETAPE sont présentés dans la figure 7.7.

Le taux d'erreur phonétique obtenu avec le modèle de langage syllabique (qui utilise les syllabes vues au moins trois fois dans le corpus d'apprentissage) n'est que de 4% plus mauvais (en valeur absolue) que le taux d'erreur obtenu avec le système de reconnaissance grand vocabulaire, et bien meilleur que le taux d'erreur obtenu avec le modèle de langage phonétique.


Une analyse détaillée des performances de reconnaissance en fonction du rapport signal-à-bruit et de la vitesse d'élocution a également été effectuée. Les valeurs de rapport signal-à-bruit ont été obtenues à partir des valeurs moyennes des coefficients MFCC C0 calculés (par l'outil *sphinx_fe*) sur les voyelles et sur les zones de non-parole (silence ou bruit), converties ensuite en dB (cf. eq. 7.1). La vitesse d'élocution est définie par le nombre de voyelles par seconde (ce qui correspond aussi au nombre de syllabes par seconde). Les intervalles de rapport signal-à-bruit et les intervalles de vitesse d'élocution ont été découpés de manière arbitraire afin d'obtenir des sous-ensembles de données des tailles équivalentes.

$$SNR_{dB} = 10 \log_{10} \frac{P_{signal}}{P_{bruit}} \cong 10 \left(\frac{\ln(\bar{C}_{0\text{voyelle}})}{\ln(10)} - \frac{\ln(\bar{C}_{0\text{bruit}})}{\ln(10)} \right) \quad (7.1)$$

Les différentes unités lexicales ont des comportement similaires : la performance de reconnaissance s'améliore (le taux d'erreur baisse) avec l'augmentation du rapport signal-à-bruit et avec la diminution de la vitesse d'élocution (cf. Fig. 7.8).



(a) Rapport signal-à-bruit [dB]



(b) Vitesse d'élocution [#syllables/seconde]

FIGURE 7.8 – Taux d'erreur phonétique obtenus sur les corpus ESTER2 et ETAPE, en fonction du rapport signal-à-bruit (a) et de la vitesse d'élocution (b)

Les performances obtenues sur le corpus ETAPE avec le modèle de langage grand vocabulaire par rapport au différents intervalles de rapports signal-à-bruit et de vitesse d'élocution sont présentées dans le tableau 7.5. Des écarts importants de performance sont observés entre les conditions les plus favorables (signal peu bruité, i.e. rapport signal-à-bruit élevé, et vitesse d'élocution basse) et les conditions les moins favorables (signal bruité, et vitesse d'élocution élevée).

		Vitesse d'élocution		
		[2, 5[[5, 6[[6, 25[
Rapport signal-à-bruit	[-3, 7[14,49	17,89	25,97
	[7, 13[12,76	13,05	17,39
	[13, 28[8,89	10,23	15,37

TABLE 7.5 – Taux d'erreur phonétique obtenus avec les modèles de langage grand vocabulaire sur les corpus ETAPE en fonction du rapport signal-à-bruit et de la vitesse d'élocution

7.2 Heuristiques de décodage

Une analyse complémentaire a été menée pour évaluer l'impact de la taille des modèles acoustiques sur les performances de reconnaissance.

Comme indiqué précédemment (section 2.4), les deux principaux paramètres qui influent sur la taille globale du modèle acoustique sont le nombre total de sénones (le nombre de densités de probabilité partagées entre les modèles contextuels des sons), et le nombre de gaussiennes par densité.

Les modèles obtenus en modifiant ces paramètres sont plus ou moins détaillés. Un modèle peu détaillé (peu de sénones, peu de gaussiennes par densité) occupera moins de place en mémoire, mais sera peu performant. L'augmentation du nombre de gaussiennes par densité, et du nombre de sénones permet d'améliorer la qualité de la modélisation, et donc les performances de reconnaissance, mais le modèle prendra plus de place en mémoire, et coutera aussi plus cher en CPU pour le décodage.

		#sénones		
		2 500 sen	5 000 sen	7 500 sen
#gaussiennes	8 g	20 000 [6 Mo]	40 000 [13 Mo]	60 000 [19 Mo]
	16 g	40 000 [13 Mo]	80 000 [25 Mo]	120 000 [37 Mo]
	32 g	80 000 [26 Mo]	160 000 [50 Mo]	240 000 [74 Mo]
	64 g	160 000 [51 Mo]	320 000 [100 Mo]	480 000 [148 Mo]
	64 g (H/F)	320 000 [102 Mo]	640 000 [200 Mo]	960 000 [296 Mo]

TABLE 7.6 – Taille des modèles acoustique

Plusieurs modèles acoustiques ont été évalués, en considérant différents nombres de sénones (2500, 5000 ou 7500) et différents nombres de gaussiennes par densité (8, 16, 32 ou 64). Leur nombre total de paramètres et leur taille sont indiqués dans le tableau 7.6.

Le modèle ‘64g(H/F)’ représente le modèle acoustique avec 64 gaussiennes adaptées à la parole des hommes (H) et autant à la parole des femmes (F).

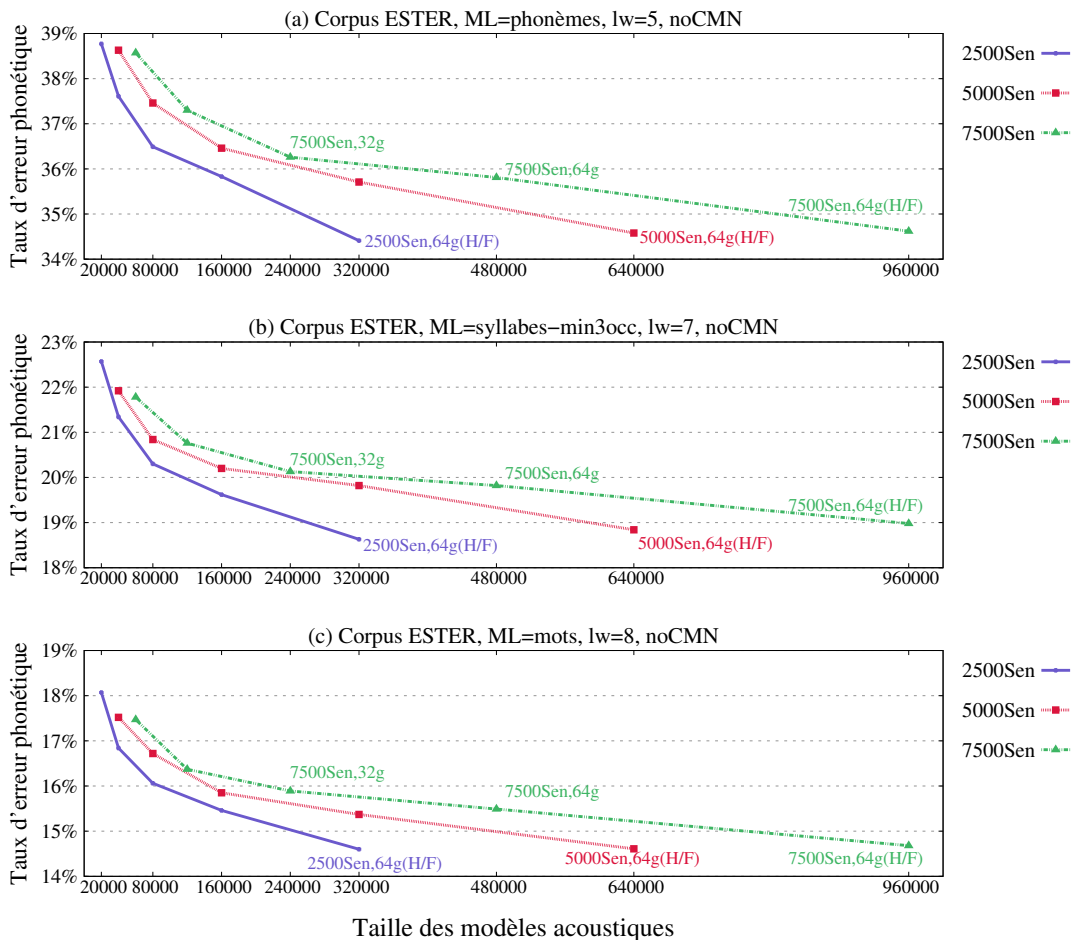


FIGURE 7.9 – Taux d’erreur phonétique sur le corpus ESTER2 obtenus avec différentes tailles de modèles acoustiques (tailles exprimées en nombre total de gaussiennes), en utilisant un modèle de langage phonétique (a), syllabique (b) ou grand vocabulaire (c)

La figure 7.9 montre les résultats obtenus en décodage phonétique sur le corpus ESTER2 en considérant les modèles de langage phonétique, syllabique et grand vocabulaire. L’axe horizontale indique le nombre total des paramètres des différents modèles acoustiques ayant entre 20K gaussiennes (8 gaussiennes par densité, 2500 états partagés) et 960K gaussiennes (64 gaussiennes par densité, 7500 états partagés, adaptation homme/femme). Les résultats montrent qu’un nombre important des gaussiennes par densité est plus important qu’un nombre élevé de sénones. Les résultats sont similaires pour tous les 3 unités lexicales.

De nombreux critères viennent aussi impacter les performances de reconnaissance et le temps CPU nécessaire pour le décodage. Ils sont liés aux heuristiques de l’algorithme de décodage. Plus les heuristiques sont restreintes, moins le décodeur explore de solutions possibles ; en conséquence cela coûte moins cher en calcul, mais c’est au détriment du taux d’erreur. Il est aussi important de souligner que le temps de calcul fluctue d’un énoncé à un autre. Le temps de réponse a tendance à être plus important lorsque l’on traite un signal de mauvaise qualité.

Chapitre 8

Modèles hybrides

Dans le projet, des entretiens effectués avec des personnes sourdes ont révélé l'intérêt d'une reconnaissance en mots [PIQUARD-KIPFFER et al. 2015]. En effet, cette solution est la plus simple à appréhender et, contrairement à la reconnaissance en syllabes, elle ne nécessite pas d'effort supplémentaire de la part du lecteur pour regrouper les différentes syllabes en mots porteurs de sens. Cependant, le choix d'un modèle de langage à base des mots ne résout pas tous les problèmes. L'incapacité de concevoir un système qui couvre tous les mots (taille fini du lexique) et qui ne soit pas contraint par les ressources disponibles, nous a amené à proposer et développer une approche combinant des mots et des syllabes dans un seul modèle de langage, dit hybride. Le choix des syllabes résulte de leurs bonnes performances en décodage phonétique (cf. chapitre précédent) pour une taille limitée des modèles associés. Le nombre de mots peut-être ajusté en fonction des ressources disponibles.

L'utilisation d'un tel modèle de langage hybride vise à assurer une reconnaissance correcte des mots les plus fréquents et à proposer des suites de syllabes pour les segments de parole correspondant à des mots hors vocabulaire. Les syllabes devraient faciliter la compréhension des segments de parole hors vocabulaire, du moins plus facilement que de devoir interpréter une suite de petits mots dont l'une des variantes de prononciation correspond au segment de parole hors vocabulaire (ce qui est le cas le plus fréquent lorsque le lexique et le modèle de langage n'utilisent pas d'unités sous-lexicales).

En conséquence, ce chapitre analyse l'intérêt des modèles de langage hybrides pour transcrire de la parole.

Cette partie du travail est publiée dans deux articles de conférence [OROSANU et JOUVET 2014a ; OROSANU et JOUVET 2014b].

Sommaire

8.1	Fabrication des modèles hybrides	64
8.2	Évaluation des modèles hybrides	65
8.3	Interpolation des modèles hybrides	72

8.1 Fabrication des modèles hybrides

La fabrication d'un modèle de langage hybride, combinant mots et syllabes, implique de constituer un corpus d'apprentissage qui repose sur ces deux unités lexicales. Pour ce faire, le vocabulaire est défini en sélectionnant les mots les plus fréquents, i.e. les mots qui apparaissent au moins θ fois dans le corpus d'apprentissage ; puis les mots hors vocabulaire sont décomposés en syllabes ; et les syllabes correspondantes sont alors ajoutées au lexique.

Un alignement forcé est appliqué sur les données d'apprentissage EEE, afin de déterminer quelle variante de prononciation a été effectivement utilisée pour chaque mot prononcé (fréquent ou pas). Ensuite, les mots peu fréquents (non sélectionnés par rapport au seuil choisi) sont remplacés par leur variante de prononciation résultant de l'alignement forcé. Enfin, les séquences de phonèmes ainsi obtenues, correspondant aux segments de parole entre les mots sélectionnés, sont traitées par l'outil de syllabation décrit dans le chapitre précédent.

Prenons l'exemple donné dans la figure 8.1. La phrase "une femme a été blessée" contient 4 mots fréquents {une, femme, a, été} et un seul mot non-fréquent {blessée}. Le mot "blessée" est remplacé par sa prononciation "b l e s e" (variante résultante de l'alignement forcé), qui est ensuite découpée en deux syllabes "_b_l_e" et "_s_e". La séquence finale de mots et syllabes est alors "une femme a été _b_l_e _s_e".

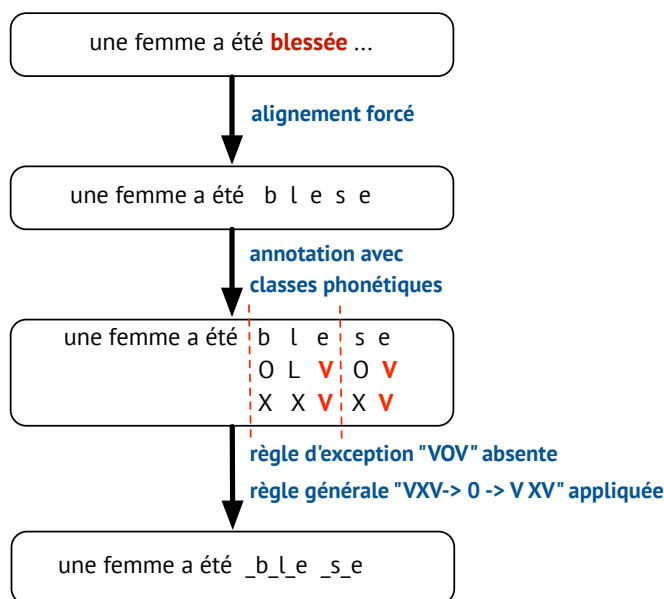


FIGURE 8.1 – Préparation des données pour la fabrication des modèles de langage hybrides

Différents seuils minimaux sur la fréquence d'occurrence des mots ont été considérés : $\theta \in \{3, 5, 10, 25, 50, 100, 300\}$. Chaque choix de seuil entraîne la création d'une transcription différente du corpus d'apprentissage (avec un nombre différent de mots et de syllabes), et conduit à un lexique et un modèle de langage correspondant. Pour limiter la taille des modèles et éviter de conserver trop de pseudo-syllabes non pertinentes (cf.

Sec. 7.1.3), seules les syllabes observées au moins trois fois dans le corpus d'apprentissage sont conservées dans les lexiques et dans les modèles de langage.

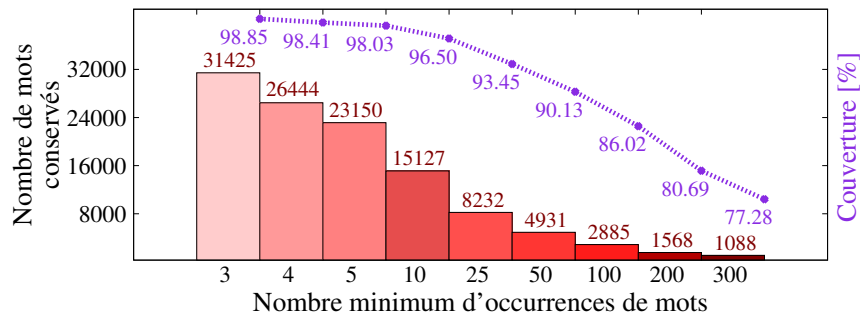


FIGURE 8.2 – Nombre et couverture des mots dans les modèles de langage hybrides

Le nombre de mots et la couverture, résultant de l'application de différents seuils sur le nombre minimum d'occurrences de mots, sont présentés dans la figure 8.2. En sélectionnant les 31 000 mots les plus fréquents du corpus d'apprentissage, près de 99% des occurrences de mots du corpus sont couvertes. En ne sélectionnant que les 5 000 mots les plus fréquents, le taux de couverture est encore supérieur à 90%.




FIGURE 8.3 – Nombre de syllabes utilisées dans les modèles de langage hybrides

La figure 8.3 affiche le nombre de syllabes nécessaires pour représenter les prononciations des mots non sélectionnés dans le lexique en fonction du seuil sur le nombre minimum d'occurrences de mots. En fonction de la liste des mots sélectionnés, 2 à 6 000 syllabes sont nécessaires.

Ces différentes sélections conduisent à des lexiques hybrides de 33 000 à 7 000 entrées (mots plus syllabes). Les modèles de langage associés comportent environ 1,8 millions de 3-grammes, pour une taille totale de 11 à 14 Mo (cf. le tableau A.2 en annexe).

8.2 Évaluation des modèles hybrides

L'évaluation des modèles hybrides a comme objectif de déterminer si la combinaison de mots et de syllabes conduit néanmoins à un bon taux de reconnaissance des mots (ce qui est important pour les personnes sourdes). Nous nous intéressons également aux taux de mots correctement reconnus (par rapport à la transcription de référence), aux taux de syllabes correctement reconnus (par rapport à l'alignement forcé de la transcription de

référence) et aux taux de mots hors-vocabulaire reconnus par des syllabes. Nous étudions la pertinence des mesures de confiance pour identifier les mots correctement reconnus.

8.2.1 Taux d’erreur phonétique

La première évaluation porte sur les taux d’erreur phonétique obtenus avec les différents modèles de langage hybrides ; ces taux sont affichés dans la figure 8.4. La performance du modèle de langage hybride dépend du nombre de mots conservés dans le lexique : il y a une différence de performance d’environ 1,5% entre le modèle de langage comprenant les mots vus au moins 3 fois (‘min3occ’) et le modèle de langage comprenant les mots ayant au moins 300 occurrences (‘min300occ’). La différence de performance entre le contexte de parole préparée (ESTER2) et le contexte de parole spontanée (ETAPE) est de 3,7%.

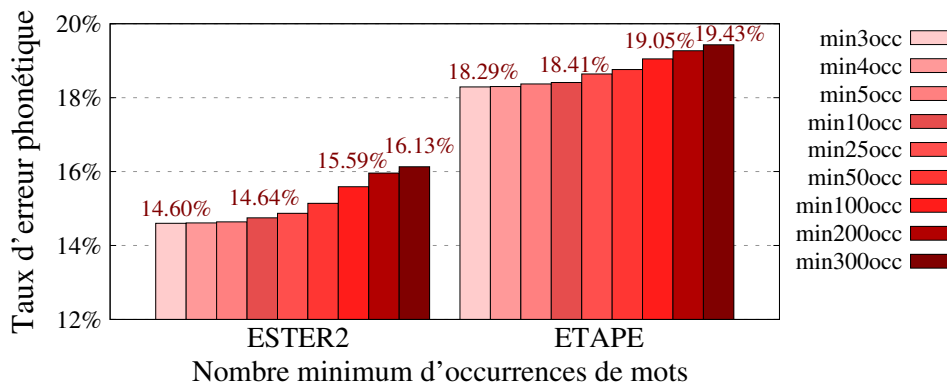


FIGURE 8.4 – Taux d’erreur phonétique obtenus avec les modèles de langage hybrides

Comparé aux autres modèles de langage classiques (mots, phonèmes, syllabes), le modèle de langage hybride ‘min3occ’ a une performance supérieure à celle du modèle syllabique (~2%), mais toujours inférieure à celle du modèle grand vocabulaire (~2%). Pour rappel, le modèle de langage grand vocabulaire a été appris sur une base de données contenant environ 1,7Md de mots, avec un lexique de 97K mots ; alors que le modèle de langage hybride (31 000 mots et 2 000 syllabes) est appris à partir des transcriptions de données de parole correspondant à 3,4M mots plus 110K syllabes.




FIGURE 8.5 – Comparaison des taux d’erreur phonétique obtenus avec les 4 modèles de langage

8.2.2 Mots et syllabes

Étant donné que les modèles de langage hybrides mélangent des mots et des syllabes, et que nous sommes intéressés à récupérer le message porté par la parole, nous avons particulièrement analysé combien de mots sont produits par le décodeur (dans la séquence de mots et de syllabes), et parmi ces mots, combien d'entre eux sont effectivement bien reconnus.




FIGURE 8.6 – Taux de mots dans la séquence de mots et syllabes reconnus par les modèles hybrides

La figure 8.6 affiche le pourcentage de mots produits par le décodeur en fonction des différents vocabulaires hybrides : les sorties de reconnaissance contiennent essentiellement des mots. Les transcriptions automatiques obtenues sur le corpus ESTER2 présentent 97% de mots pour le plus gros modèle ('min300occ', qui a donné 40K mots et 1K syllabes) et ~60% pour le plus petit modèle ('min300occ', qui a donné 31K mots et 21K syllabes). Les transcriptions automatiques obtenues sur le corpus ETAPE présentent 97% de mots pour le plus gros modèle ('min300occ', qui a donné 72K mots et 2K syllabes) et ~63% pour le plus petit modèle ('min300occ', qui a donné 59K mots et 33K syllabes).

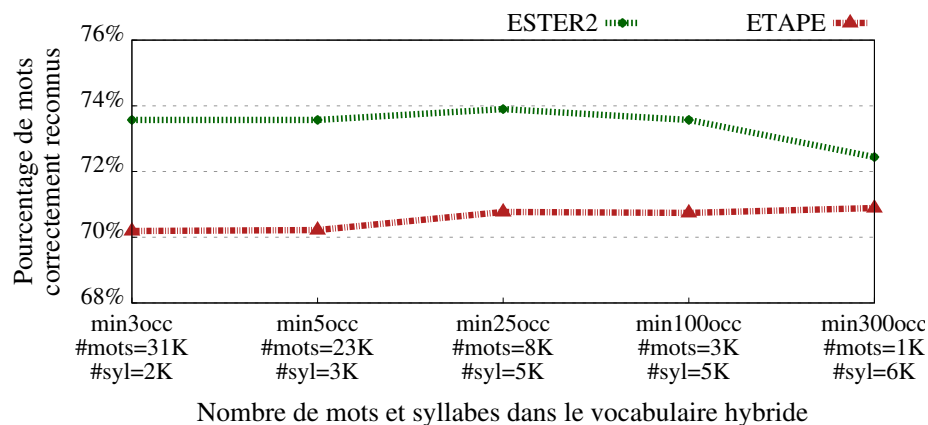


FIGURE 8.7 – Taux de mots correctement reconnus par les modèles hybrides

Les pourcentages de mots correctement reconnus parmi les mots produits par le décodeur, en fonction des différents vocabulaires hybrides, sont présentés dans la figure 8.7.

Ce pourcentage est obtenu en comparant les transcriptions automatiques en mots et syllabes avec l’alignement forcé (en mots) des références (STM) du corpus de parole : pour qu’un mot soit considéré comme étant bien reconnu il doit être présent dans les deux transcriptions, automatique et référence, dans le même intervalle temporel (± 40 ms pour tolérer les petites erreurs de segmentation ou d’alignement). Il y a en moyenne 73% de mots bien reconnus sur le corpus ESTER2, versus 71% sur le corpus ETAPE.

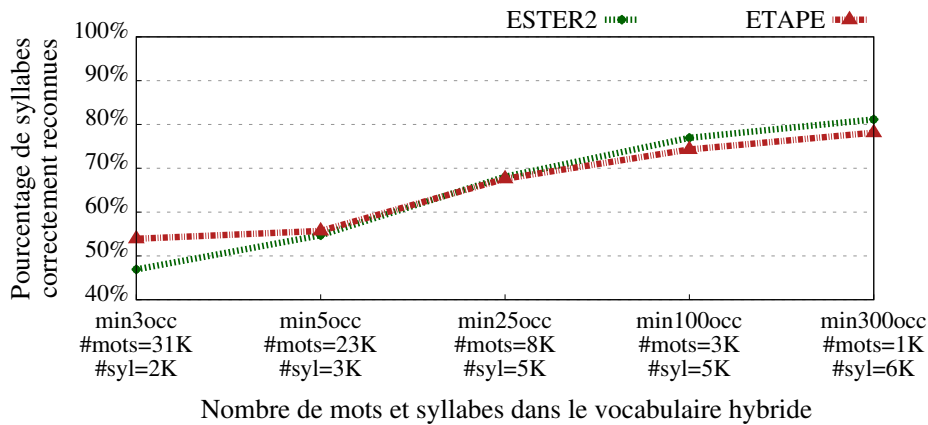


FIGURE 8.8 – Taux de syllabes correctement reconnues par les modèles hybrides

Le pourcentage de syllabes correctement reconnues parmi les syllabes produites par le décodeur, en fonction des différents vocabulaires hybrides, est également étudié. Ce pourcentage est obtenu en comparant les transcriptions automatiques en mots et syllabes avec l’alignement forcé (en phonèmes) des références (STM) du corpus de parole : pour qu’une syllabe soit considérée comme étant bien reconnue, la totalité des phonèmes la composant doit être présente dans les deux transcriptions, automatique et référence, dans le même intervalle temporel (± 40 ms pour tolérer les petites erreurs de segmentation ou d’alignement). Les taux de syllabes bien reconnues varient entre 46% et 81% pour le corpus ESTER2 et entre 54% et 78% pour le corpus ETAPE (cf. Fig. 8.8).

8.2.3 Mots hors-vocabulaire

Une des raisons de l’implémentation d’un modèle hybride est liée à son pouvoir de transcrire les mots hors-vocabulaire par des syllabes.




FIGURE 8.9 – Mots hors-vocabulaire

Les mots hors-vocabulaire sont en fait les mots qui sont présents dans le corpus de test mais absents dans le vocabulaire du système de reconnaissance (cf. Fig. 8.9). Ces mots ne peuvent jamais être reconnus tels quels par le système de reconnaissance de la parole et sont remplacés par d'autres unités lexicales en fonction des modèles de reconnaissance. Dans le cas d'un modèle de langage grand vocabulaire, les mots hors-vocabulaire sont le plus souvent remplacés par une suite des petits mots ayant une prononciation similaire.

Les résultats reportés par la suite sont obtenus sur l'ensemble de développement du corpus ESTER2 qui contient 6517 mots différents avec 41374 occurrences (d'après les fichiers STM).

Vocabulaire	# mots hors-vocabulaire	% occ. mots hors-vocabulaire
min3occ	929	4.34 %
min5occ	1166	5.11 %
min25occ	2452	9.51 %
min100occ	4125	16.98 %
min300occ	5369	26.04 %

TABLE 8.1 – Nombre de mots hors-vocabulaire différents, et pourcentage d'occurrences

La liste des mots hors vocabulaire correspond aux mots absents dans le lexique, mais présents dans la transcription. Le pourcentage d'occurrences est calculée par rapport à tous les mots du corpus évalué (41K mots). Le nombre et le pourcentage d'occurrences des mots hors-vocabulaire relatifs aux différents lexiques hybrides sont affichés dans le tableau 8.1 : ce taux augmente évidemment lorsque la taille du lexique diminue.




FIGURE 8.10 – Analyse du décodage des mots hors vocabulaire sur le corpus ESTER2

La figure 8.10 présente une analyse du décodage des mots hors vocabulaire par les modèles hybrides. Pour réaliser cette analyse nous avons identifié dans la transcription de référence les mots absents dans le vocabulaire du système de reconnaissance et nous avons récupéré la séquence correspondante d'unités lexicales dans chaque transcription automatique. L'analyse des résultats montre que les mots hors vocabulaire ont été remplacés par un ou plusieurs mots (courbe rouge), par une ou plusieurs syllabes (courbe rouge) ou par un mélange de mots et de syllabes (courbe orange) ; il arrive également que le décodeur reconnaisse cette zone de parole hors-vocabulaire par un segment de silence ou de

bruit (courbe grise foncé). Les mots hors-vocabulaire ont été remplacés par des mots (1 ou plusieurs), par des syllabes ou par une séquence de mots et de syllabes. Dans le cas du plus grand modèle ('min300cc'), la plupart de mots hors-vocabulaire sont remplacés par d'autres mots (75%). Ce taux diminue avec l'augmentation du nombre de syllabes dans le lexique hybride, et les mots hors-vocabulaire sont de plus en plus fréquemment remplacés par des syllabes.

8.2.4 Mesures de confiance

Le logiciel de reconnaissance fournit une mesure de confiance pour chaque élément reconnu (mot ou syllabe). Avec PocketSphinx, cette mesure repose sur le calcul d'une probabilité a posteriori. Les mesures de confiance donnent une indication de la pertinence de la reconnaissance. Typiquement, les items ayant une mesure de confiance élevée sont généralement "corrects", et ceux ayant une mesure de confiance faible correspondent fréquemment à une erreur de reconnaissance. Il est ainsi possible en choisissant un seuil sur les mesures de confiance de traiter différemment les items ayant une mesure de confiance supérieure à ce seuil de ceux ayant une mesure de confiance inférieure à ce seuil.

Des tests subjectifs ont montré une préférence pour l'affichage sous forme phonétique des mots ayant une faible mesure de confiance [RAZIK et al. 2008].

Notre approche est donc de conserver les mots avec une bonne probabilité d'être corrects (pour maximiser la bonne compréhension du message), et de remplacer les autres par des suites de phonèmes ou de syllabes [PIQUARD-KIPFFER et al. 2015]. Le choix du seuil est donc crucial : un compromis doit être fait entre le nombre de mots qui sont rejetés (remplacés avec d'autres unités), et la performance obtenue sur les mots conservés.

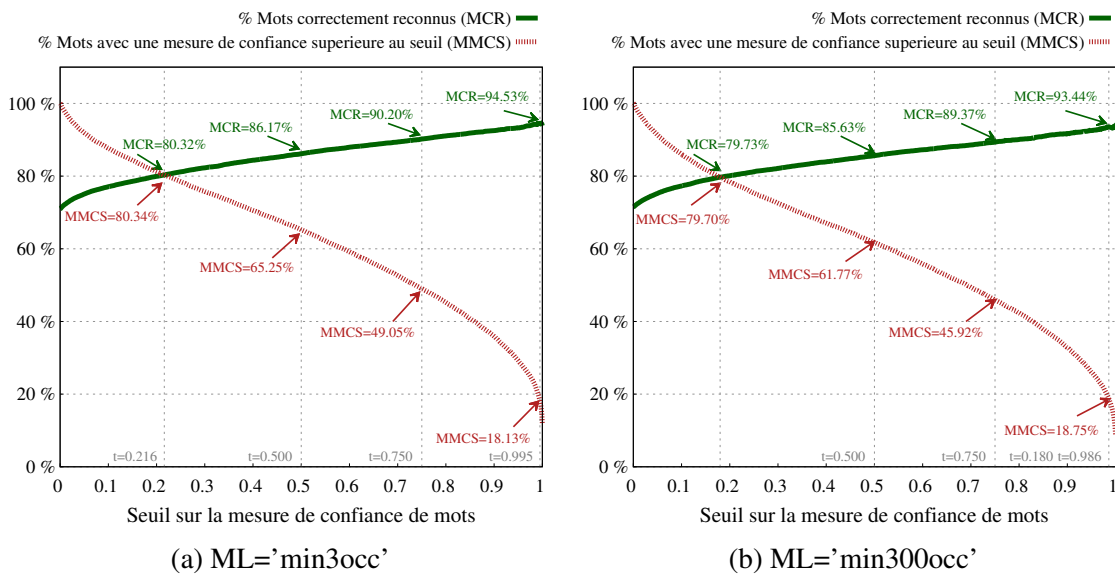


FIGURE 8.11 – Impact du choix du seuil sur la mesure de confiance de mots, pour les modèle de langage hybrides 'min300cc' (a), et 'min3000cc' (b), sur le corpus ESTER2

La figure 8.11 analyse les résultats sur les mots en fonction du choix du seuil sur les mesures de confiance, en utilisant le modèle de langage 'min300cc' (a) et 'min3000cc' (b).

La courbe verte (en trait plein, MCR) indique le pourcentage de mots correctement reconnus parmi ceux ayant une mesure de confiance supérieure au seuil choisi (axe horizontal). La courbe rouge (en pointillés, MMCS) donne le pourcentage de mots qui ont une mesure de confiance supérieure à ce seuil. Bien évidemment, plus le seuil choisi sur la mesure de confiance est élevé, plus y a de réponses correctes parmi les items ayant une mesure de confiance supérieure à ce seuil ; malheureusement le nombre d'items ayant une mesure de confiance supérieure au seuil diminue. Les mesures de confiance calculées sur les mots sont pertinentes : environ 65% de mots ont une mesure de confiance supérieure à 0,5 avec le modèle de langage 'min3occ' et environ 62% avec le modèle de langage 'min300occ'.

Les résultats sur les syllabes en fonction du choix du seuil sur les mesures de confiance sont également étudiés (cf. Fig. 8.12). La courbe verte (en trait plein, SCR) indique le pourcentage de syllabes correctement reconnues parmi celles ayant une mesure de confiance supérieure au seuil choisi (axe horizontal). La courbe rouge (en pointillés, SMCS) donne le pourcentage de syllabes qui ont une mesure de confiance supérieure à ce seuil. Avec le modèle 'min3occ' le taux de syllabes ayant une mesure de confiance supérieure à 0,5 est inférieur à 20%, et le taux de syllabes correctement reconnues varie entre 50% et 76%. Les résultats obtenus avec le modèle 'min300occ' sont meilleurs : le taux de syllabes ayant une mesure de confiance supérieure à 0,5 est supérieur à 50% et le taux de syllabes correctement reconnues varie entre 80% et 96%. Les mesures de confiance calculées sur les syllabes sont pertinentes seulement s'il existe une quantité relativement importante de syllabes dans le corpus d'apprentissage.

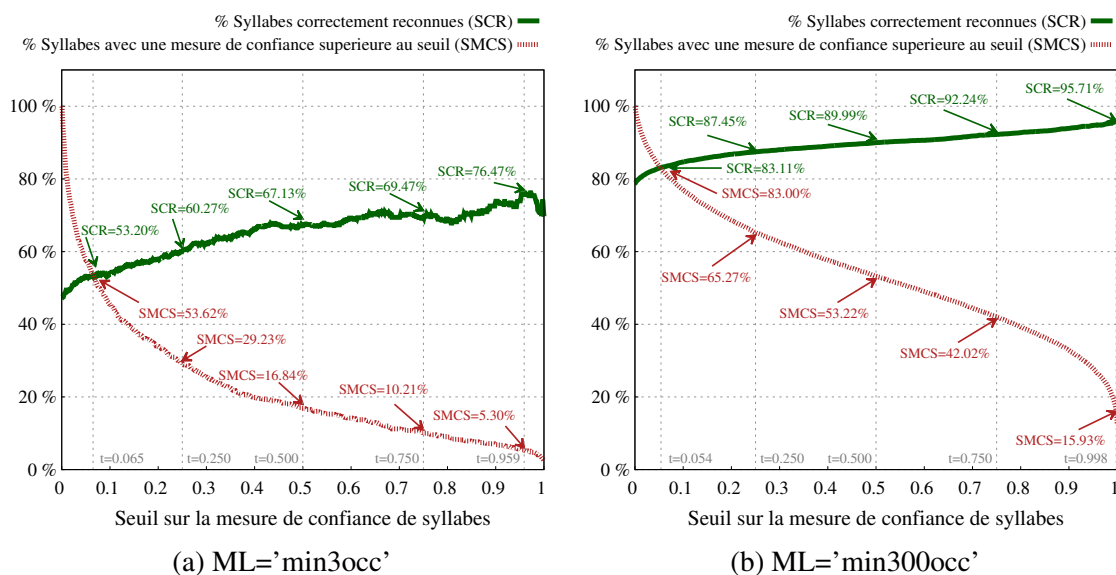


FIGURE 8.12 – Impact du choix du seuil sur la mesure de confiance des syllabes pour les modèles de langage hybrides 'min3occ' (a) et 'min300occ' (b) sur le corpus ESTER2

Les tests effectués ont montré un réel intérêt dans cette mesure. Cependant, plus de tests sur la version finale du produit permettront d'optimiser, par la suite, le choix du seuil.

8.3 Interpolation des modèles hybrides

Pour mieux modéliser les syllabes à l’intérieur d’un modèle hybride nous proposons de combiner deux modèles de langage hybrides, l’un offrant une bonne couverture des mots et l’autre une bonne couverture des syllabes. Le but est d’assurer une bonne reconnaissance d’un nombre important de mots, tout en améliorant les performances des syllabes pour la reconnaissance des mots hors-vocabulaire.

L’interpolation entre deux modèles de langage hybrides implique un regroupement de leurs n-grammes et une mise-à-jour de leurs probabilités (cf. eq. 8.1). En fonction d’une valeur $\lambda \in]0, 1[$, les probabilités n-grammes d’un modèle vont être privilégiées par rapport à l’autre : un λ se rapprochant de la valeur 1 va créer un modèle qui se rapproche des probabilités du premier modèle, et vice-versa — un λ se rapprochant de la valeur 0 va créer un modèle qui se rapproche des probabilités du deuxième modèle.

$$ML_{mix} = \lambda ML_1 + (1 - \lambda) ML_2 \tag{8.1}$$

Nous avons analysé l’interpolation entre un modèle de langage qui contient une quantité importante de mots et quelques syllabes (‘min3occ’ - 31 000 mots et 2 000 syllabes) et un autre modèle qui contient une quantité importante de syllabes et quelques mots (‘min300occ’ - 1 000 mots et 6 000 syllabes), avec les valeurs $\lambda \in \{0, 9; 0, 8; 0, 7; 0, 6; 0, 5; 0, 4; 0, 3; 0, 2; 0, 1\}$. Les modèles interpolés contiennent 31 000 mots et 6 000 syllabes.

Les modèles interpolés sont comparés aux deux modèles de référence en ce qui concerne les taux d’erreur, les taux de mots reconnus, taux de mots bien reconnus, les taux de mots hors-vocabulaire reconnus pas des syllabes, et la pertinence de mesures de confiance sur les syllabes.

Les figures suivantes affichent les différents résultats obtenus avec les modèles interpolés ($\lambda \in \{0, 9; \dots; 0, 1\}$) sur les corpus de parole ESTER2 et ETAPE, en les comparant aux deux modèles de référence - le modèle ‘min3occ’ (à gauche, équivalent à $\lambda = 1$) et le modèle ‘min300occ’ (à droite, équivalent à $\lambda = 0$).

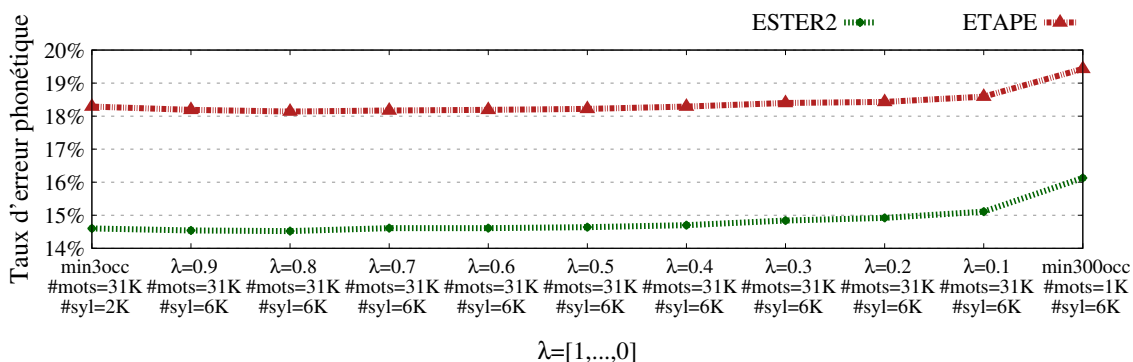


FIGURE 8.13 – Taux d’erreur phonétique obtenus avec l’interpolation de deux modèles de langage hybrides ‘min3occ’ et ‘min300occ’

Les taux d’erreur phonétique des différents modèles sont présentés dans la figure 8.13 : les modèles interpolés produisent un taux d’erreur phonétique similaire à celui du premier modèle ; les modèles $\lambda \in \{0, 3; 0, 2; 0, 1\}$ présentent une dégradation non-significative.

Les taux de mots produits par le décodeur dans les suites de mots et de syllabes, les taux de mots correctement reconnus et les taux de syllabes correctement reconnues sont présentés dans la figure 8.14. Le taux de mots produits par le décodeur varie entre 95% et 80%, soit un écart d'environ 20% de mieux en comparaison du taux produit par le modèle hybride 'min300occ'. Le taux de mots correctement reconnus avec les modèles interpolés est supérieur aux taux obtenus avec les modèles de référence : environ 75% pour le corpus ESTER2 et environ 72% pour le corpus ETAPE. Le taux de syllabes correctement reconnues s'améliore pour les modèles qui s'approchent des probabilités n-grammes du deuxième modèle (λ inférieur à 0,5) : il varie entre 47% et 70% avec un écart de 10% par rapport aux taux obtenus avec le modèle 'min300occ'.




FIGURE 8.14 – Taux de mots reconnus, de mots correctement reconnus et de syllabes correctement reconnues avec l'interpolation de deux modèles de langage hybrides 'min300cc' et 'min300occ'

La figure 8.15 présente les résultats sur les mots hors-vocabulaire. Les modèles interpolés améliorent le taux de mots hors-vocabulaire reconnus par des syllabes (entre 18% et 32%), ce qui est bénéfique compte-tenu de l'affichage envisagé dans l'application. Cependant, il y a toujours un écart de 33% avec le deuxième modèle 'min300occ', qui remplace 65% de mots hors-vocabulaire par des syllabes.

Ces analyses visent à déterminer la meilleure combinaison entre les deux modèles de langage hybrides qui permet de conserver les atouts du premier modèle (reconnaissance

majoritaire de mots, bonne reconnaissance de mots, bonnes mesures de confiance sur les mots) et d'améliorer la performance des syllabes grâce au deuxième modèle. Une combinaison 40%-60% ($\lambda = 0.4$) assure une reconnaissance majoritaire de mots (88%), une bonne reconnaissance de mots connus par le système (76% sur ESTER2 et 73% sur ETAPE), une meilleure reconnaissance de syllabe (60%) et elle double la quantité de mots hors-vocabulaire qui sont reconnus par des syllabes (27% comparé au 13%).




FIGURE 8.15 – Analyse du décodage des mots hors-vocabulaire avec l'interpolation de deux modèles de langage hybrides 'min3occ' et 'min300occ' sur le corpus ESTER2

Les résultats sur les sorties mots et syllabes, en fonction du choix du seuil sur les mesures de confiance, en utilisant le modèle de langage interpolé ($\lambda = 0,4$) entre les modèles hybrides 'min3occ' et 'min300occ' sont affichés dans la figure 8.16. Les mesures de confiance sur les mots sont similaires à celles obtenues avec les modèles de langage 'min3occ' et 'min300occ'. Les mesures de confiance sur les syllabes ne sont toujours pas pertinentes : le taux de syllabes correctement reconnues varie entre 60% et 73% et seulement 21% de syllabes ont une mesure de confiance supérieure à 0,5.




FIGURE 8.16 – Impact du choix du seuil sur la mesure de confiance de mots (a) et de syllabes (b) pour le modèle de langage interpolé $\lambda = 0,4$ entre les modèles hybrides 'min3occ' et 'min300occ' sur le corpus ESTER2

Chapitre 9

Ajout de nouveaux mots

Ce chapitre propose et évalue une nouvelle approche pour ajouter de nouveaux mots dans un modèle de langage. L'ajout de nouveaux mots est nécessaire dans le contexte du projet afin d'assurer une bonne reconnaissance des mots spécifiques à un certain domaine (par exemple mots utiles dans un magasin de bricolage, qui est le contexte applicatif choisi dans le projet pour la validation et l'expérimentation ; et aussi pour pouvoir tenir compte de l'arrivée de nouveaux produits ou services).

L'approche proposée est basée sur un principe de similarité entre mots. Cette partie du travail est publiée dans un article de conférence [OROSANU et JOUVET 2015a].

Sommaire

9.1	Approche	75
9.2	Expérimentations	77

9.1 Approche

Pour ajouter de nouveaux mots dans un modèle de langage et faire face à l'impossibilité de trouver une quantité importante des données textuelles les représentant, nous avons proposé une nouvelle approche basée sur la similarité entre mots.

L'idée est de considérer que deux mots sont similaires s'ils ont les mêmes prédécesseurs et successeurs. Formellement, la comparaison (recherche de similarité) entre deux mots se traduit par un calcul de divergence entre les distributions des mots prédécesseurs et des mots successeurs. L'approche implique ainsi plusieurs étapes : utiliser quelques phrases exemples contenant le nouveau mot, chercher dans le modèle de langage des mots similaires au nouveau mot, puis définir les n-grammes associés au nouveau mot à partir des n-grammes des mots similaires.

9.1.1 Recherche des mots similaires

Un ensemble de phrases est nécessaire afin de disposer d'un minimum d'information sur les nouveaux mots. Il peut être récupéré sur internet ou composé manuellement. Les voisins, prédécesseurs et successeurs, des nouveaux mots sont extraits de ces phrases, afin

de calculer leurs distributions de probabilités. Pour chaque nouveau mot nW (*new word*) on calcule la distribution de probabilités $P_k(w|nW)$ de tous les voisins w trouvés dans chaque position k , avec $k \in \{\dots, -3, -2, -1, +1, +2, +3, \dots\}$.

Un ensemble différent de données est utilisé pour représenter les mots “connus” (i.e. dans le vocabulaire). Les compteurs 2-grammes permettent de calculer les distributions de 2 voisins (-1, +1), les compteurs 3-grammes permettent de calculer les distributions de 4 voisins (-2, -1, +1, +2), et ainsi de suite. Les voisins prédécesseurs et successeurs de chaque mot “connu” sont extraits à partir des compteurs n-grammes, afin de calculer leurs distributions de probabilités. Pour chaque mot connu kW (*known word*) on calcule la distribution de probabilités $P_k(w'|kW)$ de tous les voisins w' trouvés dans chaque position k , avec $k \in \{\dots, -3, -2, -1, +1, +2, +3, \dots\}$.

La (dis)similarité entre les distributions de voisins w d’un nouveau mot nW et d’un mot connu kW est évaluée par la divergence KL [KULLBACK et LEIBLER 1951] sur chaque position k :

$$\begin{aligned} D_k(kW, nW) &= D_{KL}(P_k(\bullet|kW) || P_k(\bullet|nW)) \\ &= \sum_w P_k(w|kW) \log \frac{P_k(w|kW)}{P_k(w|nW)} \end{aligned} \quad (9.1)$$

La divergence KL est calculée sur les voisins w des nouveaux mots pour chaque position k . Si ces voisins ne sont pas présents dans la liste des voisins d’un mot connu, leur probabilité est remplacée avec une petite valeur λ par défaut (dans nos expériences $\lambda = 1e^{-7}$).

La (dis)similarité globale entre deux mots est définie comme la somme des divergences sur toutes les k positions de voisins (cf. eq. 9.2). Les mots les plus similaires avec un nouveau mot sont ceux ayant les divergences les plus faibles.

$$D(kW, nW) = \sum_k D_k(kW, nW) \quad (9.2)$$

9.1.2 Ajout de nouveaux n-grammes

L’algorithme suivant décrit notre méthode d’ajout de n-grammes correspondants à un nouveau mot dans un modèle de langage.

Le nouveau modèle de langage (*newLM*) est initialisé avec tous les n-grammes du modèle baseline. Chaque entrée n-gramme (*ngram*) du modèle baseline est analysée pour vérifier si elle contient un mot connu (kW) qui fait partie de la liste de mots similaires du nouveau mot à ajouter (*similarWords(nW)*). Si c’est le cas, une nouvelle entrée n-gramme est créée en remplaçant le mot connu (kW) avec le nouveau mot (nW) qui lui est similaire, et cette nouvelle entrée n-gramme est ensuite ajoutée dans le nouveau modèle de langage. À noter que le remplacement des mots connus par le nouveau mot (avec lequel il y a similarité) peut produire plusieurs n-grammes ayant la même séquence de mots mais avec des probabilités différentes. Dans ces cas, une seule entrée est conservée pour la séquence de mots correspondante, avec la valeur médiane de probabilité.

Algorithme Ajouter des nouveaux n-grammes dans le modèle de langage

```

1: procédure ADDNGRAMS(n)
2:   newLM ← LM
3:   newNgrams ← ∅
4:   # traiter les n-grams du modèle baseline
5:   for each ngram ∈ LM do
6:     for each kW ∈ similarWords(nW) do
7:       if contains(ngram, kW) then
8:         ngram' ← replace(ngram, kW, nW)
9:         push(newNgrams, ngram')
10:  # choisir les nouveaux n-grams à ajouter dans le nouveau modèle
11:  S ← getUniqueSequences(newNgrams)
12:  for each seq ∈ S do
13:    if frequency(seq) = 1 then
14:      prob ← getProbability(seq)
15:    else
16:      P ← getProbabilities(seq)
17:      prob ← medianProbability(P)
18:      push(newLM, "seq prob")

```

Les poids de back-off sont ensuite renormalisés.

9.2 Expérimentations

Cette section présente les expérimentations menées pour évaluer l'approche proposée, et analyse les résultats. Le contexte expérimental est décrit : choix de nouveaux mots, choix des données textuelles exemples pour les nouveaux mots, nombre de mots similaires à conserver pour chaque nouveau mot et type des n-grammes à ajouter dans le nouveau modèle de langage. Les différents modèles de langage obtenus sont ensuite évalués sur l'ensemble de données de développement d'ESTER2.

9.2.1 Recherche de mots similaires

Nous avons sélectionné une liste de 20 "nouveaux" mots, vus entre 50 et 100 fois dans les ensembles de développement d'ESTER2 et d'ETAPE : {soirée, place, gouvernement, moment, exemple, problème, pouvoir, tour, niveau, nombre, groupe, histoire, journal, sécurité, réunion, projet, année, guerre, jour, rapport}. Nous avons ajouté à cette liste leurs formes féminine, masculine et pluriel pour éviter que le décodeur choisisse une de ces formes comme remplacement à cause de leur prononciations similaires. La liste finale contient 44 mots. L'ensemble de ces mots a une fréquence d'occurrence de 1,33% dans le corpus de développement d'ESTER2, et la suppression de ces mots du lexique et du modèle de langage conduit à une augmentation significative du taux d'erreur mot (26,97% au lieu de 24,80%).

Pour chaque nouveau mot, {5, 10, 20, ou 50} phrases exemples ont été extraites de

manière aléatoire des corpus Wikipedia et GigaWord. Différentes distributions de probabilités ont été testées en utilisant {2 voisins, 4 voisins ou 6 voisins}.

Pour donner un exemple avec 6 voisins, dans la phrase “les précipitations sont également réparties sur l’**année** avec un total de 610 millimètres de pluie”, le nouveau mot “**année**” a comme voisin en position -3 le mot ‘réparties’, voisin en position -2 le mot ‘sur’, ..., voisin en position +3 le mot ‘total’.

Le corpus Wikipedia est utilisé pour calculer les compteurs n-grammes des mots connus (par rapport à un vocabulaire de 97K mots ignorant les nouveaux mots).

Pour le 4-gramme “cèdent leur place à” (qui a été vu 9 fois) le mot “cèdent” a comme voisin en position +1 le mot ‘leur’, voisin en position +2 le mot ‘place’ et voisin en position +3 le mot ‘à’ ; le mot “leur” a comme voisin en position -1 le mot ‘cèdent’, voisin en position +1 ‘place’ et voisin en position +2 ‘à’, ..., le mot “à” a comme voisin en position -3 le mot ‘cèdent’, et ainsi de suite.

Pour la recherche des mots similaires aux nouveaux mots, la prise en compte d’informations complémentaires a été étudiée en considérant la classe grammaticale et le lemme des mots. En conséquence, toutes les phrases ont été annotées avec les unités “mot|classeGrammaticale” et “lemme|classeGrammaticale” correspondantes.

Différentes listes de mots similaires sont obtenues selon que l’on considère les unités mots, les unités “mot|classeGrammaticale” ou les unités “lemme|classeGrammaticale”. À noter que les unités “lemme|classeGrammaticale” ne peuvent pas être utilisés avec les formes féminine, masculine, pluriel des mots (puisque tous les mots sont réduits à la forme racine).

Voici un exemple de listes de 10 mots similaires obtenus pour le nouveau mot “journal” en considérant 10 phrases exemples et la distribution de 6 voisins (avec les fichiers de compteurs 4-grammes de Wikipedia) :

- basée sur les mots : {nom, premier, jeux, livre, paire, monde, magazine, deuxième}
- basée sur les unités “mot|classeGrammaticale” : {magazine, nom, titre, jeux, livre, monde, service, texte, programme, reseau}
- basée sur les unités “lemme|classeGrammaticale” : {chronique, titre, magazine, nom, série, livre, version, gamme, programme, presse}

Pour les expériences suivantes, les mots similaires sont obtenus avec la distribution de 4 voisins en considérant les unités “mot|classeGrammaticale”.

Les tableaux D.1 et D.2 en annexe donnent les 5 mots les plus similaires obtenus pour chaque nouveau mot en considérant 5 et respectivement 50 phrases exemples (avec la distribution de 4 voisins en considérant les unités “mot|classeGrammaticale”).

9.2.2 Ajout de mots dans le modèle de langage

Un modèle de langage grand vocabulaire (97K mots) a été appris sur données textuelles variées (1,3Md mots, 58M phrases), après suppression des phrases contenant les nouveaux mots. Il contient 97 305 1-grammes, 37,1M 2-grammes et 63,1M 3-grammes. Ce modèle est le modèle ‘baseline’ ; les 44 nouveaux mots sont des mots hors-vocabulaire pour ce modèle.

Pour l’évaluation de l’ajout des nouveaux mots au modèle ‘baseline’, trois paramètres

différents ont été testés dans nos expériences : ajouter seulement les 1-grammes ('+1-grammes'), les 1-grammes et 2-grammes ('+1-,2-grammes') ou tous les n-grammes ('+1-,2-,3-grammes') définis pour les 44 nouveaux mots (à partir des mots similaires).

Plusieurs listes de mots similaires ont été évaluées en utilisant {5, 10, 20 ou 50} phrases exemples pour chaque nouveau mot et en choisissant les premiers {5, 10, 20 ou 50} mots connus les plus similaires à chaque nouveau mot.

Pour chacune de ces situations, un nouveau modèle de langage a été fabriqué en ajoutant les 1-grammes associés aux nouveaux mots ('baseline+1-grammes'), un autre en ajoutant les 1-grammes et 2-grammes associés aux nouveaux mots ('baseline+1-,2-grammes') et un troisième en ajoutant les 1-grammes, 2-grammes et 3-grammes associés aux nouveaux mots ('baseline+1-,2-,3-grammes').

Le tableau 9.1 indique le nombre de 2-grammes et de 3-grammes associés aux modèles de langage 'baseline+1-,2-,3-grammes'. L'utilisation de 5 phrases exemples et de 5 mots similaires pour chaque nouveau mot génère le plus petit nouveau modèle ('baseline+1-,2-,3-grammes-5ex-5mS') qui ajoute 2% de nouveaux 2-grammes et 6% de nouveaux 3-grammes (en comparaison avec le modèle 'baseline'). L'utilisation de 50 phrases exemples et de 50 mots similaires pour chaque nouveau mot génère le plus grand nouveau modèle ('baseline+1-,2-,3-grammes-50ex-50mS') qui ajoute 10% de nouveaux 2-grammes et 49% de nouveaux 3-grammes.

	5 mS	10 mS	20 mS	50 mS		5 mS	10 mS	20 mS	50 mS
5 ex	38,0	38,6	39,2	40,3	5 ex	67,2	71,7	76,0	86,7
10 ex	38,1	38,6	39,3	40,5	10 ex	68,1	71,4	77,4	89,8
20 ex	38,2	38,7	39,4	40,6	20 ex	68,5	72,1	77,9	93,2
50 ex	38,1	38,7	39,5	40,7	50 ex	68,4	72,3	79,4	94,2

(a) #2-grammes

(b) #3-grammes

TABLE 9.1 – Nombre de 2-grammes (a) et de 3-grammes (b) [en millions] dans les nouveaux modèles de langage 'baseline+1-,2-,3-grammes', en fonction du nombre de phrases exemples par nouveau mot (*ex*) et du nombre de mots similaires pour chaque nouveau mot (*mS*)

Les modèles 'baseline+1-,2-grammes' ont le même nombre de 2-grammes que les modèles 'baseline+1-,2-,3-grammes'. Dans tous les cas, le nombre de 1-grammes passe de 97305 à 97349 par rapport au modèle 'baseline'.

9.2.3 Modèles de langage de référence

Un modèle ORACLE est fabriqué pour établir la performance maximale que l'on peut atteindre lorsque les nouveaux mots sont déjà connus et le modèle de langage correspondant correctement appris. Ce modèle est appris sur les mêmes données que le modèle 'baseline', mais sans supprimer les phrases associées aux nouveaux mots (1,7Md mots, 74M phrases). Les 44 "nouveaux mots" font partie de son vocabulaire.

Pour rappeler, compte tenu des différentes sources de données et des différentes tailles de données, les modèles de langage 'baseline' et ORACLE sont fabriqués par interpola-

tion ; les poids optimaux d'interpolation sont estimés sur l'ensemble de données de développement d'ETAPE.

Quatre modèles de langage supplémentaires (LM-INTERP-1, LM-INTERP-2, LM-INTERP-3 et LM-INTERP-4) ont été utilisés pour valider notre approche d'ajout de nouveaux mots. Ils ont été appris sur les mêmes ensembles de données que le modèle 'baseline', plus un autre (petit) ensemble de données contenant les {5, 10, 20 ou 50} phrases exemples pour chaque nouveau mot. Les poids optimaux d'interpolation sont estimés également sur le corpus de développement d'Etape : les poids associés aux modèles de langage appris sur {5, 10, 20 ou 50} phrases exemples pour chaque nouveau mot sont respectivement de {4.73%, 5.06%, 5.30%, 5.71%}. Les 44 nouveaux mots ont une fréquence d'occurrence de 0.93% dans le corpus de développement d'Etape.

Le tableau 9.2 indique les tailles des modèles de langage utilisés comme référence dans nos expériences.

LM	1-grammes	2-grammes	3-grammes
baseline	97 305	37,1M	63,1M
modèles interpolés LM-INTERP-1, ..., -4	97 349	37,1M	63,1M
ORACLE	97 349	43,3M	80,1M

TABLE 9.2 – Taille des modèles de langage de référence

9.2.4 Résultats

Les performances des différents modèles de langage sont évaluées sur le corpus de développement d'ESTER2. L'analyse de résultats repose sur le calcul du taux d'erreur mot et du pourcentage de nouveaux mots correctement reconnus.

Le pourcentage de nouveaux mots correctement reconnus est obtenu en comparant les résultats du décodage avec l'alignement forcé des références (STM) du corpus de parole : pour qu'un mot soit considéré comme étant bien reconnu il doit être présent dans les deux transcriptions, automatique et référence, dans le même intervalle temporel (± 40 ms pour tolérer les petites erreurs de segmentation ou d'alignement). Il est défini par le rapport entre le nombre d'occurrences des nouveaux mots correctement reconnues et le nombre total d'occurrences des nouveaux mots dans la transcription de référence.

Modèle de langage	WER	% correctRec.
baseline	26.97	0.00
ORACLE	24.80	85.45

TABLE 9.3 – Statistiques obtenues sur les modèles de langage de référence

Le tableau 9.3 présente le taux d'erreur mot et le pourcentage de nouveaux mots correctement reconnus avec les modèles 'baseline' et ORACLE. La différence de 2,17% entre la performance du modèle 'baseline' et celle du modèle 'ORACLE' est liée aux 44 mots qui sont inconnus dans le modèle de langage 'baseline' (les nouveaux mots ont une

fréquence d'occurrence de 1.33% dans le corpus d'évaluation d'ESTER2); de plus, le modèle ORACLE a été appris sur un ensemble de 74M de phrases, dont 16M de phrases contenant les nouveaux mots.

Le taux d'erreur mot et le pourcentage de nouveaux mots correctement reconnus obtenus avec les modèles interpolés (LM-INTERP-1,...,-4) et avec les nouveaux modèles de langage 'baseline+1-,2-,3-grammes' sont présentés dans le tableau 9.4. Les modèles interpolés sont appris sur les mêmes ensembles de données que le modèle 'baseline', complétés avec {5, 10, 20 ou 50} phrases exemples par nouveau mot. Les nouveaux modèles ('baseline+1-,2-,3-grammes') utilisent les mêmes phrases exemples pour définir la distribution de voisins de nouveaux mots (utilisées pour chercher des mots similaires).

	LM-INTERP	'baseline+1-,2-,3-grammes'			
		5 mS	10 mS	20 mS	50 mS
5 ex	26,12	25,78	25,83	25,96	26,01
10 ex	26,02	25,74	25,84	25,96	26,05
20 ex	25,81	25,63	25,68	25,92	25,95
50 ex	25,68	25,68	25,75	25,82	25,99

(a) Taux d'erreur mot (WER)

	LM-INTERP	'baseline+1-,2-,3-grammes'			
		5 mS	10 mS	20 mS	50 mS
5 ex	44,72	64,90	61,09	58,36	56,72
10 ex	47,45	63,09	61,09	57,09	55,27
20 ex	54,18	68,72	65,81	61,27	58,18
50 ex	59,63	68,54	63,45	61,81	57,09

(b) Pourcentage de nouveaux mots correctement reconnus

TABLE 9.4 – Analyse du taux d'erreur mot (a) et du pourcentage de nouveaux mots correctement reconnus (b) obtenus avec les quatre modèles interpolés (LM-INTERP-1,...,-4) et avec les nouveaux modèles de langage 'baseline+1-,2-,3-grammes', en fonction du nombre de phrases exemples par nouveau mot (*ex*) et du nombre de mots similaires pour chaque nouveau mot (*mS*)

En ce qui concerne les modèles interpolés, de meilleures performances sont obtenues avec un plus grand nombre de phrases exemples par nouveau mot. L'utilisation de seulement 5 phrases exemples (LM-INTERP-1) conduit à une réduction du taux d'erreur mot de 0,80% (en absolu) par rapport au modèle 'baseline' et permet au système de reconnaître correctement 45% des nouveaux mots. L'utilisation de 50 phrases exemples (LM-INTERP-4) fournit une réduction du taux d'erreur mot de 1,30% (en absolu) par rapport au modèle 'baseline' et permet au système de reconnaître correctement 60% des nouveaux mots. Les bons résultats produits par les modèles interpolés sont probablement liés à la quantité non négligeable de nouveaux mots présents dans l'ensemble de données de développement d'ETAPE (utilisées pour estimer les poids optimaux d'interpolation).

En ce qui concerne les nouveaux modèles de langage, de meilleures performances sont obtenues avec moins de mots similaires pour chaque nouveau mot et avec plus de phrases exemples par nouveau mot. Les meilleurs résultats sont obtenus en ajoutant des

1-grammes, 2-grammes et 3-grammes pour les nouveaux mots dans le modèle ‘baseline’, à partir de 20 phrases exemples par nouveau mot et 5 mots similaires pour chaque nouveau mot (‘baseline+1-,2-,3-grammes-20ex-5mS’) : un taux d’erreur mot de 25,63% (amélioration de 1,34% par rapport au modèle ‘baseline’) et 69% de nouveaux mots correctement reconnus. Utiliser peu de mots similaires pour chaque nouveau mot limite également la taille des nouveaux modèles de langage.

Les nouveaux mots sont mieux reconnus avec les nouveaux modèles de langage créés sur le principe de similarité entre mots (entre 64,90% et 68,54%), qu’avec les modèles interpolés (entre 44,72% et 59,63%). Aussi, de plus petits taux d’erreur mot sont obtenus avec les nouveaux modèles qu’avec les modèles interpolés, en particulier lorsque seulement une petite quantité de données associées aux nouveaux mots est disponible. Lorsqu’on dispose d’une quantité plus grande de données associées aux nouveaux mots, l’écart de performance (taux d’erreur mot) entre les deux types de modèles diminue, mais le pourcentage de nouveaux mots correctement reconnus est toujours plus élevé avec les nouveaux modèles.

Nous avons également évalué le taux de nouveaux mots insérés à tort, pour s’assurer que les probabilités associées aux nouveaux mots ne soient pas trop importantes par rapport aux autres mots du lexique. Ce taux est négligeable (inférieur à 0,5%) pour les nouveaux modèles de langage ; il en est de même pour les modèles interpolés.

L’ajout des 1-grammes uniquement (‘baseline+1-grammes’) ou des 1-grammes et des 2-grammes (‘baseline+1-,2-grammes’) pour les nouveaux mots fournissent des performances inférieures : un taux d’erreur mot de minimum 26,57% pour les nouveaux modèles ‘baseline+1-grammes’, avec un maximum de 24% de nouveaux mots correctement reconnus ; et un taux d’erreur mot de minimum 25,84% pour les nouveaux modèles ‘baseline+1-,2-grammes’, avec un maximum de 56% de nouveaux mots correctement reconnus (cf. Tab. E.1 en annexe).

D’autres tests ont considéré l’ajout uniquement des 1-grammes pour les nouveaux mots. Deux méthodes ont été évaluées : (M1) les 1-grammes des nouveaux mots ont associée la même probabilité unigramme de l’étiquette inconnue <unk> ; (M2) les nouveaux mots sont inclus dans le vocabulaire du modèle ‘baseline’, sachant que ces mots sont toujours absents dans le corpus d’apprentissage - les probabilités 1-grammes de nouveaux mots sont estimées par la méthode de *smoothing* modifiée de Kneser-Ney. La méthode M1 fournit un taux d’erreur mot de 26,68% et permet de reconnaître correctement 15,45% de nouveaux mots. La méthode M2 fournit un taux d’erreur mot de 26,85% et permet de reconnaître correctement 3,63% de nouveaux mots. Ces performances sont inférieures à celles obtenues avec les nouveaux modèles de langage. De plus, ces deux méthodes ont un grand inconvénient : tous les 1-grammes associés aux nouveaux mots ont la même probabilité, ce qui a conduit le décodeur à choisir arbitrairement la forme plurielle de chaque nouveau mot (sachant que les formes singulier et pluriel d’un mot peuvent avoir la même prononciation en français).

Ces résultats montrent que notre approche basée sur la similarité entre mots et notre méthode d’ajouter de nouveaux n-grammes dans un modèle de langage sont efficaces, surtout lorsque seulement une quantité limitée de données relative aux nouveaux mots est disponible.

Chapitre 10

Conclusions

Cette partie a présenté les travaux autour de l'optimisation des modèles de reconnaissance de la parole (en particulier par rapport à la problématique des mots hors vocabulaire) : choix et combinaison des unités lexicales et possibilité d'ajouter de nouveaux mots au modèle de langage.

L'optimisation du décodage phonétique a mis en évidence l'intérêt des modèles syllabiques : le taux d'erreur phonétique obtenu avec le modèle de langage syllabique n'est que de 4% plus mauvais (en valeur absolue) que le taux d'erreur phonétique obtenu avec le système de reconnaissance grand vocabulaire, et son lexique compte seulement 8 100 syllabes.

La modélisation hybride, combinant un ensemble de mots et un ensemble de syllabes, apparaît comme une approche prometteuse. La partie en mots est choisie pour être la plus pertinente possible (mots les plus fréquents dans un corpus donné), et la taille du vocabulaire est ajustée en fonction des ressources disponibles pour le décodage. L'inclusion de syllabes dans le modèle de reconnaissance permet d'approximer les prononciations de mots hors-vocabulaire lors du décodage, et d'éviter ainsi que ces mots génèrent systématiquement des erreurs (confusions avec d'autres mots du lexique). Le taux d'erreur phonétique d'un modèle hybride n'est que légèrement plus mauvais que le taux d'erreur obtenu avec le système de reconnaissance grand vocabulaire (2%). Parmi les mots qui apparaissent dans les résultats de reconnaissance (le reste étant représenté par des syllabes), environ 70% d'entre eux sont correctement reconnus.

En ajustant un seuil de décision sur les mesures de confiance associées aux mots (qui indiquent la probabilité qu'un mot soit correctement reconnu), nous avons constaté, comme attendu, que plus nous augmentons le seuil, plus le pourcentage de mots ayant une mesure de confiance supérieure à ce seuil est réduit et plus le pourcentage de mots correctement reconnus parmi les mots conservés est élevé (entre 70% et 92%). L'idée est de conserver les mots avec une bonne probabilité d'être corrects (pour maximiser la bonne compréhension du message), et de remplacer les autres par des suites de syllabes. Le meilleur choix du seuil reste à ajuster par la suite en effectuant des tests sur la version finale du produit.

Les mesures de confiance sur les syllabes sont pertinentes seulement s'il existe une quantité relativement importante de syllabes dans le corpus d'apprentissage. Cependant, une quantité importante de syllabes dans le corpus implique une quantité faible de mots.

Pour mieux modéliser les syllabes à l'intérieur d'un modèle hybride en conservant au même temps une quantité importante de mots nous avons proposé d'interpoler deux modèles de langage hybrides. Le but est d'assurer une bonne reconnaissance d'un nombre important de mots et tout en améliorant les performances des syllabes pour la reconnaissance des mots hors-vocabulaire. La combinaison a été faite entre un modèle de langage offrant une bonne couverture des mots (31 000 mots et 2 000 syllabes) et un autre modèle offrant une bonne couverture des syllabes (1 000 mots et 6 000 syllabes). Une combinaison 40%-60% continue d'assurer une bonne reconnaissance des mots connus par le système. Comparé au premier modèle, le modèle combiné produit le même taux d'erreur phonétique, mais il améliore notablement (il double) le taux de mots hors-vocabulaire reconnus par des syllabes, ce qui est bénéfique compte-tenu de l'affichage choisi. Les mesures de confiance sur les syllabes ne sont toujours pas pertinentes avec les modèles interpolés ; cependant, le taux de syllabes correctement reconnues est supérieur à celui du premier modèle (60% vs 48%).

Pour ajouter de nouveaux mots dans un modèle de langage et faire face à l'impossibilité de trouver une quantité importante des données textuelles les représentant et éviter un réapprentissage complet du modèle de langage, nous avons proposé une nouvelle approche basée sur la similarité entre mots : deux mots sont similaires s'ils ont les mêmes prédécesseurs et successeurs. Formellement, la recherche de similarité entre deux mots se traduit par un calcul de divergence entre les distributions des mots prédécesseurs et des mots successeurs. L'approche implique plusieurs étapes : utiliser quelques phrases exemples pour le nouveau mot, chercher des mots connus (du modèle de langage) similaires au nouveau mot, puis définir les n-grammes associés à ce nouveau mot à partir des n-grammes des mots similaires.

Deux modèles de langage grand-vocabulaire, fabriqués par interpolation sur des ensembles de données textuelles de sources différentes et de tailles différentes, sont utilisés comme référence : un modèle 'baseline' qui ne connaît pas les nouveaux mots, et un modèle ORACLE qui établit la performance maximale que l'on peut atteindre lorsque les nouveaux mots sont déjà connus et le modèle de langage correspondant correctement appris. Quatre modèles de langage supplémentaires (LM-INTERP-1, LM-INTERP-2, LM-INTERP-3 et LM-INTERP-4) ont été utilisés pour valider notre approche d'ajout de nouveaux mots. Ils ont été appris sur les mêmes ensembles de données que le modèle 'baseline', plus un nouveau petit ensemble de données contenant {5, 10, 20 ou 50} phrases exemples pour chaque nouveau mot.

Les évaluations ont montré que notre approche basée sur la similarité entre mots et notre méthode d'ajout de nouveaux n-grammes dans un modèle de langage sont efficaces. L'ajout de n-grammes (1-grammes, 2-grammes et 3-grammes) pour les nouveaux mots fournit une amélioration absolue de 1,3% sur le taux d'erreur mot (par rapport au modèle 'baseline') et permet de reconnaître correctement 69% des nouveaux mots. Des meilleures performances sont obtenues avec la sélection de peu de mots similaires pour chaque nouveau mot (5-10) et avec un nombre raisonnable de phrases exemples pour les nouveaux mots (20-50). L'utilisation de seulement quelques mots similaires limite aussi la taille des nouveaux modèles de langage.

Le pourcentage de nouveaux mots correctement reconnus est plus élevé avec les nou-

veaux modèles de langage créés sur le principe de similarité entre mots (entre 63% et 69%) qu'avec les modèles interpolés (entre 44% et 60%). Aussi, des réductions du taux d'erreur mot sont obtenues avec les nouveaux modèles en comparaison des modèles interpolés, en particulier lorsque seulement une petite quantité de données associées aux nouveaux mots est disponible. Lorsqu'on dispose d'une quantité plus grande de données associées aux nouveaux mots, l'écart de performance WER entre les deux types de modèles diminue, mais le pourcentage de nouveaux mots correctement reconnus est toujours plus élevé avec les nouveaux modèles.

Troisième partie

Modélisation para-lexicale

11	État de l’art	89
11.1	Détection de la modalité des phrases	89
11.2	Nos travaux	93
12	Contexte expérimental	95
12.1	Données textuelles	95
12.2	Données de parole	96
12.3	Classifieurs	97
12.4	Configuration	99
13	Paramètres prosodiques et linguistiques	101
13.1	Paramètres prosodiques	102
13.2	Paramètres linguistiques	105
14	Expérimentations	107
14.1	Utilisation des paramètres prosodiques	108
14.2	Utilisation des paramètres linguistiques	110
14.3	Utilisation des paramètres combinés	111
14.4	Comparaisons entre paramètres	113
14.5	Impact des frontières sur la performance	116
15	Conclusions	119

Chapitre 11

État de l’art

Le deuxième défi de cette thèse porte sur l’extraction d’informations complémentaires (non lexicales) qui sont importantes pour la communication inter-personnes. L’aspect étudié porte sur la détection de la modalité des phrases, en particulier la détection des questions et des affirmations, visant à enrichir la communication avec les personnes sourdes ou malentendantes, de manière à leur signaler s’il s’agit d’une question, et que dans ce cas, ils doivent répondre ou intervenir pour une demande de répétition ou de clarification.

Ce chapitre présente l’état de l’art relatif à la détection automatique de la modalité de phrases. Nos travaux sont ensuite positionnés par rapport aux objectifs du projet et à l’état de l’art.

Sommaire

11.1 Détection de la modalité des phrases	89
11.2 Nos travaux	93

11.1 Détection de la modalité des phrases

La détection automatique de la modalité de phrases a été étudiée dans les dernières décennies avec différents objectifs : modéliser et détecter la structure de la parole [JURAFSKY et al. 1997], faire la distinction entre les déclarations et les questions [KRAL et al. 2005 ; YUAN et JURAFSKY 2005 ; LISCOMBE et al. 2006 ; QUANG et al. 2006 ; QUANG et al. 2007 ; KHAN et al. 2010], faire la distinction entre différents types de questions [MARGOLIS et OSTENDORF 2011], créer le résumé de documents ou de réunions [QUANG et al. 2006] ou enrichir une transcription automatique avec des marques de ponctuation [KOLÁŘ et LAMEL 2012].

Toutes ces études utilisent des données manuellement annotées (ponctuées ou classées en actes de dialogue). Cependant, l’annotation des signaux audio est subjective et difficile, car il y a de nombreux cas pour lesquels il n’existe pas de règle standard de ponctuation [KOLÁŘ et LAMEL 2011]. C’est pour cette raison que les données sont habituellement annotées par plusieurs annotateurs et qu’une mesure d’accord entre annotateurs est souvent fournie.

Les indices généralement utilisés pour la détection de la modalité de phrases sont les

paramètres prosodiques (calculés sur le signal de parole) et les paramètres linguistiques (calculés sur la transcription en mots). L'extraction de paramètres prosodiques repose généralement sur le calcul de la fréquence fondamentale de la parole qui fournit la courbe d'intonation (en général, intonation montante en fin de phrase, pour des questions). Les paramètres linguistiques dépendent de deux scénarios : selon qu'ils sont extraits de données correctes (textuelles et / ou transcriptions manuelles des signaux audio) ou de transcriptions automatiques (générées par un système de reconnaissance automatique de la parole). Les erreurs de reconnaissance, qui sont plus fréquentes avec un signal audio de mauvaise qualité (faible rapport signal-à-bruit) et avec de la parole spontanée, peuvent fortement diminuer les performances de classification. De plus, selon le mode de reconnaissance mis en œuvre (mots, syllabes ou autre) plus ou moins d'informations lexicales seront disponibles et pourront être exploitées.

Paramètres prosodiques

Les études sur les paramètres prosodiques sont très diversifiées. Différents types de paramètres sont calculés et différentes parties du signal de parole sont analysées, en fonction de la langue et de la modalité.

Les paramètres prosodiques pris en compte dans [KRAL et al. 2005] pour la détection de questions, affirmations et exclamations françaises incluent la fréquence fondamentale (F0) et l'énergie, calculés sur les dernières 700 millisecondes de parole. Leurs évaluations sont effectuées sur le corpus français ESTER, sur un ensemble de 150 affirmations, 153 exclamations et 126 questions. Dans leur approche, ils prennent en compte les règles de base concernant la prosodie des phrases en français : les phrases déclaratives ont une légère diminution de la mélodie (le F0 est presque stationnaire), les phrases impératives ont une diminution importante de la mélodie (le F0 diminue), les phrases interrogatives sans formules interrogatives ont une augmentation de la mélodie (le F0 augmente) et les phrases interrogatives avec formules interrogatives ont une intonation neutre. Leur meilleure approche combine les sorties de deux classifieurs : un classifieur GMM (*Gaussian Mixture Model*) qui utilise les dérivées temporelles de la fréquence fondamentale (F0) et un perceptron multi-couches qui utilise 20 paramètres liés à la fréquence fondamentale et 20 paramètres liés à l'énergie. Les phrases reconnues comme des questions par le classifieur GMM sont définitivement classées comme questions. Les autres phrases sont alors traitées par le perceptron. La performance globale est de 61%, mais ceci avec un bon taux de reconnaissance des questions de 84%. La performance est définie comme le pourcentage de phrases correctement classées.

Une étude effectuée sur la détection de questions dans la langue arabe a montré l'importance de l'énergie et de la fréquence fondamentale [KHAN et al. 2010]. Dans leur approche, chaque phrase a été divisée en trois segments distincts : 200 millisecondes de départ, 200 millisecondes finales et le reste. Les paramètres prosodiques (123 au total, 15 après une sélection progressive) sont calculés sur les trois parties de la phrase. Le classifieur basé sur un réseau bayésien conduit à une performance de 77% (pourcentage de phrases correctement classées).

Un autre détecteur de questions et affirmations françaises a été proposé dans [QUANG

et al. 2006]. Leur but est de résumer automatiquement les réunions ou les enregistrements des conversations et, plus particulièrement, d'extraire les phrases interrogatives de ces enregistrements. Ils utilisent 12 paramètres prosodiques dérivés de la fréquence fondamentale de la parole. Les évaluations sont effectuées sur un ensemble de 95 questions et 357 affirmations appartenant au corpus français DeLoc ; le classifieur est basé sur l'arbre de décision C4.5 (présenté dans la section 12.3) ; la performance est définie comme la moyenne entre le pourcentage de questions correctement classées et le pourcentage d'affirmations correctement classées. La performance obtenue est d'environ 75% (dont 77% des questions correctement identifiées par le système).

Combinaison de paramètres sur données lexicales correctes

La combinaison des paramètres prosodiques et linguistiques se révèle très utile lorsque l'on traite des données lexicales correctes (e.g. du texte ou des transcriptions manuelles des signaux audio).

Dans [LISCOMBE et al. 2006], la façon de poser des questions a été modélisée dans le but d'améliorer les systèmes tutoriels intelligents (en anglais). Dans leur approche, ils extraient des paramètres prosodiques (associés à la fréquence fondamentale, à l'intensité sonore et au rythme), lexicaux (1-grammes et 2-grammes de mots prononcés par les étudiants) et syntaxiques (1-grammes et 2-grammes de classes grammaticales appartenant aux phrases prononcées par les étudiants), et des informations liées à l'étudiant et à ses énonciations. Leur classifieur est basé sur l'arbre de décision C4.5, amélioré avec l'algorithme AdaBoost. Leur étude a conclu que l'information la plus utile pour la détection de questions est le pitch calculé sur les 200 dernières millisecondes d'un tour de parole, qui fournit une performance de 72,6%. Cependant, les paramètres lexicaux et syntaxiques ajoutés à la prosodie améliorent la performance globale jusqu'à 79,7%.

Le classifieur prosodique-lexical présenté dans [QUANG et al. 2007] considère des paramètres lexicaux qui décrivent la présence et la position des mots interrogatifs (la présence ou l'absence de termes interrogatifs, les 1-grammes et 2-grammes précédant les termes interrogatifs, les 1-grammes suivant les termes interrogatifs). Les expériences sont effectuées sur un ensemble de 234 questions et 234 affirmations appartenant au corpus français DeLoc, et un ensemble de 650 questions et 650 affirmations appartenant au corpus français Nespole. Le classifieur est basé sur l'arbre de décision C4.5 et la performance est définie en termes de F-mesure du rappel et de la précision. Leur détecteur combiné atteint une performance de 77% sur les deux ensembles.

L'utilisation de conversations textuelles stockées sur internet (en anglais) pour détecter différents types de questions (oui/non, déclaratives, rhétoriques, sélections multiples, ...) dans les conversations orales a été étudiée dans [MARGOLIS et OSTENDORF 2011]. Les tests ont été effectués sur 26K phrases (manuellement transcrites) appartenant aux ensembles de développement et de test du corpus MRDA (*Meeting Recorder Dialog Act*). Les paramètres lexicaux prennent en compte la présence ou l'absence des 1-grammes, 2-grammes, 3-grammes dans la phrase. Un ensemble de 16 paramètres acoustiques a été extrait pour chaque phrase (statistiques de F0, nombre de trames voisés, nombre de mots par trame). La performance est donnée par la surface en-dessous la courbe (*Area Un-*

der the Curve) entre le taux de fausses prédictions positives et le taux de détection. Les paramètres lexicaux appris sur données textuelles récupérées sur internet fournissent des performances supérieures à 75% pour la plupart des types de questions et une performance de seulement 30% pour les questions déclaratives. Les paramètres prosodiques et lexicaux appris sur l'ensemble d'apprentissage du corpus MRDA fournissent des performances supérieures à 88% pour la plupart des types de questions et une performance de 70% pour les questions déclaratives. L'utilisation des paramètres prosodiques est donc indispensable pour la bonne classification des questions déclaratives.

Combinaison de paramètres sur données lexicales automatiques

Différentes études sont également effectuées sur des transcriptions automatiques en utilisant des paramètres linguistiques ou des paramètres linguistiques et prosodiques combinés.

Un modèle de 42 actes de dialogue (décrivant les actes les plus répandus, comme les questions, réponses, accords, désaccords, excuses, etc), a été utilisé pour étiqueter le corpus anglais Switchboard qui contient 1155 conversations téléphoniques [JURAFSKY et al. 1997]. Trois types d'informations ont été prises en compte pour la détection des actes de dialogue : la séquence des mots qui caractérisent l'acte de dialogue, la séquence des paramètres prosodiques (comme le pitch et la vitesse de locution) qui caractérisent l'acte de dialogue et une grammaire statistique du discours. Le détecteur combiné atteint une performance de 65% sur les transcriptions automatiques et 72% sur les transcriptions manuelles. La performance est définie comme le pourcentage de phrases correctement classées (par rapport au nombre total de phrases).

La détection de questions lors de réunions (en anglais) a été abordée dans [BOAKYE et al. 2009]. Ils ont utilisé des paramètres lexico-syntaxiques (1-grammes et 2-grammes de mots, la présence d'un verbe auxiliaire ou d'un mot 'wh', d'un pronom d'une deuxième personne ou d'une inversion dans l'ordre des mots), des informations liées à la prise de parole et au pitch. Ils ont atteint une F-mesure de 54% sur les transcriptions automatiques contre 70% sur les transcriptions manuelles de référence. Les paramètres lexico-syntaxique étaient les plus utiles pour cette tâche.

Un système automatique de ponctuation (virgule, point, point d'interrogation) pour le français et l'anglais a été étudié dans [KOLÁŘ et LAMEL 2012]. Leur modèle de ponctuation utilise des informations prosodiques et lexicales (les mots reconnus par un système automatique de reconnaissance vocale). Les 30 paramètres prosodiques sont associés à des frontières inter-mots et capturent des informations liées aux pauses, durées, pitch et énergie. L'information textuelle est capturée à chaque frontière inter-mots : les n-grammes (jusqu'à 4-grammes) contenant le mot avant la frontière d'intérêt, ainsi que l'unigramme suivant. La métrique *Slot Error Rate* (taux d'erreur d'emplacement) a été utilisée pour évaluer la performance de leur système : 67% sur les transcriptions automatiques et 45% sur les transcriptions manuelles.

Tous les classifieurs mentionnés sont appliqués sur des langues différentes, sur des types de données différentes, dans des conditions différentes, et avec des paramètres différents. Certains utilisent des données qui sont manuellement classées dans des actes de

dialogues, d'autres extraient des phrases des ensembles de données basées sur les signes de ponctuation (avec ou sans un ré-étiquetage manuel postérieur). Certains s'intéressent seulement à la partie finale du signal de parole (en considérant l'avis général que l'intonation d'une question est une intonation finale montante), d'autres à l'ensemble de la phrase. Certains utilisent divers paramètres prosodiques (voire jusqu'à 123 paramètres différents), d'autres ne gardent que les valeurs les plus classiques : moyenne, maximum, minimum, delta, pente, etc. Chaque analyse est unique et très dépendante du type de données et du choix des fonctionnalités. De plus, les diverses métriques de mesure de performance rendent difficiles les comparaisons entre deux études.

11.2 Nos travaux

Dans notre étude, plusieurs approches sont analysées : la création d'un classifieur avec seulement des paramètres prosodiques (extraits du signal audio), d'un classifieur avec seulement des paramètres linguistiques (extraits des séquences de mots et des séquences de classes grammaticales) ou d'un classifieur qui combine les deux types d'information.

La nouveauté de notre approche consiste à combiner trois types différents de paramètres linguistiques pour détecter les questions dans les transcriptions automatiques : des n-grammes basés sur les mots, des n-grammes basés sur les classes grammaticale et la présence de motifs interrogatifs discriminatoires. Les paramètres prosodiques prennent en compte, entre autre, les pentes ascendantes et descendantes de la fréquence fondamentale (F0) sur des segments 'isolés' ou sur des trames consécutives (ignorant les valeurs nulles). L'évaluation de classifieurs est effectuée en utilisant des paramètres linguistiques et prosodiques extraits à partir de transcriptions automatiques (pour étudier la performance dans des conditions réelles) et de transcriptions manuelles (pour étudier la performance dans des conditions idéales, c'est-à-dire quand il n'y a pas d'erreurs de mots). Les premières expériences considèrent une segmentation de phrases parfaite (prédéfinie). Ensuite, nous évaluons la perte de performance lorsque les frontières de phrases ne sont pas parfaitement identifiées.

Cette partie du travail est publiée dans deux articles de conférence [[OROSANU et JOUVET 2015c](#) ; [OROSANU et JOUVET 2015b](#)].

Chapitre 12

Contexte expérimental

Les différentes données et les outils utilisés dans nos expériences sont présentés ci-dessous.

Sommaire

12.1 Données textuelles	95
12.2 Données de parole	96
12.3 Classifieurs	97
12.4 Configuration	99

12.1 Données textuelles

Des données textuelles ponctuées sont nécessaires afin de modéliser les caractéristiques lexicales et syntaxiques des questions et des affirmations. Les données disponibles (plus de 800 millions de mots) appartiennent au corpus GigaWord [MENDONÇA et al. 2011]; seulement les phrases qui contiennent uniquement des mots présents dans le vocabulaire de 97K mots sont conservées. 89K questions et 16M d'affirmations ont été extraites de ce corpus (cf. Tab. 12.1), en filtrant les phrases qui se terminent par un point d'interrogation et celles qui se terminent par un point. Les données lexicales ont été annotées en classes grammaticales POS (*part-of-speech tags*), fournissant ainsi les données syntaxiques.

Données	# phrases	# occ. mots	# mots uniques
toutes les données	27 353 351	827 513 775	985 633
questions	88 726	1 147 726	37 436
affirmations	15 777 681	407 030 184	93 973

TABLE 12.1 – Données textuelles du corpus Gigaword avec les sous-ensembles extraits de questions et d'affirmations

Deux modèles de langage ont été appris sur les données *textuelles* (basées sur les mots), un pour les questions et un pour les affirmations, avec un vocabulaire commun de 97K mots. Ces modèles de langage ont pour but de représenter les principales séquences

de mots qui se produisent respectivement dans les questions et dans les affirmations (e.g. ‘est-ce que ...’, ‘qu’est-ce que ...’, ‘il a vu ...’, ‘j’ai mangé ...’).

Deux autres modèles de langage ont été appris sur les données *syntaxiques* (basées sur les classes grammaticales POS), un pour les questions et un pour les affirmations, avec un vocabulaire commun de 36 étiquettes POS. Ces modèles de langage ont pour but de représenter les principales séquences syntaxiques qui se produisent respectivement dans les questions et dans les affirmations (e.g. les inversions verbe-pronom ‘pourrait-on ...’, ‘fallait-il ...’, les séquences pronom-verbe ‘je peux ...’, ‘il faut ...’).

Modèle de langage	basé sur mots	basé sur étiquettes POS
questions	718K	9K
affirmations	68M	16K

TABLE 12.2 – Nombre de 3-grammes dans les modèles de langage calculés sur les questions et sur les affirmations

Le tableau 12.2 présente les tailles (en nombre de 3-grammes) des modèles de langage trigrammes appris sur les données lexicales et sur les données syntaxiques.

12.2 Données de parole

Les corpus de parole utilisés pour apprendre et évaluer les détecteurs de questions proviennent des campagnes d’évaluation ESTER2 [GALLIANO et al. 2009] et ETAPE [GRAVIER et al. 2012], et du projet EPAC [ESTÈVE et al. 2010]. Les corpus ESTER2 et EPAC contiennent des journaux d’information radiodiffusées en français (beaucoup de parole préparée) et le corpus ETAPE contient des débats et interview recueillis auprès de diverses chaînes de radio et de télévision françaises (parole spontanée). Ces données sont manuellement transcrites et ponctuées (la segmentation de la parole en phrases est donc donnée).

L’ensemble des questions et des affirmations a été extrait de ces corpus en filtrant les phrases qui se terminent par un point d’interrogation et, respectivement, par un point. Les ensembles d’apprentissage des corpus ESTER2, EPAC et ETAPE sont utilisés pour l’apprentissage des classifieurs de questions/affirmations ; les ensembles de développement et de test de corpus ESTER2 et ETAPE sont utilisés pour l’évaluation des classifieurs.

L’ensemble de données pour l’apprentissage contient 10K questions et 98K affirmations. Cependant, l’apprentissage des classifieurs binaires ne fonctionne pas bien quand les ensembles de données d’apprentissage sont mal équilibrés : les phrases de test sont susceptibles d’être classées dans la classe qui est représentée par le plus d’échantillons. Afin d’éviter ce biais d’apprentissage, nous avons choisi de ré-échantillonner les énoncés en gardant toutes les questions et en choisissant au hasard des sous-ensembles d’affirmations de même taille. Neuf ensembles différents de données d’apprentissage sont considérés sur la base des différentes listes aléatoires d’affirmations. Dans le chapitre des expériences, nous présentons principalement les performances moyennes (avec les écarts-types associés) obtenues avec les modèles appris sur les 9 ensembles d’apprentissage.

Les classifieurs questions/affirmations sont appris sur 10K questions et 10K affirmations, et évalués sur 972 questions et 7908 affirmations (cf. Tab. 12.3).

Données	#questions	#affirmations
d'apprentissage	10506	10506
d'évaluation	940	7708

TABLE 12.3 – Description des données utilisées dans nos expériences

12.3 Classifieurs

L'outil WEKA [HALL et al. 2009] est utilisé pour apprendre et évaluer les classifieurs questions / affirmations.

Le corpus d'apprentissage est représenté par un ensemble de données $D = \{\bar{X}_i, y_i\}$, $i = 1, \dots, N$ où : $\bar{X} = \langle x_1, x_2, \dots, x_p \rangle$ est un vecteur comprenant les paramètres sur l'énoncé à classifier, y indique l'appartenance à la classe "question" ($y = 1$) ou à la classe "affirmation" ($y = 0$) et N est le nombre d'énoncés dans le corpus d'apprentissage.

Dans nos expériences 5 algorithmes de classification ont été évalués. Dans un premier temps ils ont été considérés séparément. Ensuite nous avons combiné leurs sorties. Chaque classifieur fait une prédiction de classe (question ou affirmation) sur chaque énoncé de l'ensemble de données de test. La décision finale est alors prise par vote majoritaire : si la plupart des classifieurs (dans ce cas au moins trois) affectent l'énoncé à la classe des questions, alors l'énoncé est affecté à la classe des questions ; sinon, l'énoncé est affecté à la classe des affirmations.

Régression logistique (*logistic regression*, LR)

En général, la régression logistique [CESSIE et HOUWELINGEN 1992] est utilisée pour calculer la probabilité d'appartenance à une classe parmi deux en utilisant plusieurs variables prédictives :

$$P(1|\bar{X}, \alpha) = f(x) = \frac{1}{1 + \exp(-(\alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_p x_p))}$$

Les paramètres $\alpha = \langle \alpha_0, \alpha_1, \dots, \alpha_p \rangle$ sont déterminés par l'estimation du maximum de vraisemblance, qui se calcule en minimisant la fonction d'erreur :

$$E = - \sum_{i=1}^N (y_i \ln(f(\bar{X}_i)) + (1 - y_i) \ln(1 - f(\bar{X}_i)))$$

La minimisation est effectuée par la méthode de la descente du gradient. Cet algorithme d'optimisation numérique vise à obtenir un optimum (éventuellement local) par améliorations successives. A partir d'un point de départ α et une valeur initiale du pas de descente, les paramètres sont modifiés jusqu'à atteindre une condition d'arrêt (plus d'amélioration possible, nombre maximum d'itérations). Un seuil $\sigma \in [0, 1]$ permet de classifier les entrées comme questions ($f(x) \geq \sigma$) ou affirmations ($f(x) < \sigma$).

Dans l’outil WEKA ce seuil est par défaut égal à 0,5.

Arbre de décision basé sur l’algorithme C4.5 (J48)

L’arbre de décision J48 [QUINLAN 1993] est une solution ‘diviser pour régner’ (*divide-et-impera*) au problème de l’apprentissage à partir d’un ensemble d’exemples indépendants. Les nœuds dans un arbre de décision impliquent généralement une comparaison entre la valeur d’un attribut et une constante. Les nœuds feuilles donnent une classification pour toutes les instances qui répondent à toutes les conditions menant à cette feuille. Pour définir un arbre de décision il faut définir les conditions sur ses nœuds. L’attribut à choisir pour chaque nœud est celui qui divise le plus efficacement l’ensemble des échantillons en sous-ensembles représentant une des classes. Le critère de division sur les différentes valeurs de l’attribut A dans un exemple avec S entrées et n classes est le gain normalisé d’information :

$$gainRatio(S, A) = \frac{gain(S, A)}{splitInfo(S, A)}$$

où

$$gain(S, A) = entropie(S) - \sum_j \left(\frac{S_j}{S} \cdot entropie(S_j) \right)$$

$$entropie(S) = - \sum_{i=1}^n (p_i \cdot \log(p_i))$$

$$splitInfo(S, A) = - \sum_j \frac{S_j}{S} \cdot \log \left(\frac{S_j}{S} \right)$$

L’attribut A divise l’ensemble S en sous-ensembles S_j . La fraction S_j/S indique la proportion d’entrées présentes dans le sous-ensemble S_j par rapport au nombre total d’entrées. L’attribut avec le gain d’information le plus élevé est choisi pour prendre la décision.

Pour classifier une instance inconnue, ses valeurs d’attributs sont testées dans les nœuds successifs jusqu’à atteindre une feuille : l’instance est classée en fonction de la classe attribuée à cette feuille.

Règles JRip

Le classifieur JRip (*Repeated Incremental Pruning to produce error reduction*) [COHEN 1995] est basé sur des règles d’association qui utilisent la technique “*reduced error pruning*”. Ici les données disponibles sont divisées en deux sous-ensembles : un ensemble d’apprentissage et un ensemble de validation. Un ensemble initial de règles est défini seulement sur l’ensemble d’apprentissage. Ces règles sont ensuite augmentées et simplifiées à plusieurs reprises. Dans l’étape d’augmentation, une règle est développée en y ajoutant des antécédents jusqu’à ce qu’elle soit parfaite (précision à 100%). La procédure essaie toutes les valeurs possibles de chaque attribut et sélectionne la condition avec le gain d’information le plus élevé. Dans l’étape de simplification l’on choisit l’opérateur d’élagage (parmi tous les opérateurs d’élagage possibles) qui produit la plus grande réduction d’erreur sur l’ensemble de validation. La simplification se termine lorsque l’ap-

plication de tout opérateur d'élagage augmenterait l'erreur sur l'ensemble d'élagage. La règle ainsi simplifiée est ajoutée dans l'ensemble des règles. Tous les exemples couverts par cette règle sont supprimés. Ces étapes sont répétées jusqu'à ce que l'ensemble des données soit vide.

Méthode Adaboost M1 (AdaBoost)

Le classifieur AdaBoostM1 [FREUND et SCHAPIRE 1996] est basé sur une méthode de "boosting". L'algorithme définit à chaque étape $1 \leq t \leq T$ une nouvelle distribution D_t de probabilités a priori sur les exemples d'apprentissages en fonction des résultats de l'algorithme "faible" à l'étape précédente. Initialement, tous les exemples ont un poids identique, puis à chaque étape, les poids des exemples mal classés sont augmentés, forçant ainsi l'algorithme à se concentrer sur les exemples difficiles à classer. Chaque hypothèse h_t apprise est affectée d'un poids α_t mesurant l'importance qui sera donnée à cette hypothèse dans la combinaison finale.

Dans l'outil WEKA le classifieur "faible" est l'arbre de décision J48.

Réseau de neurones multi-couches (*multilayer perceptron*, MLP)

Le classifieur MLP [RUCK et al. 1990] est un réseau de neurones qui associe un ensemble de données d'entrée sur un ensemble de données de sorties approprié. Un MLP est constitué de plusieurs couches de nœuds dans un graphe orienté, chaque couche est entièrement reliée à la suivante. La couche d'entrée contient la liste des attributs utilisés pour la classification. La couche de sortie contient la liste des classes possibles. Plusieurs couches cachées peuvent être utilisées entre la couche d'entrée et la couche de sortie. Les poids associés à chaque attribut sont appris sur le corpus d'apprentissage, par rétro-propagation de la fonction d'erreur.

12.4 Configuration

Annotation avec classes grammaticales

L'annotation des phrases avec les classes grammaticales (POS) est réalisée avec l'outil TreeTagger [SCHMID 1994].

Fabrication de modèles de langage

Les modèles de langage n-grammes de questions et d'affirmations, basés sur des séquences de mots ou des séquences de classes grammaticales, sont appris avec l'outil SRILM [STOLCKE 2002]. Ces modèles sont utilisés pour le calcul des rapports de vraisemblance.

Analyse acoustique

Les valeurs de F0 en demi-tons et de l'énergie sont calculées toutes les 10 ms à partir du signal de parole en utilisant l'analyse acoustique ETSI / AURORA [ETSI ES 202 212 2005].

Alignement forcé et décodage de la parole

L'alignement forcé texte-parole est réalisé avec l'outil Sphinx [PLACEWAY et al. 1996]. Ceci permet d'obtenir la segmentation de la parole en mots et en phonèmes. Cette segmentation est ensuite utilisée pour calculer les durées des sons, ainsi que pour obtenir l'emplacement et la durée des pauses. Comme la qualité du signal de parole est plutôt bonne, nous pouvons supposer que la segmentation obtenue ne contient pas trop d'erreurs.

Les outils Sphinx sont également utilisés pour l'apprentissage de modèles acoustiques et pour le décodage de la parole. Plus d'informations sur le système de décodage grand vocabulaire utilisé dans nos expériences et son lexique associé peuvent être trouvées dans [JOUVET et FOHR 2013 ; JOUVET et LANGLOIS 2013].

Évaluation de classifieurs

La performance obtenue sur l'ensemble de données d'évaluation non équilibré (972 questions et 7908 affirmations) est évaluée par la moyenne harmonique entre le pourcentage de questions correctement classées et le pourcentage d'affirmations correctement classées :

$$\frac{1}{H} = \frac{1}{2} \times \left(\frac{1}{\text{questionsCC}} + \frac{1}{\text{affirmationsCC}} \right) \quad (12.1)$$

où "CC" est un acronyme pour "correctement classées".

Cette valeur nous permet d'estimer la performance globale de chaque classifieur, étant donné que les performances obtenues sur les questions et sur les affirmations sont tout aussi importantes.

Chapitre 13

Paramètres prosodiques et linguistiques

La détection de questions fait partie d'une étape de post-traitement ajoutée au système de reconnaissance vocale (cf. Fig. 13.1) : les paramètres prosodiques sont extraits du signal audio (en utilisant des informations sur les frontières de phrases et de phonèmes), les paramètres linguistiques sont extraits du message décodé (qui est susceptible de contenir des erreurs de reconnaissance sur les mots).




FIGURE 13.1 – Étape de post-traitement pour la détection de questions

L'approche mise en place implique la définition de différents types de paramètres prosodiques et linguistiques permettant de faire la différence entre les questions et les affirmations.

Sommaire

13.1 Paramètres prosodiques	102
13.2 Paramètres linguistiques	105

13.1 Paramètres prosodiques

Les classifieurs prosodiques ont l'objectif de détecter les phrases perçues comme des questions par le biais de l'intonation. Le choix des paramètres prosodiques résulte de l'avis général que les questions comportent une intonation finale montante.

La figure 13.2 présente la courbe de la fréquence fondamentale (F0) sur la phrase "c'est quoi ?".




FIGURE 13.2 – Courbe de la fréquence fondamentale (en haut) sur la phrase "c'est quoi ?"

Les caractéristiques prosodiques comprennent des informations liées à la durée, à l'énergie et à la fréquence fondamentale (F0). Deux ensembles de paramètres prosodiques sont considérés : un qui prend en compte la structure prosodique de la phrase et des informations a priori sur les locuteurs, et un autre qui est calculé sur différentes parties de la phrase.

13.1.1 Paramètres avec structure prosodique

Un premier ensemble d'expériences considère seulement les données issues des transcriptions manuelles de référence, donc des transcriptions en mots parfaites, des informations a priori sur les différents locuteurs et des frontières temporelles parfaites sur les phrases. Les frontières temporelles des mots et des phonèmes, obtenues par alignement forcé, sont supposées correctes. Dix paramètres prosodiques ont été utilisés afin de distinguer les questions des affirmations (voir Tab. 13.1) : cinq sont associés à la dernière syllabe de la phrase (avec des normalisations par rapport à son groupe prosodique) et cinq autres sont calculés sur la partie finale de la phrase. Les groupes prosodiques de la phrase sont déterminés à partir des informations linguistiques (pour grouper des mots grammaticaux avec les mots lexicaux correspondants) et des informations prosodiques, comme décrit dans [BARTKOVA et JOUVET 2013].

La durée de la dernière voyelle ($P0$) est calculée à partir de la segmentation phonétique résultant de l'alignement forcé. Son énergie ($P1$) correspond à la valeur moyenne calculée sur l'ensemble des trames de son segment. L'énergie et la durée de la voyelle sont ensuite normalisées par rapport aux valeurs moyennes calculées sur les autres voyelles du groupe prosodique courant. La pente F0 ($P2$) est calculée par régression linéaire sur les trames de parole correspondant à la voyelle. La différence du F0 par rapport à la voyelle précédente ($P3$) est aussi prise en compte. Le cinquième paramètre ($P4$) est le produit entre la pente du F0 et la durée de la voyelle au carré (ce paramètre est inspiré du seuil de glissando).

id.	description
P0	la durée de la dernière voyelle (normalisée)
P1	le logarithme de l'énergie de la dernière voyelle (normalisé)
P2	la pente F0 sur la dernière voyelle
P3	la différence du F0 entre la dernière voyelle et la voyelle précédente
P4	$P2 \times P0^2$
P5	la pente de F0 calculée sur la plus longue pente finale de F0
P6	la durée de la plus longue pente finale de F0
P7	la variation F0 entre le début et la fin de la plus longue pente finale de F0
P8	$P5 \times P6^2$
P9	la valeur F0 en fin de phrase (normalisée par locuteur)

TABLE 13.1 – Les paramètres prosodiques qui prennent en compte la structure prosodique de la phrase et des informations a priori sur les locuteurs (pour la normalisation)

D'autres paramètres, prosodiques, plus globaux, sont calculés sur la plus longue pente de F0 qui se termine dans la dernière syllabe de la phrase. A partir de la dernière syllabe, nous remontons dans le temps jusqu'à la détection d'une inversion de la pente de F0 (nommée "pente finale"). Les paramètres calculés sur cette partie du signal sont : la pente de F0 (déterminée par régression linéaire) (*P5*), la durée de ce segment (*P6*), la variation totale de F0 entre le début et la fin de la pente (*P7*), et également le produit entre la pente et le carré de la durée (*P8*). Un dernier paramètre prosodique (*P9*) correspond au niveau de F0 à la fin de la phrase, exprimé en pourcentage de la plage de F0 du locuteur courant (0 correspondant à la valeur la plus basse de F0 pour ce locuteur, 100 correspondant à la valeur la plus élevée de F0 pour ce locuteur).

13.1.2 Paramètres sur segment arbitraire

Des tests complémentaires ont été effectués en extrayant d'autres paramètres prosodiques sur la phrase entière, sur les dernières 700ms du signal ou sur les dernières 200ms du signal de la phrase. Ces tests n'utilisent aucune information a priori (sur les locuteurs ou autre) et n'effectuent donc pas des normalisations. Ils peuvent être appliqués sur des données transcrites manuellement (correctes) ou sur des données transcrites automatiquement (susceptibles de contenir des erreurs de mots).

Vingt-quatre paramètres prosodiques ont été utilisés afin de distinguer les questions des affirmations : deux paramètres généraux (la durée du segment et la vitesse d'élocution), quatre paramètres liés à l'énergie et 18 paramètres liés à la fréquence fondamentale (voir Tab. 13.2).

Les frontières temporelles de voyelles sont extraites des alignements forcés à partir des transcriptions manuelles ou à partir des variantes de prononciation des mots issus des transcriptions automatiques.

La durée de la phrase (C0) et la vitesse d'élocution (C1) servent comme indices pour identifier le type de parole, préparée ou spontanée. Dans la parole spontanée les phrases sont généralement plus courtes et prononcées plus rapidement.

id.	description
C0	la durée du segment (nombre de trames)
C1	la vitesse d'élocution (nombre de voyelles par seconde)
C2,C3	la moyenne et l'écart type des logarithmes des énergies des voyelles
C4	la pente des logarithmes des énergies
C5	la pente "finale" des logarithmes des énergies
C6	le nombre des trames ayant des valeurs F0 non-nulles
C7,C8	la moyenne et l'écart type des valeurs F0 (non-nulles) des voyelles
C9	la valeur F0 en fin de phrase (non nulle)
C10	la pente de F0
C11	la pente "finale" de F0
C12	la pente de F0 minimale (sur segment isolé)
C13	la pente de F0 maximale (sur segment isolé)
C14	le nombre de pentes de F0 ascendantes (sur segments isolés)
C15	le nombre de pentes de F0 descendantes (sur segments isolés)
C16	la moyenne des pentes de F0 ascendantes (sur segments isolés)
C17	la moyenne des pentes de F0 descendantes (sur segments isolés)
C18	la déviation moyenne des pentes de F0 (sur segments isolés)
C19	le nombre de pentes de F0 ascendantes (sur trames consécutives)
C20	le nombre de pentes de F0 descendantes (sur trames consécutives)
C21	la moyenne des pentes de F0 ascendantes (sur trames consécutives)
C22	la moyenne des pentes de F0 descendantes (sur trames consécutives)
C23	la déviation moyenne des pentes de F0 (sur trames consécutives)

TABLE 13.2 – Les paramètres prosodiques calculés sur la phrase entière, sur les dernières 700ms du signal ou sur les dernières 200ms du signal

Toutes les pentes sont calculées par régression linéaire (sur les valeurs non-nulles).

La pente "finale" de F0 est calculée sur le dernier segment de la phrase qui ne présente pas d'inversion de la pente de F0 : à partir de la dernière trame, nous remontons dans le temps jusqu'à la détection d'une inversion de la pente de F0. La pente "finale" des logarithmes des énergies est calculée sur le dernier segment de la phrase qui ne présente pas d'inversion de la pente des logarithmes des énergies.




FIGURE 13.3 – Exemple des segments "isolés" des fréquences fondamentales (F0)

Sept de nos paramètres prosodiques ($\{C12, C13, C14, C15, C16, C17, C18\}$) sont calculés sur des segments "isolés". Un segment est considéré comme étant "isolé" s'il est

entouré par des valeurs nulles. Dans l'exemple donné dans la figure 13.3 (question "c'est quoi ?" prononcée en 380ms), nous avons 2 segments isolés sur la fréquence fondamentale : [10, 17], [27, 38].

Nous avons calculé la pente de la fréquence fondamentale sur chacun des segments "isolés". Une pente est considérée comme ascendante si elle a une valeur positive, et descendante - si elle a une valeur négative. Seuls les pentes non-nulles sont considérées dans le calcul des paramètres. La déviation moyenne des pentes de F0 sur segments isolés (C18) est calculée comme la valeur moyenne des pentes en valeur absolue.




FIGURE 13.4 – Exemple de segments de trames consécutives pour la fréquence fondamentale (F0)

Les cinq derniers paramètres ({C19, C20, C21, C22, C23}) sont calculés sur des trames consécutives en ignorant les valeurs nulles. Sur la séquence de valeurs F0 non-nulles, nous considérons les segments qui ont des valeurs F0 ascendantes ou descendantes et nous ignorons les transitions d'un segment à l'autre.

Pour clarifier, l'exemple donné dans la figure 13.3 contient 38 trames, dont 18 trames ont associée une valeur F0 nulle ; la figure 13.4 affiche la suite des valeurs F0 non-nulles sur 20 trames, après l'enlèvement des valeurs F0 nulles. Nous identifions ensuite sur la séquence de valeurs F0 non-nulles tous les changements de direction (ascendante ou descendante) de valeurs F0 : entre les trame [2, 3], [7, 8], [9, 10], [14, 15], [16, 17]. Les segments sur lesquels sont calculés les derniers cinq paramètres prosodiques sont : [0, 2], [3, 7], [8, 9], [10, 14], [15, 16], [17, 19] (les transitions d'un segment à l'autre sont ignorées).

13.2 Paramètres linguistiques

Les classifieurs linguistiques ont l'objectif de détecter les phrases perçues comme questions par le biais de formes interrogatives. Trois paramètres linguistiques sont considérés dans notre étude.

13.2.1 Rapports de vraisemblance

Deux de nos paramètres linguistiques (*lexLLR* - *lexical log-likelihood ratio*, *synLLR* - *syntactic log-likelihood ratio*) sont représentés par le logarithme du rapport entre la vraisemblance d'une phrase par rapport au modèle de langage de questions et la vraisemblance de la phrase par rapport au modèle de langage d'affirmations [YUAN et JURAFSKY 2005] :

$$LLR(\text{phrase}) = \log \left(\frac{P(\text{phrase} | ML - \text{questions})}{P(\text{phrase} | ML - \text{affirmations})} \right) \quad (13.1)$$

Une phrase qui a une valeur *LLR* positive est susceptible d'être une question. Et vice-versa, une phrase ayant une valeur *LLR* négative est susceptible d'être une affirmation.

Pour calculer le rapport de vraisemblance lexical (*lexLLR*) d'une phrase, nous appliquons les modèles de langage lexicaux (de questions et d'affirmations) sur sa séquence de mots.

Pour calculer le rapport de vraisemblance syntaxique (*synLLR*) d'une phrase, nous appliquons les modèles de langage syntaxiques (de questions et d'affirmations) sur sa séquence de classes grammaticales (POS).

13.2.2 Présence de motifs interrogatifs

Le troisième paramètre linguistique (*iP* - *interrogative patterns*) indique la présence (1) ou l'absence (0) de motifs interrogatifs discriminatoires. Une phrase ayant un motif interrogatif est susceptible d'être une question.

Une liste de motifs interrogatifs a été extraite à partir des questions appartenant au corpus GigaWord avec une version modifiée de l'outil PrefixSpan [PEI et al. 2001] qui ne considère que des séquences consécutives de mots. Leur fréquences d'occurrence ont été ensuite comparées entre les transcriptions de questions et d'affirmations : les séquences ayant des fréquences similaires ont été ignorées. Les séquences sans aucun sens interrogatif ont été supprimées à la main (40 séquences).

La liste finale de motifs interrogatifs est : {quel, quelle, quels, quelles, comment, combien, pourquoi, est ce que, est ce qu', qu' est ce, qu' est ce que, qu' est ce qu' }.

Chapitre 14

Expérimentations

Trois types différents de paramètres sont étudiés : le classifieur basé uniquement sur des paramètres prosodiques, le classifieur basé uniquement sur des paramètres linguistiques et le classifieur combiné, basé sur des paramètres prosodiques et linguistiques. Différentes combinaisons de paramètres sont également analysées.

L'évaluation de classifieurs est faite sur des transcriptions manuelles et sur des sorties d'un système de reconnaissance vocale.

Les tests effectués sur des informations issues des transcriptions manuelles ont pour but d'évaluer la performance maximale pouvant être obtenue dans des conditions idéales (transcription parfaite, segmentation parfaite). Les paramètres linguistiques sont extraits à partir des transcriptions manuelles de signaux audio et les paramètres prosodiques - à partir de la segmentation phonétique résultant de l'alignement forcé. Des informations a priori sur les locuteurs sont extraites des annotations manuelles des signaux audio (disponibles dans les fichiers .STM), qui permettent de normaliser si besoin les valeurs de la fréquence fondamentale (F0) pour chaque locuteur.

Les tests effectués sur des informations issues des transcriptions automatiques, obtenues avec un système de reconnaissance grand vocabulaire, ont pour but d'évaluer la performance dans des conditions réelles. La détection de questions sur les transcriptions automatiques d'un système de reconnaissance vocale pose plusieurs problèmes : les transcriptions sont susceptibles de contenir des erreurs de reconnaissance sur les mots et les frontières de phrases sont susceptibles d'être mal placées. Si les frontières temporelles de phrases sont mal placées, certains mots peuvent manquer ou être en trop et les paramètres prosodiques seront calculés sur le mauvais segment. Dans la première série d'expériences (sections 14.1, 14.2, 14.3 et 14.4) nous considérons les frontières de phrases parfaites, telles que définies dans les transcriptions manuelles.

Sommaire

14.1	Utilisation des paramètres prosodiques	108
14.2	Utilisation des paramètres linguistiques	110
14.3	Utilisation des paramètres combinés	111
14.4	Comparaisons entre paramètres	113
14.5	Impact des frontières sur la performance	116

14.1 Utilisation des paramètres prosodiques

Les études sur les paramètres prosodiques analysent l'impact de la zone d'extraction et du jeu de paramètres. Le calcul des paramètres prosodiques utilise des informations liées aux frontières temporelles de la phrase et des voyelles, ce qui explique des analyses séparées sur des transcriptions manuelles et sur des transcriptions automatiques, et leur différence de performance.

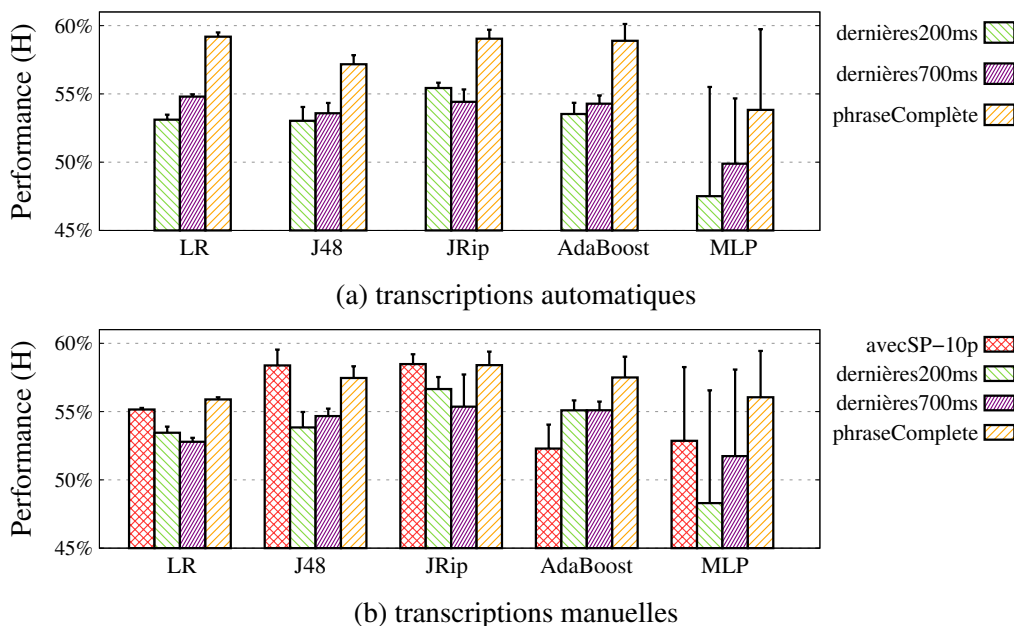


FIGURE 14.1 – Résultats (moyenne harmonique) obtenus en fonction des différentes zones d'extraction de paramètres prosodiques, lors de l'utilisation des transcriptions automatiques (a) ou des transcriptions manuelles (b)

Les résultats obtenus en fonction des différentes zones d'extraction de paramètres prosodiques sont présentés dans la figure 14.1. Dans nos expériences, un groupe de 10 paramètres prosodiques tient compte de la structure prosodique de la phrase et de l'identité des locuteurs ('avecSP-10p') et un autre groupe de 24 paramètres prosodiques est extrait sur la phrase entière ('phraseCompleète'), des dernières 700ms de la phrase ('dernières700ms') et des dernières 200ms de la phrase ('dernières200ms'). Les paramètres avec la structure prosodique ('avecSP-10p') sont calculés uniquement sur les transcriptions manuelles.

Les paramètres extraits sur les dernières 700ms de la phrase offrent de meilleures performances que les paramètres extraits sur les dernières 200ms de la phrase, avec les classifieurs J48, AdaBoost et MLP, quelque soit le type de transcriptions (manuelles ou automatiques). La performance du classifieur à base de réseaux de neurones (MLP) varie beaucoup en fonction des différents ensembles d'apprentissages, peu importe le type de paramètres prosodiques ou le type de données. Les paramètres qui prennent en compte des informations a priori sur les locuteurs et de la structure prosodique de la phrase ('avecSP-10p') donnent des résultats variables selon les différents classifieurs. La meilleure performance sur les transcriptions automatiques est acquise avec les paramètres prosodiques calculés sur la phrase complète. Dans les expérimentations suivantes, seuls les paramètres

extraits sur la phrase complète seront considérés.




FIGURE 14.2 – Performance (moyenne harmonique) obtenue avec les différents types de classifieurs en utilisant les paramètres prosodiques ‘phraseComplète’ sur les transcriptions automatiques et sur les transcriptions manuelles

Les performances moyennes des différents classifieurs sont affichées dans la figure 14.2. La meilleure performance obtenue avec les paramètres prosodiques sur les transcriptions automatiques est de 59,19% (classifieur LR) et sur les transcriptions manuelles - 58,40% (classifieur JRip).




FIGURE 14.3 – Impact du choix des paramètres prosodiques calculés sur la phrase complète, lors de l’utilisation du classifieur LR sur les transcriptions automatiques et du classifieur JRip sur les transcriptions manuelles

Diverses combinaisons des paramètres prosodiques (choisis ad-hoc ou avec l’algorithme de sélection ‘AttributeSelectedClassifier’ de WEKA) ont été évaluées dans le but de déterminer le meilleur choix de paramètres. Un sous-ensemble des résultats obtenus avec le classifieur LR sur transcriptions automatiques et avec le classifieur JRip sur transcriptions manuelles est présenté dans la figure 14.3. Les comportements sont différents entre les transcriptions automatiques et les transcriptions manuelles : les performances obtenues sur les transcriptions automatiques avec les divers choix de paramètres sont similaires et supérieures à l’utilisation des 24 paramètres (seule exception, la combinaison C{0,...,15,21}), alors que les performances obtenues sur les transcriptions manuelles varient beaucoup d’une combinaison à l’autre. Sur les transcriptions automatiques, les deux meilleures combinaisons de paramètres sont C{0,...,5,7,...,11,13,...,23} (H=59,61%) et C{0,...,4,8,...,11,13,...,15} (H=59,65%). Sur les transcriptions manuelles, les deux meilleures combinaisons de paramètres sont C{0,...,5,7,...,11,13,...,17} (H=59,02%) et C{0,...,15,C21} (H=58,87%). Pour faire un compromis entre les gains

obtenus sur transcriptions automatiques et les gains obtenus sur transcriptions manuelles, nous avons choisi d'utiliser la première combinaison de paramètres, $C\{0, \dots, 5, 7, \dots, 11, 13, \dots, 23\}$, qui conserve 22 paramètres (en ignorant les paramètres C6 - le nombre des trames ayant des valeurs F0 non-nulles, et C12 - la pente de F0 minimale sur segment isolé).

Une analyse plus détaillée des résultats obtenus avec le classifieur à base d'une régression logistique (LR) sur les transcriptions automatiques, en utilisant les 22 paramètres prosodiques appris sur le sixième ensemble d'apprentissage (sur lequel le classifieur atteignait la performance maximale) montre que 658 questions sur 940 et 4056 affirmations sur 7708 étaient correctement classées, ce qui correspond à des pourcentages de questions correctement classées de 70,00% et d'affirmations correctement classées de 52,62% (cf. Tab. 14.1). La moyenne harmonique correspondante est de $H=60,08\%$.

	nombre	classé comme question	classé comme affirmation	
question	940	658	282	questionsCC=70,00%
affirmation	7708	3652	4056	affirmationsCC=52,62%

TABLE 14.1 – Matrice de confusion question/affirmation obtenue avec le classifieur LR sur 22 paramètres prosodiques ('phrase Complète') extraits des transcriptions automatiques

14.2 Utilisation des paramètres linguistiques

Les performances obtenues avec nos 3 paramètres linguistiques sur les transcriptions automatiques et manuelles sont affichées dans la figure 14.4.




FIGURE 14.4 – Performance (moyenne harmonique) obtenue avec les différents classifieurs utilisant des paramètres linguistiques sur les transcriptions automatiques et sur les transcriptions manuelles

La différence de performance entre les transcriptions automatiques et les transcriptions manuelles est d'environ 5% en valeur absolue, en raison d'erreurs de reconnaissance (taux d'erreur mot de 22% sur ESTER2 et de 28% sur ETAPE) et probablement à la mauvaise reconnaissance de mots interrogatifs. Les meilleures performances moyennes sont obtenues avec le classifieur MLP sur les transcriptions automatiques ($H=66,92\%$) et avec le classifieur J48 sur les transcriptions manuelles ($H=71,21\%$).

Les performances moyennes obtenues avec le classifieur MLP sur les transcriptions automatiques et avec le classifieur J48 sur les transcriptions manuelles, en utilisant différentes combinaisons de paramètres linguistiques, montrent l'importance de conserver les trois paramètres (cf. Fig. 14.5). Le paramètre linguistique le plus important est le rapport de vraisemblance lexical (lexLLR), avec les motifs interrogatifs (iP) et le rapport de vraisemblance syntaxique (synLLR) fournissant des informations complémentaires.




FIGURE 14.5 – Impact du choix des paramètres linguistiques lors de l'utilisation du classifieur MLP sur les transcriptions automatiques et du classifieur J48 sur les transcriptions manuelles

Une analyse plus détaillée sur les résultats obtenus avec le classifieur MLP sur les transcriptions automatiques en utilisant des paramètres linguistiques appris sur le neuvième ensemble d'apprentissage (sur lequel le classifieur atteignait la performance maximale) montre que 671 questions sur 940 et 4921 affirmations sur 7708 étaient correctement classées, ce qui correspond à des pourcentages d'identification correcte de questions de 71,38% et d'affirmations de 63,84% (cf. Tab. 14.2). La moyenne harmonique est de $H=67,40\%$.

	nombre	classé comme question	classé comme affirmation	
question	940	671	269	questionsCC=71,38%
affirmation	7708	2787	4921	affirmationsCC=63,84%

TABLE 14.2 – Matrice de confusion question/affirmation obtenue avec le classifieur MLP sur les paramètres linguistiques extraits des transcriptions automatiques

14.3 Utilisation des paramètres combinés

Ces expériences sont basées sur un nouveau vecteur de paramètres regroupant les paramètres linguistiques et les paramètres prosodiques. Chaque phrase du corpus est donc représentée par un vecteur de 27 paramètres.

Les performances obtenues avec les 27 paramètres combinés sur les transcriptions automatiques et manuelles sont présentées dans la figure 14.6. La différence de performance entre les transcriptions automatiques et les transcriptions manuelles est d'environ 5% en valeur absolue. Les meilleures performances moyennes sont obtenues avec le classifieur JRip sur les transcriptions automatiques ($H=68,07\%$) et avec le classifieur LR sur les transcriptions manuelles ($H=72,34\%$).




FIGURE 14.6 – Performance (moyenne harmonique) obtenue avec les différents classifieurs combinés sur les transcriptions automatiques et manuelles

Diverses combinaisons des paramètres prosodiques et linguistiques (choisis ad-hoc ou avec l’algorithme de sélection ‘AttributeSelectedClassifier’ de WEKA) ont été évaluées dans le but de déterminer le meilleure choix de paramètres. Un sous-ensemble des résultats obtenus avec le classifieur JRip sur transcriptions automatiques et avec le classifieur LR sur transcriptions manuelles est présenté dans la figure 14.7. Dans les combinaisons évaluées, il apparaît qu’il est plus utile de conserver l’ensemble des 3 paramètres linguistiques (3L), plutôt qu’une sous-partie de ceux-ci.




FIGURE 14.7 – Impact du choix des paramètres (prosodiques et linguistiques) lors de l’utilisation du classifieur JRip sur les transcriptions automatiques et du classifieur LR sur les transcriptions manuelles

La meilleure performance obtenue sur les transcriptions automatiques correspond à l’utilisation des 27 paramètres prosodiques-linguistiques. La combinaison ‘3L & C{0,...,5,7,...,11,13,14,15,17,20,21}’ offre seulement une très légère amélioration en comparaison. Les différentes combinaisons de paramètres offrent des performances entre 72,26% et 72,81% sur les transcriptions manuelles, à comparer à la performance de 72,34% obtenue avec tous les paramètres. La meilleure performance est obtenue avec la deuxième combinaison de paramètres (3L & C{1,2,9,21}), mais cette combinaison dégrade la performance sur transcriptions automatiques. En revanche, la quatrième combinaison (3L & C{0,...,5,8,...,11,13,14,15,17,20}) offre une amélioration de 0,22 sur les transcriptions manuelles et pas de dégradation sur les transcriptions automatiques. Compte tenu des faibles améliorations obtenues avec les différentes combinaisons de paramètres, la totalité de paramètres sera conservée dans la suite des expériences.

Les résultats obtenus avec le classifieur JRip sur les transcriptions automatiques en utilisant des paramètres combinés appris sur le huitième ensemble d'apprentissage (sur lequel le classifieur atteignait la performance maximale) montre que 631 questions sur 940 et 5572 affirmations sur 7708 étaient correctement classées, ce qui correspond à des pourcentages de classification correcte de questions de 67,13% et d'affirmations de 72,29% (cf. Tab. 14.3). La moyenne harmonique est de $H=69,61\%$.

	nombre	classé comme question	classé comme affirmation	
question	940	631	309	questionsCC=67,13%
affirmation	7708	2136	5572	affirmationsCC=72,39%

TABLE 14.3 – Matrice de confusion question/affirmation obtenue avec le classifieur JRip sur les paramètres combinés extraits des transcriptions automatiques

La performance de ce système en termes de F-mesure (entre le rappel et la précision) est présentée dans le tableau F.1 en annexe. Le tableau F.2 en annexe indique la performance d'un système qui répond au hasard.

14.4 Comparaisons entre paramètres

Cette section a comme objectif de comparer les résultats obtenus avec les classifieurs utilisant des paramètres prosodiques (24 paramètres), linguistiques (3 paramètres) et combinés (27 paramètres).

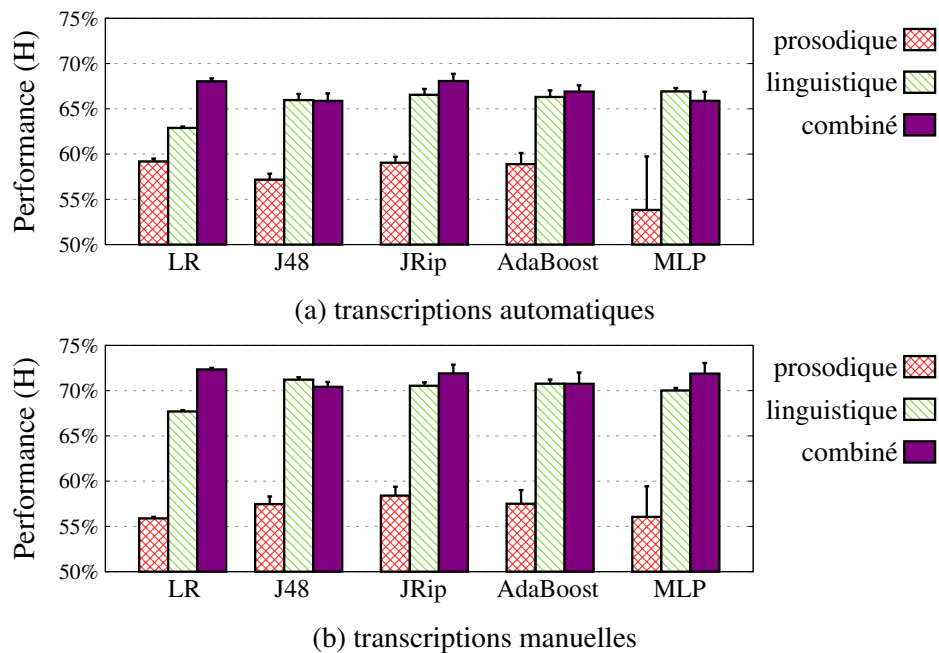


FIGURE 14.8 – Performance (moyenne harmonique) obtenue sur les transcriptions automatiques (a) et sur les transcriptions manuelles (b), lors de l'utilisation des paramètres prosodiques, linguistiques et combinés

La figure 14.8 présente les résultats obtenus avec les cinq algorithmes de classification lors de l'utilisation de paramètres prosodiques, linguistiques et combinés sur les transcriptions manuelles et sur les transcriptions automatiques. Les classifieurs prosodiques sont surpassés par les classifieurs linguistiques, qui sont surpassés par les classifieurs combinés (seules exceptions le classifieur J48 - peu importe le type de données, et le classifieur MLP - sur les transcriptions automatiques). Les écarts de performance obtenues avec les 3 types différents de paramètres varient en fonction du classifieur et des données traitées (manuelles ou automatiques).

Données d'évaluation	#questions	#affirmations
ESTER2	176	2163
ETAPE	764	5545
ESTER2 & ETAPE	940	7708

TABLE 14.4 – Description des données d'évaluation par sous corpus

Pour rappel, les différents classifieurs sont évalués sur les ensembles d'évaluation et de test de corpus ESTER2 et ETAPE, qui contiennent un total de 940 questions et 7708 affirmations. Dans la suite de cette section nous allons détailler les performances obtenues séparément sur le corpus ESTER2 et sur le corpus ETAPE.

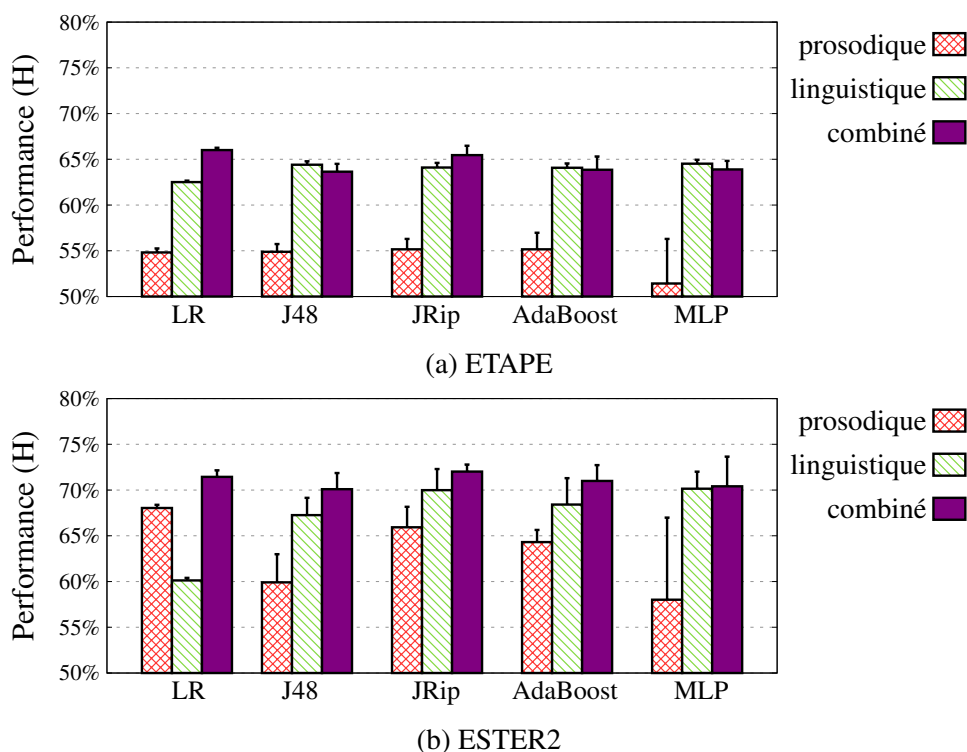


FIGURE 14.9 – Performance (moyenne harmonique) obtenue avec les différents classifieurs sur les transcriptions automatiques du corpus ETAPE (a) et du corpus ESTER2 (b)

Les performances de classification obtenues sur les transcriptions automatiques d'ESTER2 (discours préparé) et d'ETAPE (parole spontanée) sont présentées dans la figure

14.9. Les données appartenant à ESTER2 (performance moyenne de 72% avec le classifieur JRip) sont plus faciles à classer que les données appartenant à ETAPE (performance moyenne de 66% avec le classifieur LR).

Les performances moyennes (moyenne harmonique, taux de questions correctement classées, taux d'affirmations correctement classées) obtenues sur les données appartenant au corpus ETAPE et au corpus ESTER2, lors de l'utilisation des paramètres prosodiques, linguistiques ou combinés sont présentées dans la figure 14.10 (plus de détails dans les tableaux F.3, F.4 en annexe).

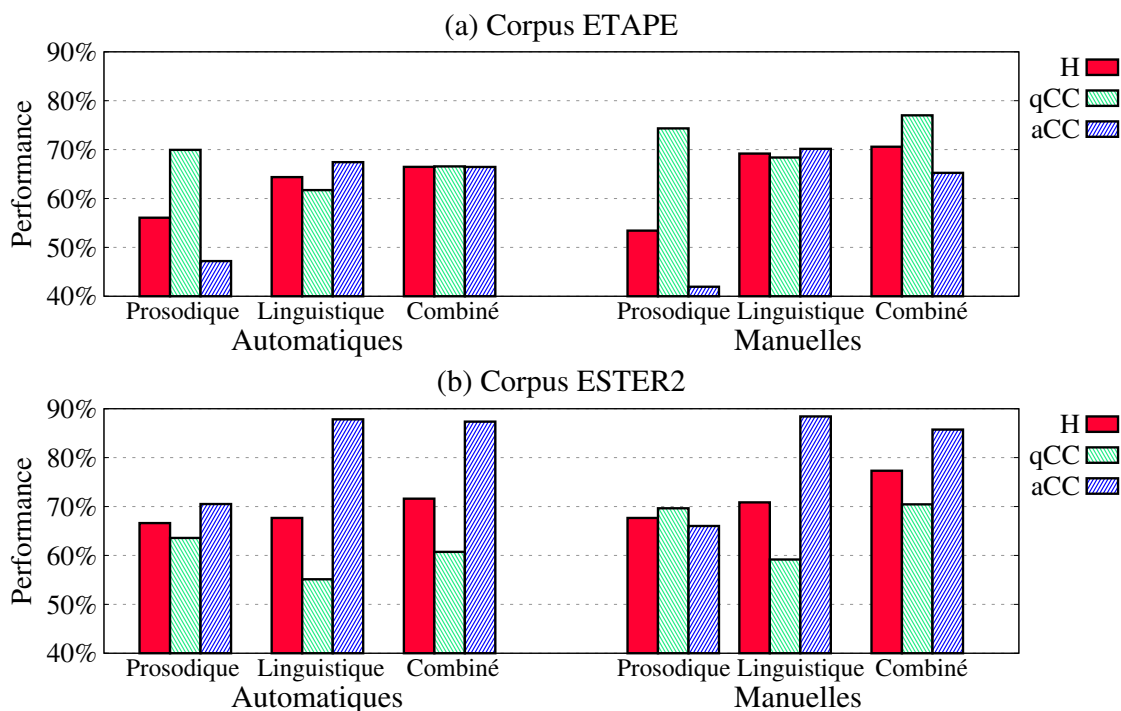


FIGURE 14.10 – Performances moyennes (moyenne harmonique H, taux de questions correctement classées qCC, taux d'affirmations correctement classées aCC) obtenues avec la combinaison de 5 algorithmes de classification par vote majoritaire sur les transcriptions automatiques et sur les transcriptions manuelles appartenant au corpus ETAPE (a) et au corpus ESTER2 (b)

Les évaluations sont effectuées avec la combinaison des 5 algorithmes de classification par vote majoritaire (qui définit le comportement global des 5 algorithmes). Sur le corpus ETAPE, les paramètres prosodiques ont une meilleure performance sur les questions, le taux d'affirmations correctement classés étant inférieur à 50%. Sur le corpus ESTER2, les paramètres linguistiques et combinés ont une meilleure performance sur les affirmations, le taux de questions correctement classés étant généralement inférieur à 60% (seule exception avec les paramètres combinés sur transcriptions manuelles).

Les paramètres combinés donnent des meilleures performances que les paramètres prosodiques ou les paramètres linguistiques, quelque soit le corpus de parole (ESTER2 ou ETAPE) ou le type de données (manuelles ou automatiques). De plus, l'utilisation des paramètres combinés réduit l'écart de performance entre les résultats obtenus sur questions et les résultats obtenus sur affirmations.

14.5 Impact des frontières sur la performance

Pour évaluer la perte de performance lorsque les frontières des phrases ne sont pas parfaites, nous avons modifié les frontières prédéfinies des phrases pour simuler des erreurs introduites par une segmentation automatique, de trois façons différentes :

- en décalant chaque frontière (gauche ou droite) avec une valeur choisie aléatoirement de $\{-300, -200, -100, +100, +200 \text{ ou } +300\}$ ms. Si le nouveau segment contient que des silences/bruits ou il est absent dans la transcription automatique, la phrase est ignorée dans cette évaluation (6% de questions et 4% d'affirmations)
- en décalant chaque frontière (gauche ou droite) avec une valeur choisie aléatoirement de $\{-1000, -800, -600, -400, -200, +200, +400, +600, +800 \text{ ou } +1000\}$ ms. Si le nouveau segment contient que des silences/bruits ou il est absent dans la transcription automatique, la phrase est ignorée dans cette évaluation (8% de questions et 4% d'affirmations)
- en extrayant le plus long segment délimité par des silences : le segment de référence est étendu avec les 5 unités précédentes (mots, silences et/ou bruits) et les 5 unités suivantes (mots, silences et/ou bruits) ; on cherche ensuite dans ce segment étendu le premier et le dernier segment de silence qui vont définir les nouvelles frontières de la phrase : la frontière gauche est le temps de fin du premier segment de silence et la frontière droite est le temps de début du dernier segment de silence. En fonction de la position de ces segments de silence, la phrase de référence va être étendue (silences à l'extérieur de la phrase) ou rétrécie (silences à l'intérieur de la phrase). Si les segments de silence recherchés sont absents dans le segment étendu, la phrase est ignorée dans cette évaluation (0.5% de questions et 0.3% d'affirmations)

La perte de performance de classification lors de la modification des frontières prédéfinies des phrases sur les transcriptions automatiques est évalué dans la figure 14.11.




FIGURE 14.11 – Performance (moyenne harmonique) obtenue avec le classificateur JRip sur les transcriptions automatiques lors de la modification des frontières prédéfinies

Le classifieur prosodique est le plus dépendant de la position des frontières, sa perte de performance atteint jusqu'à 23,82% sur les segments délimités par des silences. Avec le classifieur linguistique, la perte de performance varie entre 2,15% (aléatoire ± 300 ms) et 3,93% (frontières de silences). Le classifieur linguistique dépasse même la performance du classifieur combiné sur les segments délimités par des silences. Avec le classifieur combiné, la perte de performance varie entre 2,54% (en modifiant les frontières prédéfinies avec une valeur aléatoire de ± 300 ms) et 7,79% (en remplaçant la phrase avec un

segment délimité par des silences). Ces résultats montrent l'importance de bien définir les frontières de phrases pour la tâche de la détection de questions. Cependant, pour des petites variations dans les frontières prédéfinies ($\pm 300\text{ms}$, $\pm 1000\text{ms}$), notre classifieur parvient toujours à classer correctement 65% d'entrées questions / affirmations.

Une dernière expérience a consisté à combiner les sorties des cinq algorithmes de classification, en utilisant les 27 paramètres prosodiques-linguistiques. Les performances moyennes (H) obtenues avec les cinq classifieurs séparément, et avec leur combinaison (par vote majoritaire) sont présentés dans le tableau 14.5. La performance du vote majoritaire dépasse légèrement celle des 5 classifieurs sur les transcriptions manuelles et sur les transcriptions automatiques avec des frontières prédéfinies ou modifiées de manière aléatoire (avec un gain de performance entre 0,36% et 0,92%). Les classifieurs J48, JRip et AdaBoost ont une meilleure performance comparée à celle du vote majoritaire sur les transcriptions automatiques délimitées par des silences.

Classifieur	manuelles	automatiques			
		frontières prédéfinies	aléatoire +/-300ms	aléatoire +/-1000ms	frontières silence
LR	72,34	68,04	64,91	62,81	50,07
J48	70,42	65,87	63,78	62,35	60,77
JRip	71,91	68,07	65,53	64,03	60,28
AdaBoost	70,75	66,91	63,84	62,73	63,17
MLP	71,88	65,88	63,16	61,91	56,81
vote majoritaire	73,26	68,69	65,89	64,89	58,96

TABLE 14.5 – Performance (moyenne harmonique) obtenue avec les 5 classifieurs et avec leur combinaison (par vote majoritaire) sur les transcriptions manuelles et automatiques

Chapitre 15

Conclusions

Cette partie a analysé la détection de la modalité des phrases (questions versus affirmations) en français à partir de transcriptions manuelles ou automatiques. Les personnes sourdes ou malentendantes ont besoin d'une détection automatique de questions afin d'être informées qu'une question leur a été posée et qu'ils doivent répondre ou demander des clarifications.

Pour répondre à ce défi, des paramètres prosodiques ont été extraits à partir du signal audio (en utilisant des informations sur les frontières de phrases et de phonèmes), et des paramètres linguistiques à partir de transcriptions (manuelles ou automatiques) en mots. Plusieurs approches ont été analysées : la création d'un classifieur avec seulement des paramètres prosodiques, d'un classifieur avec seulement des paramètres linguistiques ou d'un classifieur qui combine les deux types d'information.

Plusieurs jeux de paramètres prosodiques ont été évalués dans nos expériences, les deux meilleurs ensembles étant présentés dans ce document : un ensemble de 10 paramètres qui tient compte du dernier groupe prosodique de la phrase (calculé seulement sur des données manuelles, avec des transcriptions de mots parfaites, des informations a priori sur les différents locuteurs et des frontières temporelles parfaites sur les phrases et sur les phonèmes) et un autre ensemble de 24 paramètres qui est calculé sur des portions arbitraires de la phrase (phrase complète, dernières 700ms du signal, dernières 200ms du signal). La meilleure performance est acquise avec les paramètres prosodiques calculés sur la phrase complète. Cet ensemble contient deux paramètres généraux (la durée de la phrase et la vitesse d'élocution), quatre paramètres liés à l'énergie (la moyenne et l'écart type des logarithmes des énergies des voyelles, la pente globale et la pente finale des logarithmes des énergies) et 18 paramètres liés à la fréquence fondamentale (le nombre des trames ayant des valeurs F0 non-nulles, la moyenne et l'écart type des valeurs F0 non-nulles sur les voyelles, la dernière valeur F0 non nulle, la pente globale et la pente finale des valeurs F0, 7 paramètres concernant les pentes de F0 ascendantes ou descendantes calculés sur segments isolés, 5 paramètres concernant les pentes de F0 ascendantes ou descendantes calculés sur des trames consécutives ignorant les valeurs F0 nulles). Cependant, les résultats de classification sont mitigés, la performance obtenue sur les transcriptions automatiques étant inférieure à 60%.

Trois paramètres linguistiques ont été considérés dans nos expériences : les n-grammes de mots, les n-grammes de classes grammaticales et la présence ou l'absence des motifs

interrogatifs. Le paramètre linguistique le plus utile est fourni par les n-grammes de mots. Cependant, la performance est fortement améliorée avec le complément d'information fourni par les motifs interrogatifs et par les n-grammes de classes grammaticales.

La combinaison de paramètres prosodiques et linguistiques offre la meilleure performance de classification : une moyenne de 72.34% sur les transcriptions manuelles et de 68,07% sur les transcriptions automatiques. L'essentiel de l'information pour la détection de la modalité des énoncés provient du contenu linguistique de l'énoncé, en particulier lorsque l'on applique les détecteurs sur des transcriptions manuelles. Lorsque l'on se place dans un contexte applicatif, où la détection exploite les sorties de la reconnaissance, la performance des paramètres linguistiques baisse, et la prosodie apporte un complément d'information significatif.

Une analyse séparée sur les données appartenant au corpus ESTER2 (parole préparée) et au corpus ETAPE (parole spontanée) prouve que les données appartenant à ESTER2 (performance moyenne de 77% sur transcriptions manuelles, 72% sur transcriptions automatiques) sont plus faciles à classer que les données appartenant à ETAPE (performance moyenne de 71% sur transcriptions manuelles, 66% sur transcriptions automatiques). Le taux d'affirmations correctement classées est bien supérieur au taux de questions correctement classées lors de l'utilisation des paramètres linguistiques ou combinés sur le corpus ESTER2. L'écart de performance entre questions et affirmations diminue sur le corpus d'ETAPE.

Une étude complémentaire a été menée sur les transcriptions automatiques afin de déterminer la perte de performance lorsque les frontières de phrases ne sont pas parfaites. Les frontières prédéfinies ont été modifiées aléatoirement ou en fonction des segments de silence/bruit. La perte de performance du classifieur combiné varie entre 2,54% et 7,79%. Ces résultats montrent l'importance de bien définir les frontières de phrases pour la tâche de la détection de questions.

Le choix du classifieur utilisé dans le système du projet sera fait en fonction des contraintes éventuelles d'implémentation et des performances souhaitées (taux plus élevé d'affirmations correctement classées, taux plus élevé de questions correctement classées ou taux d'affirmations correctement classées similaire au taux de questions correctement classées).

Toutes ces analyses montrent les comportements des différents classifieurs sur des corpus de parole d'émissions radio ou télévisées. Ces données (beaucoup de parole préparée) ne sont pas en parfaite adéquation avec notre objectif (détecter des questions dans des interactions spontanées), mais leurs résultats nous donnent une idée des performances possibles. D'autres tests seront effectués dans la suite du projet, ils permettront d'évaluer la performance réelle du système et de l'améliorer. Des entretiens avec des personnes sourdes permettront également de déterminer l'impact de fausses détections sur la compréhension du message transcrit.

Conclusions et perspectives

Conclusions

Partie intégrante du projet RAPSODIE, dont l'objectif était le développement d'une nouvelle génération de terminaux intégrant une reconnaissance vocale spécialisée sur les besoins des personnes sourdes et malentendantes, cette thèse a réalisé plusieurs études sur l'extraction d'informations lexicales et para-lexicale à partir du signal de parole.

Au début du projet, le système de reconnaissance automatique de la parole se voulait entièrement embarqué. Ceci nous avait conduit à étudier l'optimisation des modèles lexicaux du système, dans le but de trouver le meilleur compromis entre la taille du modèle et sa performance. La contrainte sur la taille des modèles surgit du fait que les systèmes embarqués ont des capacités calcul et mémoire limitées (qui impactent le temps de réponse).

Nous nous sommes donc premièrement intéressés à la comparaison de différentes approches de décodage phonétique. Différentes unités lexicales ont été évaluées, comme les phonèmes et les mots, et nous avons proposé l'utilisation des syllabes (déterminées à partir des prononciations réelles). Ces travaux ont fait ressortir l'intérêt des modèles syllabiques qui, pour un faible encombrement mémoire (8 100 unités syllabiques) et un faible coût en calculs, donnaient de bonnes performances de décodage phonétique (un taux d'erreur phonétique inférieur de seulement 4% à celui obtenu avec le modèle de langage grand vocabulaire). Cependant, une reconnaissance en syllabe nécessite des efforts supplémentaires de la part du lecteur pour regrouper les différentes syllabes en mots porteurs de sens. De plus, des entretiens effectués avec des personnes sourdes ont révélé l'intérêt d'une reconnaissance en mots, cette solution étant plus simple à appréhender. D'un autre côté, le choix d'un modèle de langage à base de mots qui est contraint par sa taille implique une limitation du nombre de mots conservés dans le modèle, ce qui augmente évidemment le nombre de mots inconnus par le système. Si nous utilisons un modèle de langage basé strictement sur des mots avec une faible quantité de mots au sein du modèle, l'application de ce modèle dans un nouveau domaine (présentant un grand nombre de mots inconnus) va générer beaucoup d'erreurs de reconnaissance : les segments de parole hors vocabulaire sont typiquement transcrits par une suite des petits mots du lexique. Il est donc important de pouvoir traiter les mots hors vocabulaire.

Cela nous a amené à combiner des mots et des syllabes dans un seul modèle de langage, dit hybride. La partie en mots est choisie pour être la plus pertinente possible (mots les plus fréquents dans un corpus donné), et la taille du vocabulaire est ajustée en fonction des ressources disponibles pour le décodage. L'inclusion de syllabes dans le modèle de

reconnaissance permet d'approximer les prononciations de mots hors-vocabulaire lors du décodage, et d'éviter ainsi que ces mots génèrent systématiquement des erreurs (confusions avec d'autres mots du lexique). Il faut également préciser que nous voulons modéliser les suites de sons (avec une solution qui prenne en compte la prononciation ou non du e-muet ou des phonèmes de liaison) pour mieux représenter les prononciations effectives, dans le but de maximiser la compréhension de la transcription résultante pour la communauté de personnes sourdes. Cela explique notre choix de fabriquer des modèles de langage hybrides basés sur la transcription de prononciations de parole (au niveau mots, et au niveau phonèmes en passant par un alignement forcé). Le taux d'erreur phonétique des modèles hybrides n'est que légèrement plus mauvais que le taux d'erreur obtenu avec le système de reconnaissance grand vocabulaire (2%).

Les mesures de confiance ont également été évaluées en adéquation avec le mode d'affichage choisi : notre approche est de conserver les mots ayant une bonne probabilité d'être corrects (pour maximiser la compréhension du message) et de remplacer les autres avec une suite de phonèmes ou de syllabes. Le meilleur choix du seuil sur la mesure de confiance de mots reste à ajuster par la suite en effectuant des tests sur la version finale du produit. Nous avons également étudié les mesures de confiance sur les syllabes, mais elles sont pertinentes seulement s'il existe une quantité relativement importante de syllabes dans le corpus d'apprentissage. Cependant, une quantité importante de syllabes dans le corpus implique une quantité faible de mots. Un essai pour mieux modéliser les syllabes à l'intérieur d'un modèle hybride en conservant en même temps une quantité importante de mots a consisté à interpoler deux modèles de langage hybrides : un modèle offrant une bonne couverture des mots et un autre modèle offrant une bonne couverture des syllabes. Les mesures de confiance sur les syllabes ne sont toujours pas pertinentes avec le modèle interpolé ; cependant, les taux de syllabes correctement reconnues et de mots hors-vocabulaire reconnus par des syllabes obtenus avec le modèle interpolé sont supérieurs à celui du premier modèle.

Dans le contexte du projet, il est aussi nécessaire de pouvoir ajouter de nouveaux mots dans le modèle de langage, afin d'assurer une bonne reconnaissance des mots spécifiques à un certain domaine (par exemple mots utiles dans un magasin de bricolage, qui est le contexte applicatif choisi dans le projet pour la validation et l'expérimentation ; et aussi pour pouvoir tenir compte de l'arrivée de nouveaux produits ou services). L'ajout de nouveaux mots doit pouvoir se faire sans ré-apprentissage ni adaptation du modèle de langage (qui sont des traitements qui nécessitent beaucoup de données). Nous avons donc proposé et évalué une nouvelle approche pour l'ajout de nouveaux mots qui est basée sur un principe de similarité entre mots. Formellement, la recherche de similarité entre deux mots se traduit par un calcul de divergence entre les distributions des mots prédécesseurs et des mots successeurs. L'approche implique plusieurs étapes : utiliser quelques phrases exemples pour le nouveau mot, chercher des mots connus (du modèle de langage) similaires au nouveau mot, puis définir les n-grammes associés à ce nouveau mot à partir des n-grammes des mots similaires. Les évaluations ont montré que notre approche basée sur la similarité entre mots et notre méthode d'ajouter de nouveaux n-grammes dans un modèle de langage sont efficaces. L'ajout de n-grammes (1-grammes, 2-grammes

et 3-grammes) pour les nouveaux mots fournit une amélioration absolue de 1,3% sur le taux d'erreur mot (par rapport au modèle baseline) et permet de reconnaître correctement 69% des nouveaux mots. De bonnes performances sont obtenues avec la sélection de peu de mots similaires pour chaque nouveau mot et avec un nombre raisonnable (20 à 50) de phrases exemples pour les nouveaux mots. L'utilisation de seulement quelques mots similaires limite aussi la taille des nouveaux modèles de langage.

La dernière étude a porté sur l'extraction d'informations complémentaires, para-lexicales, importantes pour la communication inter-personnes. Nous nous sommes intéressés principalement à la détection des questions et des affirmations, visant à enrichir la communication avec les personnes sourdes ou malentendantes, de manière à leur signaler quand une question leur a été adressée, car, dans ces cas, ils doivent répondre ou demander des précisions supplémentaires. Dans notre étude, plusieurs approches ont été analysées : la création d'un classifieur avec seulement des paramètres prosodiques (extraits du signal audio), d'un classifieur avec seulement des paramètres linguistiques (extraits des séquences de mots et des séquences de classes grammaticales) ou d'un classifieur qui combine les deux types d'information. Les 24 paramètres prosodiques incluent deux paramètres généraux (la durée de la phrase et la vitesse d'élocution), quatre paramètres liés à l'énergie et 18 paramètres liés à la fréquence fondamentale. Les 3 paramètres linguistiques incluent les n-grammes de mots, les n-grammes de classes grammaticales et la présence ou l'absence des motifs interrogatifs.

L'évaluation de classifieurs est effectuée en utilisant des paramètres linguistiques et prosodiques extraits à partir de transcriptions automatiques (pour étudier la performance dans des conditions réelles) et de transcriptions manuelles (pour étudier la performance dans des conditions idéales, c'est-à-dire quand il n'y a pas d'erreurs de mots). La combinaison de paramètres prosodiques et linguistiques offre la meilleure performance de classification : une moyenne de 72,34% sur les transcriptions manuelles et de 68,07% sur les transcriptions automatiques. L'essentiel de l'information pour la détection de la modalité des énoncés provient du contenu linguistique de l'énoncé, en particulier lorsque l'on applique les détecteurs sur des transcriptions manuelles. Lorsque l'on se place dans un contexte applicatif, où la détection exploite les sorties de la reconnaissance, la performance des paramètres linguistiques baisse, et la prosodie apporte un complément d'information significatif.

Une analyse séparée sur les données appartenant au corpus ESTER2 (parole préparée) et au corpus ETAPE (parole spontanée) prouve que les données appartenant à ESTER2 (performance moyenne de 77% sur transcriptions manuelles, 72% sur transcriptions automatiques) sont plus faciles à classer que les données appartenant à ETAPE (performance moyenne de 71% sur transcriptions manuelles, 66% sur transcriptions automatiques).

Une étude complémentaire a été menée sur les transcriptions automatiques afin de déterminer la perte de performance lorsque les frontières de phrases ne sont pas parfaites. Les résultats ont montré l'importance de bien définir les frontières de phrases pour la tâche de la détection de questions, la perte de performance du classifieur combiné variant entre 2,54% et 7,79%.

Perspectives

Les modèles de langage hybrides considérés pour une version embarquée du système de reconnaissance ont des tailles allant de 1K mots et 6K syllabes (par rapport aux mots vus au moins 300 fois dans le corpus d'apprentissage) jusqu'à 31K mots et 2K syllabes (par rapport aux mots vus au moins 3 fois dans le corpus d'apprentissage). Des modèles de type hybride avec de plus grands vocabulaires peuvent être utilisés dans le cadre d'une reconnaissance vocale à distance ; dans tous les cas la taille du lexique est finie et il y aura toujours des mots hors-vocabulaires à traiter. L'apprentissage de nos modèles hybrides était fait à partir des des transcriptions manuelles après un alignement forcé, pour bénéficier d'une meilleure représentation concernant la prononciation ou non des e-muets, et des liaisons. Cependant, les corpus de parole manuellement transcrites ne sont pas faciles à trouver. Donc, une piste à étudier consiste à utiliser des données de parole transcrites manuellement et des données purement textuelles pour un meilleur apprentissage de grands modèles hybrides de mots et de syllabes.

L'augmentation de la quantité des syllabes dans le corpus d'apprentissage devrait également être étudiée, pour améliorer encore le taux de syllabes correctement reconnus, le taux de mots hors-vocabulaire reconnus par des syllabes et les mesures de confiance calculés sur les syllabes. Les problématiques à traiter concernent donc les moyens de passer du texte à une phonétisation représentative de prononciations, de gérer les e-muets et les liaisons, et de combiner les données transcrites manuellement avec des données de texte.

Les données utilisées dans nos expériences sur la détection de questions (beaucoup de parole préparée) ne sont pas en parfaite adéquation avec notre objectif (détecter des questions dans des interactions spontanées), mais leurs résultats nous donnent une idée des performances possibles. D'autres évaluations sur des corpus de parole spontanées correspondant à des dialogues permettront d'évaluer la performance réelle du système et de l'améliorer. Des entretiens avec des personnes sourdes permettront également de déterminer l'impact de fausses détections sur la compréhension du message transcrit.

Les configurations pour trouver des mots similaires pour un nouveau mot peuvent être davantage étendues, en utilisant d'autres types d'information (la lemme du mot, le tag morphologique, des classes grammaticales plus étendues, des classes grammaticales plus restreintes, un autre nombre de voisins), voire d'autres mesures de similarité entre mots.

La combinaison d'informations peut également être envisagée :

$$D(kW, nW) = \lambda_1 * D_{word}(kW, nW) + \lambda_2 * D_{lemme}(kW, nW) + \lambda_3 * D_{tag}(kW, nW) + \dots$$

en associant des poids aux différentes distributions de voisins (en fonction des phrases à base de mots, des phrases à base d'unités 'mot|lemme', des phrases à base d'unités 'mot|classeGrammaticale', ...).

L'utilisation d'un nombre plus petit (inférieur à 5) de mots similaires peut également impacter la performance du nouveau modèle. Les n-grammes de nouveaux mots peuvent également être filtrés afin de diminuer la taille des nouveaux modèles de langage.

La technique proposée pour l'ajout de mots vise à inférer des n-grammes à partir de peu d'exemples en se basant sur des mots similaires. Cette approche pourrait être aussi appliquée pour l'amélioration des modèles de langage habituels, en estimant de nouveaux n-grammes pour les mots peu fréquents dans le corpus textuel d'apprentissage.

La performance du classifieur question/affirmation basé sur des paramètres linguistiques diminue fortement lorsqu'il est appliqué sur des transcriptions automatiques. Pour éviter ce problème, il pourrait être utile de prendre en compte les mesures de confiance sur les mots, soit directement dans le classifieur, soit pour ignorer les mots ayant une mesure de confiance inférieure à un seuil.

Annexes

A	Modèles de langage	129
B	Unités phonétiques	133
C	Outil de syllabation	135
D	Choix de mots similaires	137
E	Nouveaux modèles de langage	141
F	Classification question / affirmation	143

Annexe A

Modèles de langage

Cette annexe précise quelques informations complémentaires sur les modèles de langage utilisés dans nos expériences.

Pour les modèles de langage qui suivent, le nombre total des 1-grammes inclut les silences du début et fin de phrase (<s>, </s>) et le tag d'unités inconnus (<unk>).

Le tableau A.1 précise le nombre de 1-grammes, 2-grammes et 3-grammes de nos différents modèles de langage phonétique, syllabiques et grand vocabulaire utilisés pour la reconnaissance de la parole.

Unité lexicale	#1-grammes	#2-grammes	#3-grammes	Taille [Mo]	
phonèmes	40	1 343	29 978	0,2	
syllabes	min1occ	15 189	383 334	1 722 060	11,0
	min2occ	10 131	374 292	1 717 704	11,0
	min3occ	8 257	368 364	1 713 972	9,9
	min4occ	7 203	363 735	1 710 783	9,9
	min5occ	6 521	359 969	1 707 915	9,8
	min10occ	4 788	345 955	1 695 222	9,6
	min25occ	3 341	323 375	1 6695 34	9,3
	min50occ	2 492	299 003	1 635 204	9,0
	min100occ	1 868	269 077	1 582 665	8,5
	min200occ	1 358	230 094	1 496 118	7,9
min300occ	1 116	205 132	1 427 356	7,4	
mots	97 349	43 345 766	79 304 678	1300,0	

TABLE A.1 - Modèles de langage phonétique, syllabiques, grand vocabulaire

Le tableau A.2 précise le nombre de 1-grammes, 2-grammes et 3-grammes de nos différents modèles de langage hybrides de mots et syllabes utilisés pour la reconnaissance de la parole.

Filtre	#1-grammes	#2-grammes	#3-grammes	Taille [Mo]
min3occ	33 717 #mots=31 425 #syl=2 289	710 462	1 861 584	14
min4occ	29 281 #mots=26 444 #syl=2 834	702 195	1 870 166	14
min5occ	26 367 #mots=23 150 #syl=3 214	694 775	1 875 784	14
min10occ	19 189 #mots=15 127 #syl=4 059	663 331	1 886 481	14
min25occ	12 987 #mots=8 232 #syl=4 752	606 745	1 882 162	13
min50occ	10 077 #mots=4 931 #syl=5 143	554 349	1 858 966	12
min100occ	8 306 #mots=2 885 #syl=5 418	501 377	1 818 950	12
min200occ	7 217 #mots=1 568 #syl=5 646	445 850	1 758 689	11
min300occ	6 848 #mots=1 088 #syl=5 757	417 282	1 719 814	11

TABLE A.2 - Modèles de langage hybrides de mots et syllabes

Le tableau A.3 précise le nombre de 1-grammes, 2-grammes et 3-grammes de nos interpolations entre les modèles de langage hybrides ‘min3occ’ et ‘min300occ’. Les valeurs lambdas $\lambda = [10\%, \dots, 90\%]$ pour l’interpolation modifient les probabilités des n-grammes, mais elles n’ont pas d’impact sur la taille des modèles.

Combinaison	#1-grammes	#2-grammes	#3-grammes	Taille [Mo]
min3occ-min300occ	37 189 #mots=31 425 #syl=5 761	953 170	2 969 131	20

TABLE A.3 - Interpolation entre deux modèles de langage hybrides de mots et syllabes

Pour information, il y a quatre syllabes qui sont présentes dans le lexique du modèle ‘min3occ’ mais absentes dans le lexique du modèle ‘min300occ’ : “_g_a_ʋ_n”, “_l_i_ʃ”, “_w_ã”, “_w_e_s”.

Annexe B

Unités phonétiques

Cette annexe précise quelques informations complémentaires sur le lexique phonétique utilisé dans nos expériences.

Le tableau B.1 donne la liste de 37 phonèmes français, avec leur correspondance entre la notation texte et la notation API (alphabet phonétique international). La notation texte est utilisée dans les modèles pour la reconnaissance de la parole pour faciliter la lecture et éviter les erreurs d'encodage.

Format texte	Format API
a	a
ai	ɛ
an	ã
au	ɔ
b	b
ch	ʃ
d	d
e	e
eh	e ou ɛ
eu	ø
euf	œ
f	f
g	g
ge	ʒ
gn	ɲ
h	ɥ
i	i
in	ẽ
j	j
k	k
l	l
m	m
n	n
ng	ŋ
o	o
oh	o ou ɔ
on	õ
p	p
r	ʀ
s	s
swa	ə
t	t
u	u
v	v
w	w
y	y
z	z

TABLE B.1 - Notation des unités phonétique

Annexe C

Outil de syllabation

Notre outil de syllabation se base sur la configuration 'French-limsi' de l'outil 'LPL-Syllabeur-v2.1' décrit dans [Bigr et al. 2010].

Le tableau C.1 affiche les classes phonétiques avec leurs phonèmes composants.

Classe phonétique	Phonèmes composants
Silence/Bruit (#)	#, +resp+, +bouche+, +micro+, +rire+, +divers+, +parole+, +musique+, pau, <sil>, SIL, SIL+pau, pau+SIL
Voyelles (V)	i e eh ai a au oh o u y eu euf swa in an on un
Semi-voyelles (G)	j h w
Liquides (L)	l r
Obstruent (O)	p t k b d g m n ng gn s ch z ge v f

TABLE C.1 - Classes phonétiques

Le tableau C.2 affiche les règles de syllabation. Dans les règles générales (GENRULE) la lettre *V* indique un phonème appartenant à la classe phonétique des voyelles et la lettre *X* indique un phonème appartenant à n'importe quelle autre classe. Dans les règles des exceptions (EXCRULE) certaines séquences de classes phonétiques ont une position de coupure différente par rapport à leur modèle général.

Type de règle	Séquence de phonèmes	Position de coupure	Séquence de syllabes
GENRULE	VV	0	V V
GENRULE	VXV	0	V XV
GENRULE	VXXV	1	VX XV
GENRULE	VXXXV	2	VXX XV
GENRULE	VXXXXV	2	VXX XXV
GENRULE	VXXXXXV	2	VXX XXXV
GENRULE	VXXXXXXV	3	VXXX XXXV
GENRULE	VXXXXXXXV	4	VXXXX XXV
EXCRULE	VGGV	0	V GGV
EXCRULE	VLGV	0	V LGV
EXCRULE	VOGV	0	V OGV
EXCRULE	VOLV	0	V OLV
EXCRULE	VOLGV	0	V OLGV
EXCRULE	VLLGV	1	VL LGV
EXCRULE	VLOGV	1	VL OGV
EXCRULE	VLGGV	1	VL GGV
EXCRULE	VOLGV	1	VO LGV
EXCRULE	VOOGV	1	VO OGV
EXCRULE	VOGGV	1	VO GGV
EXCRULE	VGLGV	1	VG LGV
EXCRULE	VGOGV	1	VG OGV
EXCRULE	VGGGV	1	VG GGV
EXCRULE	VLOLV	1	VL OLV
EXCRULE	VOOLV	1	VO OLV
EXCRULE	VGOLV	1	VG OLV
EXCRULE	VLOLGV	1	VL OLGV
EXCRULE	VOOLGV	1	VO OLGV
EXCRULE	VGOLGV	1	VG OLGV

TABLE C.2 - Règles de syllabation

Annexe D

Choix de mots similaires

Les tableaux D.1 et D.2 affichent la liste de mots similaires obtenue pour nos 44 nouveaux mots en utilisant 5 et respectivement 50 phrases exemples pour les nouveaux mots, les transcriptions basées sur les unités "motclasse grammaticale" et la distribution de 4 voisins.

Nouveau mot	Ses mots similaires
année	période, équipe, saison, interprétation, émission
années	décennies, séries, printemps, temps, siècles
exemple	opposition, hasard, défaut, effet, an
exemples	types, éléments, objets, lieux, produits
gouvernement	contrôle, travail, port, commerce, scoutisme
gouvernements	médias, pays, dialectes, artistes, réseaux
groupe	village, club, pays, club, parti
groupes	éléments, mouvements, quartiers, secteurs, partis
guerre	crise, semaine, révolution, mission, campagne
guerres	discussions, cérémonies, missions, plongées, études
histoire	édition, architecture, étude, émission, évolution
histoires	prières, leçons, conseils, opinions, compositions
jour	volume, mois, titre, corps, livre
journal	magazine, monde, jeu, héros, prix
journaux	programmes, fictions, lecteurs, articles, livres
journée	saison, semaine, législature, division, décennie
journées	réunions, séances, heures, hommes, sessions
jours	heures, mois, ans, semaines, combats
moment	sujet, point, service, procès, supplice
moments	périodes, discussions, interactions, occasions, films
niveau	maximum, poids, point, volume, minimum
niveaux	endroits, eaux, stades, bras, pays
numéro	tome, volume, livre, chapitre, type
numéros	catégories, noms, temps, enfants, parties
place	position, scène, compétition, liberté, route
places	personnes, hectares, mètres, enfants, millions
pouvoir	commandement, contrôle, service, modèle, terrain
pouvoirs	exploits, travaux, apports, revenus, locaux
problème	domaine, corps, réseau, thème, système
problèmes	éléments, comportements, phénomènes, mouvements, défauts
projet	pays, modèle, programme, congrès, film
projets	ouvrages, programmes, magasins, personnages, éléments
rapport	opposition, israël, défaut, suite, analogie
rapports	domaines, capacités, relations, activités, métiers
rencontre	splendeur, coque, cour, terrasse, citadelle
rencontres	compétitions, courses, relations, collections, institutions
soir	matin, dimanche, samedi, concert, midi
soirs	clubs, épisodes, espoirs, modèles, stades
soirée	compétition, partie, course, projection, production
soirées	nuits, images, vacances, saisons, périodes
sécurité	protection, défense, résistance, transmission, régulation
sécurités	technologies, mesures, formations, télécommunications, décisions
tour	titre, siège, métier, livre, choix
tours	volumes, points, personnes, titres, x

TABLE D.1 - Mots similaires aux nouveaux mots obtenus sur 5 phrases

Nouveau mot	Ses mots similaires
année	époque, opération, expérience, épreuve, édition
années	décennies, saisons, épisodes, heures, opérations
exemple	effet, ordre, extension, erreur, an
exemples	éléments, objets, acteurs, articles, événements
gouvernement	parti, président, peuple, roi, mouvement
gouvernements	ministres, partis, syndicats, services, pays
groupe	système, club, mouvement, centre, corps
groupes	mouvements, chefs, services, hommes, réseaux
guerre	campagne, crise, paix, position, ville
guerres	combats, opérations, missions, campagnes, séries
histoire	écriture, action, évolution, organisation, île
histoires	aventures, idées, images, expériences, informations
jour	temps, mouvement, lieu, jeu, travail
journal	jeu, quotidien, magazine, monde, film
journaux	magazines, médias, sites, services, films
journée	semaine, période, nuit, saison, campagne
journées	heures, mois, séances, parties, saisons
jours	mois, semaines, heures, ans, minutes
moment	point, temps, sens, lieu, mois
moments	films, points, éléments, lieux, personnages
niveau	prix, centre, point, service, sommet
niveaux	points, éléments, enfants, hommes, domaines
numéro	volume, centre, modèle, type, chapitre
numéros	jeux, titres, lignes, membres, points
place	scène, position, valeur, charge, tête
places	personnes, pièces, femmes, habitants, hommes
pouvoir	corps, royaume, temps, travail, roi
pouvoirs	services, droits, biens, travaux, bâtiments
problème	système, sujet, phénomène, cas, terme
problèmes	systèmes, questions, changements, éléments, travaux
projet	système, plan, programme, mouvement, concept
projets	travaux, programmes, services, systèmes, produits
rapport	temps, travail, plan, livre, mouvement
rapports	relations, contacts, services, liens, éléments
rencontre	réunion, tournée, victoire, paix, compétition
rencontres	courses, parties, épreuves, matchs, saisons
soir	matin, midi, dimanche, samedi, vendredi
soirs	temps, joueurs, matchs, pays, matches
soirée	nuit, ville, saison, vie, semaine
soirées	réunions, fêtes, femmes, scènes, manifestations
sécurité	défense, protection, santé, recherche, communication
sécurités	police, positions, données, forces, langues
tour	match, titre, prix, livre, temps
tours	points, matchs, titres, hommes, livres

TABLE D.2 - Mots similaires aux nouveaux mots obtenus sur 50 phrases
exemples

Annexe E

Nouveaux modèles de langage

Le tableau E.1 présente le taux d'erreur mot et le pourcentage de nouveaux mots correctement reconnus, obtenus avec les nouveaux modèles de langage.

	baseline+1-grammes			
	5 mS	10 mS	20 mS	50 mS
5 ex	26.63	26.61	26.60	26.61
10 ex	26.67	26.62	26.60	26.59
20 ex	26.61	26.57	26.63	26.59
50 ex	26.61	26.63	26.59	26.57

	baseline+1-grammes			
	5 mS	10 mS	20 mS	50 mS
5 ex	21.09	20.72	21.27	22.18
10 ex	17.81	19.81	21.63	22.54
20 ex	23.81	21.81	22.18	23.45
50 ex	22.18	22.18	22.36	23.45

	baseline+1-,2-grammes			
	5 mS	10 mS	20 mS	50 mS
5 ex	25.78	25.95	25.95	26.07
10 ex	25.84	25.86	25.87	25.96
20 ex	25.84	25.86	25.91	25.97
50 ex	25.87	25.85	25.90	25.91

	baseline+1-,2-grammes			
	5 mS	10 mS	20 mS	50 mS
5 ex	55.27	51.45	50.90	49.09
10 ex	52.72	54.36	53.27	52.00
20 ex	55.81	55.45	53.81	53.63
50 ex	54.72	54.72	54.36	54.00

	baseline+1-,2-,3-grammes			
	5 mS	10 mS	20 mS	50 mS
5 ex	25.78	25.83	25.96	26.01
10 ex	25.74	25.84	25.96	26.05
20 ex	25.63	25.68	25.92	25.95
50 ex	25.68	25.75	25.82	25.99

	baseline+1-, 2-,3-grammes			
	5 mS	10 mS	20 mS	50 mS
5 ex	64.90	61.09	58.36	56.72
10 ex	63.09	61.09	57.09	55.27
20 ex	68.72	65.81	61.27	58.18
50 ex	68.54	63.45	61.81	57.09

(a) Taux d'erreur mot (WER)

(b) Pourcentage de nouveaux mots correctement reconnus

TABLE E.1 – Analyse du taux d'erreur mot (a) et du pourcentage de nouveaux mots correctement reconnus (b) obtenus avec les nouveaux modèles de langage 'baseline+1-grammes', 'baseline+1-,2-grammes' et 'baseline+1-,2-,3-grammes', en fonction du nombre de phrases exemples par nouveau mot (*ex*) et du nombre de mots similaires pour chaque nouveau mot (*mS*)

Annexe F

Classification question / affirmation

Le tableau F.1 présente la performance obtenue avec le classifieur JRip sur les transcriptions automatiques en utilisant des paramètres combinés appris sur le huitième ensemble d'apprentissage (sur lequel le classifieur atteignait la performance maximale). La performance est donnée en termes de la moyenne harmonique H entre le pourcentage de questions correctement classées et le pourcentage d'affirmations correctement classées, ainsi qu'en termes de la F-mesure entre le rappel et la précision sur la détection de questions et sur la détections d'affirmations.

	nombre	classé question	classé affirmation	
question	940	631	309	H=69,61%
affirmation	7708	2136	5572	questionsCC=67,13%
				affirmationsCC=72,39%

Précision et rappel sur questions	
précision = $631 / (631+2136) = 22,80\%$	fmesureQ = 34,09%
rappel = $631 / (631+309) = 67,13\%$	

Précision et rappel sur affirmations	
précision = $5572 / (5572+309) = 94,75\%$	fmesureA = 82,01%
rappel = $5572 / (5572+2136) = 72,29\%$	

Moyenne pondérée de la F-mesure	mpFmesure = 76,80%
---------------------------------	--------------------

TABLE F.1 - Performance obtenue avec le classifieur JRip utilisant des paramètres combinés sur les transcriptions automatiques appartenant au corpus ESTER2

Le tableau F.2 présente la performance d'un classifieur qui répond au hasard (50%-50%). Comme précédemment, la performance est donnée en termes de la moyenne harmonique H entre le pourcentage de questions correctement classées et le pourcentage d'affirmations correctement classées, ainsi qu'en termes de la F-mesure entre le rappel et la précision sur la détection de questions et sur la détections d'affirmations.

	nombre	classé question	classé affirmation	
question	940	470	470	H=50,00%
affirmation	7708	3854	3854	questionsCC=50,00%
				affirmationsCC=50,00%

Précision et rappel sur questions	
précision = $470 / (470+3854) = 10,87\%$	fmesureQ = 17,86%
rappel = $470 / (470+470) = 50,00\%$	

Précision et rappel sur affirmations	
précision = $3854 / (3854+470) = 89,13\%$	fmesureA = 64,06%
rappel = $3854 / (3854+3854) = 50,00\%$	

Moyenne pondérée de la F-mesure	mpFmesure = 59,04%
---------------------------------	--------------------

TABLE F.2 - Performance obtenue avec un classifieur qui répond au hasard (50%-50%)

Les tableaux suivants détaillent les performances obtenues avec les différents classifieurs et leur vote majoritaire, utilisant des paramètres prosodiques (P), linguistiques (L) ou combinés (C) sur les transcriptions automatiques (table F.3) et sur les transcriptions manuelles (table F.4) appartenant au corpus ETAPE, ESTER2 et ETAPE&ESTER2. Les résultats indiquent les valeurs moyennes (obtenues avec les modèles appris sur les 9 ensembles d'apprentissage) de la moyenne harmonique (H), du taux de questions correctement classées (qCC) et du taux d'affirmations correctement classées (aCC).

			LR	J48	JRip	AdaBoost	MLP	Vote majoritaire
ETAPE	P	H	54,82	54,89	55,16	55,16	51,43	56,06
		qCC	73,18	61,18	67,48	71,18	53,68	69,94
		aCC	43,85	50,61	47,08	45,38	58,45	47,19
	L	H	62,51	64,41	64,10	64,08	64,52	64,38
		qCC	53,52	60,52	64,92	65,72	65,43	61,72
		aCC	75,14	69,06	63,80	63,28	64,19	67,43
	C	H	66,01	63,65	65,46	63,89	63,89	66,47
		qCC	63,63	63,73	68,70	70,11	59,15	66,56
		aCC	68,60	63,74	62,97	59,21	70,32	66,45
ESTER2	P	H	68,04	59,91	65,93	64,31	58,01	66,62
		qCC	70,90	54,10	63,07	62,37	50,76	63,57
		aCC	65,43	68,23	69,60	67,03	76,31	70,51
	L	H	60,12	67,26	69,99	68,42	70,15	67,67
		qCC	44,64	54,42	59,47	57,83	59,60	55,12
		aCC	92,08	88,18	85,52	84,57	85,80	87,83
	C	H	71,44	70,10	72,02	71,00	70,41	71,61
		qCC	60,23	61,43	63,07	62,63	59,60	60,73
		aCC	87,80	81,83	84,09	82,53	86,93	87,36
ETAPE & ESTER2	P	H	59,19	57,17	59,04	58,89	53,83	60,06
		qCC	72,75	59,86	66,66	69,53	53,13	68,75
		aCC	49,90	55,56	53,40	51,46	63,46	53,74
	L	H	62,89	65,97	66,55	66,31	66,92	66,16
		qCC	51,86	59,37	63,90	64,24	64,34	60,48
		aCC	79,89	74,43	69,90	69,25	70,25	73,15
	C	H	68,04	65,87	68,07	66,91	65,88	68,69
		qCC	62,99	63,30	67,65	68,71	59,23	65,47
		aCC	73,99	68,81	68,90	65,76	74,98	72,32

TABLE F.3 - Performance obtenue avec les différents classifieurs utilisant des paramètres prosodiques (P), linguistiques (L) ou combinés (C) sur les transcriptions automatiques appartenant au corpus ETAPE et au corpus ESTER2

			LR	J48	JRip	AdaBoost	MLP	Vote majoritaire
ETAPE	P	H	50,59	54,51	53,85	52,90	53,12	53,43
		qCC	75,94	65,24	71,96	75,20	60,18	74,33
		aCC	37,94	47,36	43,31	41,08	52,98	41,94
	L	H	67,70	69,94	68,55	68,72	68,02	69,19
		qCC	59,17	68,57	71,50	72,22	70,91	68,38
		aCC	79,09	71,56	66,22	66,04	65,96	70,15
	C	H	69,78	68,19	68,89	67,99	69,64	70,59
		qCC	74,44	73,75	78,23	76,20	72,05	77,01
		aCC	65,67	63,54	61,89	61,86	67,99	62,54
ESTER2	P	H	67,68	62,32	67,35	65,95	61,67	67,67
		qCC	77,34	59,59	68,96	69,34	57,98	69,95
		aCC	60,17	65,87	66,03	63,15	71,58	66,02
	L	H	63,85	70,92	72,11	72,89	71,44	70,85
		qCC	48,72	58,97	62,45	64,06	61,45	59,16
		aCC	92,63	89,05	85,67	84,07	85,76	88,43
	C	H	76,68	74,36	76,87	74,67	76,43	77,32
		qCC	69,52	69,40	71,94	68,53	70,02	70,45
		aCC	85,49	80,18	82,68	82,43	84,70	85,73
ETAPE & ESTER2	P	H	55,89	57,46	58,40	57,50	56,05	58,37
		qCC	76,20	64,19	71,41	74,10	59,77	73,46
		aCC	44,14	52,52	49,65	47,24	58,17	48,66
	L	H	67,70	71,21	70,54	70,77	70,02	70,64
		qCC	57,22	66,78	69,81	70,70	69,15	66,66
		aCC	82,87	76,44	71,65	71,32	71,49	75,25
	C	H	72,34	70,42	71,91	70,75	71,88	73,26
		qCC	73,53	72,94	77,06	74,77	71,67	75,78
		aCC	71,20	68,18	67,69	67,60	72,65	70,96

TABLE F.4 - Performance obtenue avec les différents classifieurs utilisant des paramètres prosodiques (P), linguistiques (L) ou combinés (C) sur les transcriptions manuelles appartenant au corpus ETAPE et au corpus ESTER2

Acronyms

API *Alphabet Phonétique International.*

BBN *Bolt Beranek and Newman Inc.*

CMU *Carnegie Mellon University.*

DARPA *Defense Advanced Research Projects Agency.*

GMM *Gaussian Mixture Model.*

HMM *modèles de Markov cachés (Hidden Markov Models).*

MFCC *coefficients cepstraux (Mel Frequency Cepstral Coefficients).*

PER *taux d'erreur de phonèmes (phone error rate).*

POS *classe grammaticale (part-of-speech).*

STM *segment time marked.*

WER *taux d'erreur mot (word error rate).*

Bibliographie

- ABDEL-HAMID, O., A. MOHAMED, H. JIANG et G. PENN (2012). “Applying Convolutional Neural Networks concepts to hybrid NN-HMM model for speech recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 4277–4280.
- ALLAUZEN, A. et J.-L. GAUVAIN (2005). “Open Vocabulary ASR for Audiovisual Document Indexation”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 1013–1016.
- ALTER, R. (1968). “Utilization of Contextual Constraints in Automatic Speech Recognition”. In : *IEEE Transactions on Audio and Electroacoustics* 16.1, p. 6–11.
- AMAN, F., M. VACHER, S. ROSSATO et F. PORTET (2013). “Speech Recognition of Aged Voices in the AAL Context: Detection of Distress Sentences”. In : *The 7th International Conference on Speech Technology and Human-Computer Dialogue (SpeD)*, p. 177–184.
- ARORA, S. J. et R. P. SINGH (2012). “Automatic Speech Recognition: A Review”. In : *International Journal of Computer Applications* 60.9, p. 34–44.
- ASADI, A., R. SCHWARTZ et J. MAKHOUL (1991). “Automatic modeling for adding new words to a large-vocabulary continuous speech recognition system”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 1, p. 305–308.
- BAKER, J. K. (1975). “The DRAGON System - An Overview”. In : *IEEE Transactions on Acoustics, Speech and Signal Processing* 23.1, p. 24–29.
- BARTKOVA, K. et D. JOUVET (2013). “Automatic Detection of the Prosodic Structures of Speech Utterances”. In : *Speech and Computer*. T. 8113. Springer, p. 1–8.
- BARTLETT, S., G. KONDRAK et C. CHERRY (2009). “On the Syllabification of Phonemes”. In : *Proceedings of Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics*. Association for Computational Linguistics, p. 308–316.
- BAUM, L. E. et J. A. EAGON (1967). “An inequality with applications to statistical estimation for probabilistic functions of Markov processes and to a model for ecology”. In : *Bulletin of the American Mathematical Society* 73, p. 360–363.
- BAUM, L. E. et T. PETRIE (1966). “Statistical inference for probabilistic functions of finite state Markov chains”. In : *Annals of Mathematical Statistics* 37, p. 1554–1563.
- BELLEGGARDA, J. R. (2004). “Statistical language model adaptation: review and perspectives”. In : *Speech Communication* 42, p. 93–108.

- BENGIO, Y., R. DUCHARME, P. VINCENT et C. JANVIN (2003). “A Neural Probabilistic Language Model”. In : *The Journal of Machine Learning Research* 3, p. 1137–1155.
- BIGI, B., C. MEUNIER, R. BERTRAND et I. NESTERENKO (2010). “Annotation automatique en syllabes d’un dialogue oral spontané”. In : *Journées d’Étude sur la Parole (JEP)*, p. 1–4.
- BISANI, M. et H. NEY (2005). “Open vocabulary speech recognition with flat hybrid models”. In : *Proceedings of Interspeech*, p. 725–728.
- (2008). “Joint-sequence Models for Grapheme-to-phoneme Conversion”. In : *Speech Communication* 50.5, p. 434–451.
- BOAKYE, K., B. FAVRE et D. HAKKANI-TUR (2009). “Any questions? Automatic question detection in meetings”. In : *IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU)*, p. 485–489.
- BROWN, P. F., P. V. DESOUZA, R. L. MERCER, V. J. DELLA PIETRA et J. C. LAI (1992). “Class-Based n-gram Models of Natural Language”. In : *Computational Linguistics* 18, p. 467–479.
- BRUTTI, A., M. RAVANELLI, P. SVAIZER et M. OMOLOGO (2014). “A speech event detection and localization task for multiroom environments”. In : *Workshop on Hands-free Speech Communication and Microphone Arrays (HSCMA)*, p. 157–161.
- CALMÉS, M. de et G. PÉRENNOU (1998). “BDLEX : a Lexicon for Spoken and Written French”. In : *Proceedings of the International Conference on Language Resources and Evaluation (LREC)*, p. 1129–1136.
- CERF-DANON, H., A.-M. DEROUAULT, M. ELBEZE et B. MÉRIALDO (1989). “Speech recognition in French with a very large dictionary”. In : *Proceedings of Eurospeech*, p. 2150–2153.
- CESSIE, S. le et J. van HOUWELINGEN (1992). “Ridge estimators in Logistic Regression”. In : *Applied Statistics* 41.1, p. 191–201.
- CHARLES MICHEL DE L’ÉPÉE (1776). *Institution des sourds et muets par la voie des signes méthodiques*. Paris : Nyon l’ainé.
- (1784). *La véritable manière d’instruire les sourds et muets, confirmée par une longue expérience*. Paris : Nyon l’ainé.
- CHELBA, C. et F. JELINEK (2000). “Structured language modeling”. In : *Computer Speech & Language* 14.4, p. 283–332.
- CHEN, S. F. et J. GOODMAN (1998). *An Empirical Study of Smoothing Techniques for Language Modeling*. Rapp. tech. Harvard University.
- CHOW, Y., M. DUNHAM, O. KIMBALL, M. KRASNER, G. KUBALA, J. MAKHOUL, P. PRICE, S. ROUCOS et R. SCHWARTZ (1987). “BYBLOS: The BBN continuous speech recognition system”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 12, p. 89–92.
- COHEN, W. (1995). “Fast Effective Rule Induction”. In : *Proceedings of the 12th International Conference on Machine Learning*, p. 115–123.
- COURSANT-MOREAU, A. et F. DESTOMBES (1999). “LIPCOM, prototype d’aide automatique à la réception de la parole par les personnes sourdes”. In : *Glossa* 68, p. 36–40.

-
- COX, S., M. LINCOLN, J. TRYGGVASON, M. NAKISA, M. WELLS, M. TUTT et S. ABBOTT (2002). “Tessa, a system to aid communication with deaf people”. In : *Proceedings of the fifth international ACM conference on Assistive technologies*. ACM, p. 205–212.
- DAGAN, I., L. LEE et F. C. N. PEREIRA (1999). “Similarity-Based Models of Word Co-occurrence Probabilities”. In : *Machine Learning*. T. 34. 1-3, p. 43–69.
- DAHL, G. E., D. YU, L. DENG et A. ACERO (2012). “Context-Dependent Pre-trained Deep Neural Networks for Large Vocabulary Speech Recognition”. In : *IEEE Transactions on Audio, Speech and Language Processing*.
- DAVIS, K. H., R. BIDDULPH et S. BALASHEK (1952). “Automatic Recognition of Spoken Digits”. In : *The Journal of the Acoustical Society of America* 24.6, p. 637–642.
- DAVIS, S. B. et P. MERMELSTEIN (1980). “Comparison of Parametric Representations for Monosyllabic Word Recognition in Continuously Spoken Sentences”. In : *IEEE Transactions on Acoustics, Speech, and Signal Processing* 28.4, p. 357–366.
- DELAPORTE, Y. (2002). *Les sourds, c’est comme ça*. Ed. de la maison des sciences de l’homme.
- DEMORI, R. et M. FEDERICO (1999). “Language Model Adaptation”. In : *Computational Models of Speech Pattern Processing*. T. 169. Springer Berlin Heidelberg, p. 280–303.
- DENES, P. (1959). “The Design and Operation of the Mechanical Speech Recognizer”. In : *Journal of the British Institution of Radio Engineers* 19.4, p. 219–234.
- DENES, P. et M. V. MATHEWS (1960). “Spoken digit recognition using time-frequency pattern matching”. In : *The Journal of the Acoustical Society of America* 32.11, p. 1450–1455.
- DREYFUS-GRAF, J. (1950). “Sonograph and Sound Mechanics”. In : *The Journal of the Acoustical Society of America* 22.6, p. 731–739.
- ESTÈVE, Y., T. BAZILLON, J.-Y ANTOINE, F. BÉCHET et J. FARINAS (2010). “The EPAC corpus: manual and automatic annotations of conversational speech in French broadcast news”. In : *Proceedings of the International Conference on Language Resources and Evaluation (LREC)*.
- ETSI ES 202 212 (2005). “Speech Processing, Transmission and Quality Aspects (STQ); distributed speech recognition; extended advanced front-end feature extraction algorithm; compression algorithms”. In : *ETSI ES*.
- FATEHCHAND, R. (1960). “Machine recognition of spoken words”. In : *Advances in Computers* 1, p. 193–229.
- FOHR, D. et O. MELLA (2012). “CoALT: A Software for Comparing Automatic Labelling Tools”. In : *Proceedings of the International Conference on Language Resources and Evaluation (LREC)*.
- FORGIE, J. W. (1959). “Results Obtained from a Vowel Recognition Computer Program”. In : *The Journal of the Acoustical Society of America* 31, p. 1480–1489.
- FREUND, Y. et R. E. SCHAPIRE (1996). “Experiments with a new boosting algorithm”. In : *Thirteenth International Conference on Machine Learning*. Morgan Kaufmann, p. 148–156.

- FURUI, S. (1986). “Speaker-independent isolated word recognition using dynamic features of speech spectrum”. In : *IEEE Transactions on Acoustics, Speech and Signal Processing* 34.1, p. 52–59.
- (2005). “50 years of progress in speech and speaker recognition research”. In : *ECTI Transactions on Computer and Information Technology* 1.2, p. 64–74.
- GALATAS, G., G. POTAMIANOS et F. MAKEDON (2012). “Audio-visual speech recognition incorporating facial depth information captured by the Kinect”. In : *Proceedings of the 20th European Signal Processing Conference (EUSIPCO)*, p. 2714–2717.
- GALLIANO, S., G. GRAVIER et L. CHAUBARD (2009). “The ESTER 2 evaluation campaign for rich transcription of French broadcasts”. In : *Proceedings of Interspeech*.
- GANAPATHIRAJU, A., J. HAMAKER, J. PICONE, M. ORDOWSKI et G. DODDINGTON (2001). “Syllable-based large vocabulary continuous speech recognition”. In : *IEEE Transactions on Speech and Audio Processing* 9.4, p. 358–366.
- GEHRING, J., Y. MIAO, F. METZE et A. WAIBEL (2013). “Extracting deep bottleneck features using stacked auto-encoders”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 3377–3381.
- GOOD, I. J. (1953). “The population frequencies of species and the estimation of population parameters”. In : *Biometrika* 40.3-4, p. 237–264.
- GOODMAN, J. T. (2001). *A Bit of Progress in Language Modeling*. Rapp. tech. Microsoft Research.
- GRAVIER, G., G. ADDA, N. PAULSON, M. CARRÉ, A. GIRAUDEL et O. GALIBERT (2012). “The ETAPE corpus for the evaluation of speech-based TV content processing in the French language”. In : *Proceedings of the International Conference on Language Resources, Evaluation and Corpora (LREC)*.
- GRÉZL, F., M. KARAFIÁT, S. KONTÁR et J. CERNOCKY (2007). “Probabilistic and bottle-neck features for LVCSR of meetings”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 4, p. 757–760.
- HALL, M., E. FRANK, G. HOLMES, B. PFAHRINGER, P. REUTEMANN et I. H. WITTEN (2009). “The WEKA Data Mining Software: An Update”. In : *SIGKDD Explorations* 11.1, p. 10–18.
- HÄMÄLÄINEN, A., L. BOVES et J. de VETH (2005). “Syllable-Length Acoustic Units in Large-Vocabulary Continuous Speech Recognition”. In : *Proceedings of SPECOM*, p. 499–502.
- HERMANSKY, H. (1990). “Perceptual linear predictive (PLP) analysis of speech”. In : *The Journal of the Acoustical Society of America* 87.4, p. 1738–1752.
- HINTON, G. E. et S. OSINDERO (2006). “A fast learning algorithm for deep belief nets”. In : *Neural Computation* 18.7, p. 1527–1554.
- HINTON, G. et al. (2012). “Deep Neural Networks for Acoustic Modeling in Speech Recognition”. In : *Signal Processing Magazine*.
- HUANG, C., T. CHEN, S. Z. LI, E. CHANG et J.-L. ZHOU (2001). “Analysis of speaker variability.” In : *Proceedings of Interspeech*, p. 1377–1380.
- HUGGINS-DAINES, D., M. KUMAR, A. CHAN, A.-W. BLACK, M. RAVISHANKAR et A.-I. RUDNICKY (2006). “PocketSphinx: A free, real-time continuous speech recognition

-
- system for hand-held devices”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- ILLINA, I., D. FOHR et D. JOUVET (2011). “Grapheme-to-Phoneme Conversion using Conditional Random Fields”. In : *Proceedings of Interspeech*, p. 2313–2316.
- IRIE, K., R. SCHLÜTER et H. NEY (2015). “Bag-of-Words Input for Long History Representation in Neural Network-Based Language Models for Speech Recognition”. In : *Proceedings of Interspeech*.
- JELINEK, F., L. R. BAHL et R. L. MERCER (1975). “Design of a linguistic statistical decoder for the recognition of continuous speech”. In : *IEEE Transactions on Information Theory* 21.3, p. 250–256.
- JELINEK, F., B. MERIALDO, S. ROUKOS et M. STRAUSS I (1990). “Self-organized language modeling for speech recognition”. In : *Readings in Speech Recognition*. Morgan Kaufmann, p. 450–506.
- JELINEK, F., B. MERIALDO, S. ROUKOS et M. STRAUSS (1991). “A Dynamic Language Model for Speech Recognition”. In : *Proceedings of the Workshop on Speech and Natural Language*, p. 293–295.
- JELINEK, F. (1985). “The Development of an Experimental Discrete Dictation Recognizer”. In : *Proceedings of the IEEE*. T. 73. 11, p. 1616–1624.
- JIANG, H. (2005). “Confidence measures for speech recognition: A survey”. In : *Speech Communication* 45.4, p. 455–470.
- JIN, Q., T. SCHULTZ et A. WAIBEL (2002). “Phonetic speaker identification”. In : *Proceedings of Interspeech*.
- JOTHILAKSHMI, S. (2014). “Spoken keyword detection using autoassociative neural networks”. In : *International Journal of Speech Technology* 17.1, p. 83–89.
- JOUVET, D., D. FOHR et I. ILLINA (2012). “Evaluating grapheme-to-phoneme converters in automatic speech recognition context”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 4821–4824.
- JOUVET, D. et D. FOHR (2013). “Combining forward-based and backward-based decoders for improved speech recognition performance”. In : *Proceedings of Interspeech*.
- JOUVET, D. et D. LANGLOIS (2013). “A machine learning based approach for vocabulary selection for speech transcription”. In : *Proceedings of the 16th International Conference on Text, Speech and Dialogue (TSD)*. T. 8082, p. 60–67.
- JUANG, B. H. et S. FURUI (2000). “Automatic speech recognition and understanding: A first step toward natural human machine communication”. In : *Proceedings of the IEEE*. T. 88. 8, p. 1142–1165.
- JURAFSKY, D., R. BATES, N. COCCARO, R. MARTIN, M. METEER, K. RIES, E. SHRIBERG, A. STOLCKE, P. TAYLOR et C. VAN ESS-DYKEMA (1997). “Automatic detection of discourse structure for speech recognition and understanding”. In : *IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU)*, p. 88–95.
- KATAGIRI, S. (2003). *Pattern Recognition in Speech and Language Processing*. Sous la dir. de W. CHOU et B. H. JUANG. CRC Press 2003.
- KELLER, F. et M. LAPATA (2003). “Using the Web to Obtain Frequencies for Unseen Bigrams”. In : *Computational Linguistics* 29.3, p. 459–484.

- KEMP, T., T. SCHAAF et al. (1997). “Estimating confidence using word lattices.” In : *Proceedings of Eurospeech*.
- KHAN, O., W. G. AL-KHATIB et L. CHEDED (2010). “A Preliminary Study Of Prosody-based Detection Of Questions In Arabic Speech Monologues”. In : *Arabian Journal for Science and Engineering* 35.2C, p. 167–181.
- KIM, C. et R. M. STERN (2012). “Power-normalized cepstral coefficients (PNCC) for robust speech recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 4101–4104.
- KLATT, D. H. (1987). “Review of text-to-speech conversion for English”. In : *The Journal of the Acoustical Society of America* 82.3, p. 737–793.
- KOLÁŘ, J. et L. LAMEL (2011). “On Development of Consistently Punctuated Speech Corpora”. In : *Proceedings of Interspeech*, p. 833–836.
- (2012). “Development and Evaluation of Automatic Punctuation for French and English Speech-to-Text”. In : *Proceedings of Interspeech*.
- KRAL, P., J. KLECKOVA et C. CERISARA (2005). “Sentence modality recognition in French based on prosody”. In : *International Conference on Enformatika, Systems Sciences and Engineering - ESSE 2005*. T. 8, p. 185–188.
- KULLBACK, S. et R. A. LEIBLER (1951). “On Information and Sufficiency”. In : *The Annals of Mathematical Statistics* 22.1, p. 79–86.
- KUMAR, N. et A. G. ANDREOU (1998). “Heteroscedastic discriminant analysis and reduced rank HMMs for improved speech recognition”. In : *Speech communication* 26.4, p. 283–297.
- KUMATANI, K., J. W. McDONOUGH et B. RAJ (2012). “Microphone Array Processing for Distant Speech Recognition: From Close-Talking Microphones to Far-Field Sensors”. In : *IEEE Signal Processing Magazine* 29.6, p. 127–140.
- LADEFOGED, P. et I. MADDIESON (1996). *The Sounds of the World's Languages*. Wiley-Blackwell.
- LANE, H. (1996). *Quand l'esprit entend - Histoire des sourd-muets*. Odile Jacob (Editions).
- LE BLOUCH, O. et P. COLLEN (2006). “Reconnaissance automatique de phonemes guide par les syllables”. In : *Journées d'Etude de la parole*.
- LECORVÉ, G., G. GRAVIER et P. SÉBILLOT (2011). “Automatically finding semantically consistent n-grams to add new words in LVCSR systems”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 4676–4679.
- LEE, C. H., L. R. RABINER, R. PIERACCINI et J. G. WILPON (1990a). “Acoustic modeling for large vocabulary speech recognition”. In : *Computer Speech and Language* 4.2, p. 127–165.
- LEE, K. F., H. W. HON et R. REDDY (1990b). “An overview of the SPHINX speech recognition system”. In : *IEEE Transactions on Acoustics, Speech and Signal Processing* 38.1, p. 35–45.
- LESSER, V. R. et L. D. ERMAN (1977). “A Retrospective View of the HEARSAY-II Architecture”. In : *Proceedings of the Fifth International Joint Conference on Artificial Intelligence*, p. 790–800.

-
- LINDGREN, N. (1965). “Machine Recognition of Human Language Part I. Automatic Speech Recognition”. In : *IEEE Spectrum* 2.3, p. 114–136.
- LIPPMANN, R. P. (1987). “An Introduction to Computing with Neural Nets”. In : *IEEE ASSP Magazine* 4.2, p. 4–22.
- LISCOMBE, J., J.-J. VENDITTI et J. HIRSCHBERG (2006). “Detecting question-bearing turns in spoken tutorial dialogues”. In : *Proceedings of Interspeech*.
- LIU, X., M. J. F. GALES et P. C. WOODL (2008). “Context dependent language model adaptation”. In : *Proceedings of Interspeech*.
- LÓPEZ-LUDEÑA, V., C. GONZALEZ-MORCILLO, J.-C. LÓPEZ, E. FERREIRO, J. FERREIROS et R. SAN SEGUNDO (2014). “Methodology for developing an advanced communications system for the Deaf in a new domain”. In : *Knowledge-Based Systems* 56, p. 240–252.
- LOWERRE, B. T. (1976). “The HARPY speech recognition system”. Thèse en informatique. Carnegie Mellon University.
- MACHO, D., L. MAUARY, B. NOÉ, Y. M. CHENG, D. EALEY, D. JOUVET, H. KELLEHER, D. PEARCE et F. SAADOUN (2002). “Evaluation of a noise-robust DSR front-end on Aurora databases”. In : *Proceedings of Interspeech*.
- MARGOLIS, A. et M. OSTENDORF (2011). “Question detection in spoken conversations using textual conversations”. In : *Association for Computational Linguistics*, p. 118–124.
- MARKOWITZ, J. A. (2013). “Beyond SIRI: Exploring Spoken Language in Warehouse Operations, Offender Monitoring and Robotics”. In : *Mobile Speech and Advanced Natural Language Solutions*. Sous la dir. d’A. NEUSTEIN et J. A. MARKOWITZ. Springer New York, p. 3–21.
- MARTINS, C., A. J. S. TEIXEIRA et J. P. NETO (2008). “Automatic estimation of language model parameters for unseen words using morpho-syntactic contextual information”. In : *Proceedings of Interspeech*, p. 1602–1605.
- MASUMURA, R., T. ASAMI, T. OBA, H. MASATAKI, S. SAKAUCHI et A. ITO (2015). “Latent Words Recurrent Neural Network Language Models”. In : *Proceedings of Interspeech*.
- MCCULLOCH, W. S. et W. PITTS (1943). “A logical calculus of the ideas immanent in nervous activity”. In : *The bulletin of mathematical biophysics* 5.4, p. 115–133.
- MEDRESS, M. (1976). “Speech Understanding Systems: Report of a Steering Committee”. In : *SIGART Newsletter* 62, p. 4–8.
- MENDONÇA, A., D. GRAFF et D. DIPERSIO (2011). “French Gigaword third edition”. In : *Proceedings of the Linguistic Data Consortium*.
- MÉRIALDO, B. (1987). “Speech recognition with very large size dictionary”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 364–367.
- MIKOLOV, T., M. KARAFIÁT, L. BURGET, J. CERNOCKÝ et S. KHUDANPUR (2010). “Recurrent neural network based language model.” In : *Proceedings of Interspeech*, p. 1045–1048.

- MIKOLOV, T., A. DEORAS, S. KOMBRINK, L. BURGET et J. H. CERNOCKY (2011a). “Empirical Evaluation and Combination of Advanced Language Modeling Techniques”. In : *Proceedings of Interspeech*. ISCA.
- MIKOLOV, T., S. KOMBRINK, L. BURGET, J. CERNOCKÝ et S. KHUDANPUR (2011b). “Extensions of recurrent neural network language model”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 5528–5531.
- MIKOLOV, T., K. CHEN, G. CORRADO et J. DEAN (2013). “Efficient Estimation of Word Representations in Vector Space”. In : *CoRR* abs/1301.3781.
- MOORE, B. et K. BRUDER (2013). *Philosophy: The Power Of Ideas: Ninth Edition*. McGraw-Hill Higher Education.
- MOUSA, A. E.-D., M. A. B. SHAIK, R. SCHL
"UTER et H. NEY (2011). “Morpheme Based Factored Language Models for German LVCSR”. In : *Proceedings of Interspeech*, p. 1445–1448.
- NAPTALI, W., M. TSUCHIYA et S. NAKAGAWA (2012). “Class-Based N-Gram Language Model for New Words Using Out-of-Vocabulary to In-Vocabulary Similarity”. In : *IEICE Transactions on Information and Systems* E95-D.9, p. 2308–2317.
- NEY, H., U. ESSEN et R. KNESER (1995). “On the estimation of ‘small’ probabilities by leaving-one-out”. In : *IEEE Transactions on Pattern Analysis and Machine Intelligence* 17.12, p. 1202–1212.
- NGIAM, J., A. KHOSLA, M. KIM, J. NAM, H. LEE et A. Y. NG (2011). “Multimodal deep learning”. In : *Proceedings of the 28th International Conference on Machine Learning (ICML)*, p. 689–696.
- NOYES, J. M. et C. R. FRANKISH (1992). “Speech recognition technology for individuals with disabilities”. In : *Augmentative and Alternative Communication* 8.4, p. 297–303.
- OGER, S. (2011). “Modèles de langage ad hoc pour la reconnaissance automatique de la parole”. Thèse en informatique. Université d’Avignon.
- OROSANU, L. et D JOUVET (2013a). “Comparison and Analysis of Several Phonetic Decoding Approaches”. In : *Proceedings of the 16th International Conference on Text, Speech and Dialogic (TSD)*.
- (2013b). “Comparison of approaches for an efficient phonetic decoding”. In : *Proceedings of Interspeech*.
- (2014a). “Combinaison de mots et de syllabes pour transcrire la parole”. In : *Journées d’Étude sur la parole (JEP)*.
- (2014b). “Hybrid language models for speech transcription”. In : *Proceedings of Interspeech*.
- (2015a). “Adding new words into a language model using parameters of known words with similar behavior”. In : *Proceedings of the International Conference on Natural Language and Speech Processing (ICNLSP)*.
- (2015b). “Combining lexical and prosodic features for automatic detection of sentence modality in French”. In : *Proceedings of the International Conference on Statistical Language and Speech Processing (SLSP)*.

-
- (2015c). “Detection of sentence modality on French automatic speech-to-text transcriptions”. In : *Proceedings of the International Conference on Natural Language and Speech Processing (ICNLSP)*.
- PAUL, D. B. (1989). “The Lincoln robust continuous speech recognizer”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 1, p. 449–452.
- PEI, J., J. HAN, B. MORTAZAVI-ASL, H. PINTO, Q. CHEN, U. DAYAL et M.-C. HSU (2001). “PrefixSpan: Mining Sequential Patterns Efficiently by Prefix-Projected Pattern Growth”. In : *International Conference on Data Engineering*, p. 215–224.
- PICONE, J. (1990). “Continuous speech recognition using hidden Markov models”. In : *IEEE ASSP Magazine* 7.3, p. 26–41.
- PICONE, J. W. (1993). “Signal modeling techniques in speech recognition”. In : *Proceedings of the IEEE*, p. 1215–1247.
- PIQUARD-KIPFFER, A., O. MELLA, J. MIRANDA, D. JOUVET et L. OROSANU (2015). “Qualitative investigation of the display of speech recognition results for communication with deaf people”. In : *Workshop on Speech and Language Processing for Assistive Technologies (SLPAT)*.
- PLACEWAY, P. et al. (1996). “The 1996 Hub-4 Sphinx-3 System”. In : *DARPA Speech Recognition Workshop*.
- POVEY, D. et al. (2011). “The Kaldi Speech Recognition Toolkit”. In : *IEEE 2011 Workshop on Automatic Speech Recognition and Understanding*.
- PRAŽÁK, A., P. IRCING et L. MÜLLER (2007). “Language Model Adaptation Using Different Class-Based Models”. In : *Proceedings of SPECOM*, p. 449–454.
- QUANG, V. M., E. CASTELLI et P. N. YEN (2006). “A decision tree-based method for speech processing: question sentence detection”. In : *Proceedings of the Third international conference on Fuzzy Systems and Knowledge Discovery*, p. 1205–1212.
- QUANG, V. M., L. BESACIER et E. CASTELLI (2007). “Automatic question detection: prosodic-lexical features and crosslingual experiments”. In : *Proceedings of Interspeech*, p. 2257–2260.
- QUINLAN, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers Inc.
- RABINER, L. (1989). “A tutorial on hidden Markov models and selected applications in speech recognition”. In : *Proceedings of the IEEE*. T. 77, p. 257–286.
- RABINER, L., S. LEVINSON, A. ROSENBERG et J. G. WILPON (1979). “Speaker independent recognition of isolated words using clustering techniques”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* 4, p. 574–577.
- RABINER, L. et B.-H. JUANG (1993). *Fundamentals of Speech Recognition*. Prentice-Hall, Inc.
- RASTROW, A., A. SETHY et B. RAMABHADRAN (2009a). “A new method for OOV detection using hybrid word/fragment system”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, p. 3953–3956.

- RASTROW, A., A. SETHY, B. RAMABHADHAN et F. JELINEK (2009b). "Towards using hybrid word and fragment units for vocabulary independent LVCSR systems". In : *Proceedings of Interspeech*, p. 1931–1934.
- RAZIK, J., O. MELLA, D. FOHR et J.-P. HATON (2008). "Transcription automatique pour malentendants : amélioration à l'aide de mesures de confiance locales". In : *Journées d'Étude sur la Parole (JEP)*.
- RAZIK, J. (2007). "Local and frame-synchronous confidence measures for automatic speech recognition". Thèse en informatique. Université Henri Poincaré - Nancy I.
- READ, J., R. DRIDAN, S. OEPEN et J. L. SOLBERG (2012). "Sentence Boundary Detection: A Long Solved Problem?" In : *Proceedings of COLING*, p. 985–994.
- REDDY, D. R. (1966). "Approach to computer speech recognition by direct analysis of the speech wave". In : *The Journal of the Acoustical Society of America* 40.5.
- REGENBOGEN, C., D. A. SCHNEIDER, R. E. GUR, F. SCHNEIDER, U. HABEL et T. KELLERMANN (2012). "Multimodal human communication - Targeting facial expressions, speech content and prosody". In : *NeuroImage* 60.4, p. 2346–2356.
- ROSE, R. C., B.-H. JUANG et C.-H. LEE (1995). "A training procedure for verifying string hypotheses in continuous speech recognition". In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 1, p. 281–284.
- RUCK, D. W., S. K. ROGERS, M. KABRISKY, M. E. OXLEY et B. W. SUTER (1990). "The multilayer perceptron as an approximation to a Bayes optimal discriminant function". In : *IEEE Transactions on Neural Networks* 1.4, p. 296–298.
- RUEBER, B. (1997). "Obtaining confidence measures from sentence probabilities". In : *Proceedings of Eurospeech*.
- SAJOUS, F. (2008). "http://redac.univ-tlse2.fr/corpus/wikipedia_en.html".
- SAK, H., A. W. SENIOR et F. BEAUFAYS (2014). "Long short-term memory recurrent neural network architectures for large scale acoustic modeling". In : *Proceedings of Interspeech*, p. 338–342.
- SCHLUTER, R. et H. NEY (2001). "Using phase spectrum information for improved speech recognition performance". In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 1, p. 133–136.
- SCHMID, H. (1994). "Probabilistic Part-of-Speech Tagging Using Decision Trees". In : *Proceedings of the International Conference on New Methods in Language Processing*, p. 44–49.
- SCHÖNBÄCHLER, J. (2003). *Le traitement de la parole pour les personnes handicapées*. travail de séminaire.
- SCHWENK, H. (2007). "Continuous space language models". In : *Computer Speech & Language* 21.3, p. 492–518.
- SHAIK, M. A. B., A. E.-D. MOUSA, R. SCHLÜTER et H. NEY (2011a). "Hybrid Language Models Using Mixed Types of Sub-Lexical Units for Open Vocabulary German LVCSR". In : *Proceedings of Interspeech*, p. 1441–1444.
- SHAIK, M. A. B., A. E.-D. MOUSA, R. SCHLÜTER et H. NEY (2011b). "Using morpheme and syllable based sub-words for Polish LVCSR". In : *Proceedings of the IEEE In-*

-
- ternational Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, p. 4680–4683.
- SIMPSON, R. C. (2002). “Voice control of a powered wheelchair”. In : *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 10.2, p. 122–125.
- SINGH-MILLER, N., M. COLLINS et T. J. HAZEN (2007). “Dimensionality reduction for speech recognition using neighborhood components analysis.” In : *Proceedings of Interspeech*, p. 1158–1161.
- SOKOL, R. (1996). “Réseaux neuro-flous et reconnaissance de traits phonétiques pour l’aide à la lecture labiale”. Thèse en informatique. Université de Rennes.
- SORIN, A., T. RAMABADRAN, D. CHAZAN, R. HOORY, M. MCLAUGHLIN, D. PEARCE, F. WANG et Y. ZHANG (2004). “The ETSI extended distributed speech recognition (DSR) standards: client side processing and tonal language recognition evaluation”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 1, p. 129–132.
- STOLCKE, A. (2002). “SRILM an Extensible Language Modeling Toolkit”. In : *Conference on Spoken Language Processing*.
- SUHM, B. et A. WAIBEL (1994). “Towards better language models for spontaneous speech”. In : *The 3rd International Conference on Spoken Language Processing (ICSLP)*. ISCA.
- SWIETOJANSKI, P., A. GHOSHAL et S. RENALS (2013). “Hybrid acoustic models for distant and multichannel large vocabulary speech recognition”. In : *IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU)*, p. 285–290.
- SZÖKE, I., L. BURGET, J. CERNOCKÝ et M. FAPSO (2008). “Sub-word modeling of out of vocabulary words in spoken term detection”. In : *Spoken Language Technology Workshop (SLT)*. Sous la dir. d’A. DAS et S. BANGALORE. IEEE, p. 273–276.
- TACHBELIE, M. Y., S. ABATE et W. MENZEL (2014). “Using morphemes in language modeling and automatic speech recognition of Amharic”. In : *Natural Language Engineering*, p. 235–259.
- TACHBELIE, M., S. ABATE, L. BESACIER et S. ROSSATO (2012). “Syllable-based and hybrid acoustic models for Amharic speech recognition”. In : *Workshop on Spoken Language Technologies for Under-Resourced Languages (SLTU)*, p. 5–10.
- TANG, K. W., R. KAMOUA, V. SUTAN, O. FAROOQ, G. ENG, W. C. CHU et G. HOU (1994). “Speech recognition technology for disabilities education”. In : *Journal of Educational Technology Systems* 33.2, p. 173–184.
- TU, C. et C. JUANG (2012). “Recurrent type-2 fuzzy neural network using Haar wavelet energy and entropy features for speech detection in noisy environments”. In : *Expert systems with applications* 39.3, p. 2479–2488.
- TURNEY, P. D. et P. PANTEL (2010). “From Frequency to Meaning: Vector Space Models of Semantics”. In : *Journal of Artificial Intelligence Research* 37.1, p. 141–188.
- VACHER, M., B. LECOUTEUX et F. PORTET (2014). “Multichannel Automatic Recognition of Voice Command in a Multi-Room Smart Home : an Experiment involving Seniors and Users with Visual Impairment”. In : *Proceedings of Interspeech*, p. 1008–1012.

- VASWANI, A., Y. ZHAO, V. FOSSUM et D. CHIANG (2013). “Decoding with Large-Scale Neural Language Models Improves Translation”. In : *EMNLP*, p. 1387–1392.
- VINCENT, E., A. SINI et F. CHARPILLET (2015). “Audio source localization by optimal control of a mobile robot”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- VIROLE, B. (1999). *Psychologie de la surdité*. De Boeck.
- VITERBI, A. (1967). “Error Bounds for Convolutional Codes and an Asymptotically Optimum Decoding Algorithm”. In : *IEEE Transactions on Information Theory* 13.2, p. 260–269.
- WAGNER, R. A. et M. J. FISCHER (1974). “The String-to-String Correction Problem”. In : *Journal of the ACM* 21.1, p. 168–173.
- WAIBEL, A., T. HANAZAWA, G. HINTON, K. SHIKANO et K. J. LANG (1989). “Phoneme recognition using time-delay neural networks”. In : *IEEE Transactions on Acoustics, Speech and Signal Processing* 37.3, p. 328–339.
- WANG, D. et S. KING (2011). “Letter-to-sound pronunciation prediction using conditional random fields”. In : *Signal Processing Letters* 18.2.
- WEINTRAUB, M., H. MURVEIT, M. COHEN, P. PRICE, J. BERNSTEIN, G. BALDWIN et D. BELL (1989). “Linguistic constraints in hidden Markov model based speech recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 2, p. 699–702.
- WEINTRAUB, M., F. BEAUFAYS, Z. RIVLIN, Y. KONIG et A. STOLCKE (1997). “Neural-network based measures of confidence for word recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 887–890.
- WESSEL, F., K. MACHEREY et H. NEY (1999). “A Comparison Of Word Graph And N-Best List Based Confidence Measures”. In : *Proceedings of Eurospeech*, p. 315–318.
- WESSEL, F., R. SCHLÜTER, K. MACHEREY et H. NEY (2001). “Confidence Measures for Large Vocabulary Continuous Speech Recognition”. In : *IEEE Transactions on Speech and Audio Processing* 9, p. 288–298.
- WOLF, J. J. et W. A. WOODS (1977). “The HWIM speech understanding system”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* 2, p. 784–787.
- WOLF, M. et C. NADEU (2013). “Channel Selection Measures for Multi-Microphone Speech Recognition”. In : *Speech Communication* 57, p. 170–180.
- WOODCOCK, K. (1997). “Ergonomics and automatic speech recognition applications for deaf and hard-of-hearing users”. In : *Technology and Disability*. T. 7, p. 147–164.
- WU, S.-L., B. KINGSBURY, N. MORGAN et S. GREENBERG (1998). “Incorporating Information From Syllable-Length Time Scales Into Automatic Speech Recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 721–724.
- XU, P. et F. JELINEK (2007). “Random forests and the data sparseness problem in language modeling”. In : *Computer Speech & Language* 21.1, p. 105–152.

-
- YAN, Y. et E. BARNARD (1995). “An approach to automatic language identification based on language-dependent phone recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 3511–3514.
- YAZGAN, A. et M. SARAÇLAR (2004). “Hybrid language models for out of vocabulary word detection in large vocabulary conversational speech recognition”. In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 745–748.
- YOUNG, S. (1996). “A review of large-vocabulary continuous-speech”. In : *Signal Processing Magazine, IEEE* 13.5, p. 45–57.
- YOUNG, S. J., D. KERSHAW, J. ODELL, D. OLLASON, V. VALTCHEV et P. WOODLAND (2006). *The HTK Book Version 3.4*. Cambridge University Press.
- YU, D. et M. L. SELTZER (2011). “Improved Bottleneck Features Using Pretrained Deep Neural Networks.” In : *Proceedings of Interspeech*, p. 237–240.
- YUAN, J. et D. JURAFSKY (2005). “Detection of questions in Chinese conversational speech”. In : *IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU)*, p. 47–52.
- ZHANG, L. et W. H. EDMONDSON (2002). “Speech Recognition Using Syllable Patterns”. In : *Spoken Language Processing*.
- ZHANG, R. et A. I. RUDNICKY (2001). “Word level confidence annotation using combinations of features”. In : *Proceedings of Eurospeech*.
- ZOLNAY, A., R. SCHLÜTER et H. NEY (2005). “Acoustic Feature Combination for Robust Speech Recognition.” In : *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. T. 1, p. 457–460.
- ZUE, V., J. GLASS, M. PHILLIPS et S. SENEFF (1989). “The MIT SUMMIT Speech Recognition System: A Progress Report”. In : *Proceedings of the Workshop on Speech and Natural Language*. Association for Computational Linguistics, p. 179–189.

Publications personnelles

- OROSANU, L. et D JOUVET (2013a). “Comparison and Analysis of Several Phonetic Decoding Approaches”. In : *Proceedings of the 16th International Conference on Text, Speech and Dialogue (TSD)*.
- (2013b). “Comparison of approaches for an efficient phonetic decoding”. In : *Proceedings of Interspeech*.
- (2014a). “Combinaison de mots et de syllabes pour transcrire la parole”. In : *Journées d’Étude sur la parole (JEP)*.
- (2014b). “Hybrid language models for speech transcription”. In : *Proceedings of Interspeech*.
- (2015a). “Adding new words into a language model using parameters of known words with similar behavior”. In : *Proceedings of the International Conference on Natural Language and Speech Processing (ICNLSP)*.
- (2015b). “Combining lexical and prosodic features for automatic detection of sentence modality in French”. In : *Proceedings of the International Conference on Statistical Language and Speech Processing (SLSP)*.
- (2015c). “Detection of sentence modality on French automatic speech-to-text transcriptions”. In : *Proceedings of the International Conference on Natural Language and Speech Processing (ICNLSP)*.
- PIQUARD-KIPFFER, A., O. MELLA, J. MIRANDA, D. JOUVET et L. OROSANU (2015). “Qualitative investigation of the display of speech recognition results for communication with deaf people”. In : *Workshop on Speech and Language Processing for Assistive Technologies (SLPAT)*.

Résumé

Cette thèse fait partie du projet RAPSODIE dont l'objectif est de proposer une reconnaissance vocale spécialisée sur les besoins des personnes sourdes et malentendantes. Deux pistes sont étudiées : la modélisation lexicale et l'extraction d'informations para-lexicales.

En ce qui concerne la modélisation lexicale, nous nous sommes intéressés au choix des unités lexicales définissant le lexique et le modèle de langage associé. Nous avons évalué différentes unités lexicales, comme les phonèmes et les mots, et proposé l'utilisation des syllabes. Nous avons également proposé une nouvelle approche reposant sur la combinaison de mots et de syllabes dans un seul modèle de langage, dit hybride. L'utilisation d'un tel modèle vise à assurer une reconnaissance correcte des mots les plus fréquents et à proposer des suites de syllabes pour les segments de parole correspondant à des mots hors vocabulaire. Afin d'assurer une bonne reconnaissance des mots spécifiques à un certain domaine, nous avons approfondi l'ajout de nouveaux mots dans le modèle de langage. Nous avons proposé et évalué une nouvelle approche qui repose sur un principe de similarité entre mots ; deux mots sont considérés comme similaires s'ils ont des distributions similaires de voisins. L'approche implique plusieurs étapes : utiliser quelques phrases exemples pour le nouveau mot, chercher dans le modèle de langage des mots similaires au nouveau mot, puis définir les n-grammes associés à ce nouveau mot à partir des n-grammes des mots similaires.

Concernant l'extraction d'informations para-lexicales, nous nous sommes intéressés principalement à la détection des questions et des affirmations, afin de signaler aux personnes sourdes ou malentendantes quand une question leur est adressée. Dans notre étude, plusieurs approches ont été analysées reposant sur l'utilisation des paramètres prosodiques (extraits du signal audio), des paramètres linguistiques (extraits des séquences de mots et de classes grammaticales) ou des deux types d'information. L'extraction des informations est faite à partir des signaux audio et des transcriptions automatiques ou des transcriptions manuelles, ce qui permet de comparer les performances des classificateurs dans ces deux conditions (avec ou sans erreurs sur les mots).

Mots clés : reconnaissance de la parole, syllabes, modèles de langage hybrides, mots hors-vocabulaire, mots similaires, détection de questions

Abstract

This thesis is part of the RAPSODIE project which aims at proposing a speech recognition device specialized on the needs of deaf and hearing impaired people. Two tracks are studied: optimizing the lexical models and extracting para-lexical information.

Regarding the lexical modeling, we focused on optimizing the choice of lexical units defining the vocabulary and the associated language model. We evaluated various lexical units, such as phonemes and words, and proposed the use of syllables. We also proposed a new approach based on the combination of words and syllables in a hybrid language model. This kind of model aims to ensure proper recognition of the most frequent words and to offer sequences of syllables for speech segments corresponding to out-of-vocabulary words. Another focus was on adding new words into the language model, in order to ensure proper recognition of specific words in a certain area. We proposed and evaluated a new approach based on a principle of similarity between words ; two words are similar if they have similar neighbor distributions. The approach involves three steps: using a few examples of sentences including the new word, looking for in-vocabulary words similar to the new word, defining the n-grams associated with the new word based on the n-grams of its similar in-vocabulary words.

Regarding the extraction of para-lexical information, we focused mainly on the detection of questions and statements, in order to inform the deaf and hearing impaired people when a question is addressed to them. In our study, several approaches were analyzed using only prosodic features (extracted from the audio signal), using only linguistic features (extracted from word sequences and sequences of POS tags) or using both types of information. The evaluation of the classifiers is performed using linguistic and prosodic features (alone or in combination) extracted from automatic transcriptions (to study the performance under real conditions) and from manual transcriptions (to study the performance under ideal conditions).

Keywords: speech recognition, syllables, hybrid language models, out-of-vocabulary words, similar words, question detection