

Reconnaissance automatique de la parole pour les langues peu dotées

Laurent BESACIER, Viet-Bac LE

LIG/GETALP (Grenoble, France)

PLAN

1 Collecte de données

- Collecte de données textuelles
- Collecte de parole

2 Amorçage des modèles acoustiques

- Modélisation acoustique translingue
- Application au vietnamien et au khmer


3 Réduction de la complexité des modèles

- Utilisation d'unités sous-lexicales pour la modélisation statistique du langage parlé
- Application à une langue peu écrite

Un monde multilingue

- En 2005, moins de 1 % des 6000 langues du monde atteignent un haut niveau d'informatisation (services allant du traitement de texte à la traduction automatique)
 - Langues peu dotées (*under-resourced languages, low density languages*)

Cf. Thèse V.Berment : «*Méthodes pour informatiser des langues et des groupes de langues peu dotées*»



- Grande diversité des systèmes d'écriture
- Langues à forte tradition orale (langues peu écrites)

Un monde multilingue

- Langues peu dotées
 - Peu de données disponibles
 - Besoin de méthodes innovantes qui vont au delà du simple ré-apprentissage des modèles acoustiques et de langage
 - Méthodologie de collecte
 - Amorçage (bootstrap) des modèles acoustiques
 - Réduction de la complexité des modèles

Exemple du khmer

de [Berment, 2004]


	Services / ressources	Importance (/10)	Mark (/20)	Weighted mark (Importance x Mark)
Text processing				
Basic input	10	16	160	
Visualization / printing	10	14	140	
Search and Replace	8	12	48	
Text selection	6	12	72	
Lexicographical sort	5	0	0	
Spelling Correction	2	0	0	
Speech processing				
Text-to-speech	5	0	0	
Automatic Speech Recognition	5	0	0	
Translation				
Tools for Automatic translation	8	4	32	
OCR				
Optical Character Recognition	9	0	0	
Ressources				
Bilingual dictionary	10	4	40	
Usability dictionary	10	0	0	
Total				540 / 1760
Mean				31 / 100



Autre exemple : Vietnamien

	Services / ressources	Importance <i>(/10)</i>	Mark <i>(/20)</i>	Weighted mark <i>(Importance x Mark)</i>
Text processing				
Basic input	10	16	160	
Visualization / printing	10	16	160	
Search and Replace	8	17	136	
Text selection	6	17	102	
Lexicographical sort	5	6	30	
Spelling Correction	2	6	12	
Speech processing				
Text-to-speech	5	0	0	
Automatic Speech Recognition	5	0	0	
Translation				
Tools for automatic translation	8	6	48	
OCR				
Optical Character Recognition	9	12	108	
Ressources				
Bilingual dictionary	10	13	130	
Usability dictionary	10	0	0	
Total				886 / 1760
Mean				50 / 100

Ressources nécessaires pour la RAP



- Corpus textuels et de parole
- Dictionnaire de prononciation
- Modèles acoustiques
- Modèles de langage

Collecte de données


□ Collecte de données textuelles

- D. Vaufreydaz : *Modélisation statistique du langage à partir d'Internet pour la reconnaissance automatique de la parole continue*. Doctorat de l'Université J. Fourier, **thèse soutenue** en janvier 2002 .
- Potentiel pour les langues peu dotées
 - Web parfois unique moyen de collecter des données texte
 - Mais principalement sites d'informations
- Exemple : www.voanews.com

	#phr	#mots	#octets
indonésien	116k	2.4M	17M
coréen	405k	7M	67M
pachto	7k	0.2M	2M
kurde	24k	0.6M	8M
hindî	73k	2M	28M
farsi	212k	5.8M	54M

Collecte de données

- Collecte de données textuelles
- **Collecte de parole**
 - Collaborations locales (MICA/Hanoi ; ITC/Phnom-Penh)
 - Enregistrement sur place avec EMACOP (*Multimedia Environment for Acquiring and Managing Speech Corpora*)
 - Transcriptions locales d'enregistrements radio ou TV



Amorçage des modèles acoustiques

- Collecte de données textuelles
- Collecte de parole
- **Amorçage des modèles acoustiques (bootstrap)**
 - Modélisation acoustique translingue

Modélisation acoustique translingue

	Bilabial	Labiodental	Dental	Alveolar	Postalveolar	Retroflex	Palatal	Velar	Uvular	Pharyngeal	Glottal
Plosive	██████			████		████	██	██████	q	G	?
Nasal	██	m		██		η	██	██		N	
Trill	B			r					R		
Tap or Flap				f		t̪					
Fricative	φ β	███	θ ð	███	███	███	ç j	x	███	h ʃ	h̪
Lateral fricative				f̪ ɬ							
Approximant		v		r		l	j	w			
Lateral approximant				██		l̪	ɬ	L			


○

Phonème FR


□

Phonème VN

- FR/VN ~63% couverture
- Si plusieurs langues source (ex: modèle multilingue de 7 langues)
=> 87% couverture



Bénéfice d'une
couverture
multilingue




Modélisation acoustique translingue

$$\forall \Phi_S, d(\Phi_{S^*}, \Phi_T) = \min [d(\Phi_S, \Phi_T)]$$

- Proposition de nouvelles mesures de similarité entre phonèmes (ou polyphonèmes) pour l'amorce (*bootstrap*) rapide des modèles acoustiques dans une nouvelle langue
 - Φ_S et Φ_T : modèles en langue source et cible
 - Monophones, polyphones, groupes de polyphones
 - d : distances fondées sur les connaissances ou fondées sur les données
 - V-B Le : *Reconnaissance automatique de la parole pour des langues peu dotées*. Doctorat de l'Université J. Fourier, école doctorale EDMI Grenoble, **thèse soutenue** le 1er Juin 2006.
-

Distance entre deux phonèmes : méthode automatique (*data-driven method*)


- Besoin d'un corpus vocal étiqueté en phonèmes en quantité limitée
- Utiliser un décodeur acoustico-phonétique en langue source
- Calculer une matrice de confusion (phonèmes source/cible)
- Développer un outil d'estimation automatique de distance entre deux phonèmes
 - PESCORING (Time-based source/target phoneme scoring)



Soit $A(M, N)$: matrice de confusion de phonèmes,
avec $0 \leq A_{i,j} \leq 1$ $d(s_i, t_j) = A_{i,j}$ où $A_{i,j} \in [0, 1]$ et $i=1..M$,
 $j=1..N$

Distance entre deux phonèmes : méthode à base de connaissances phonémiques (API)

- Construire un graphe hiérarchique où chaque nœud est attaché à un groupe de phonèmes
- Chaque groupe de phonème est assigné à une valeur de similarité qui représente la similarité des éléments dans ce groupe : $G_i \in [0, 1]$



- Distance entre phonèmes s et t = valeur de similarité du nœud père le plus proche de s et t


Distance entre deux polyphones

- Distance entre le polyphone P_S en langue source et le polyphone P_T en langue cible est calculée à partir des distances entre les phonèmes source/cible dans les contextes correspondant

$$d(P_S, P_T) = \alpha_0 \cdot d(s_0, t_0) + \alpha_1 \cdot [d(s_{-1}, t_{-1}) + d(s_1, t_1)] + \dots + \alpha_L \cdot [d(s_{-L}, t_{-L}) + d(s_L, t_L)]$$


avec : - $\alpha_0, \alpha_1, \dots, \alpha_L$: coefficients de distance suivant la position dans le contexte

- $d(s_k, t_k)$: la distance entre deux phonèmes pour $k = -L, \dots, L$




Distance entre deux groupes de polyphones

- # Distance entre deux groupes de polyphones est égale à la moyenne des distances entre tous les couples de polyphones composant les deux ensembles Φ_T et Φ_S



$d(\Phi_S, \Phi_T)$



$$d(\Phi_S, \Phi_T) = \frac{\sum_{i=1}^m \sum_{j=1}^n d(P_{Si}, P_{Tj})}{m.n}$$

Modélisation acoustique à base de graphèmes (1/2)

- Génération d'un dictionnaire de prononciation
 - Fractionner un mot en une suite de graphèmes (caractères)
 - Romaniser des caractères : convertir les caractères en une forme plus simple (ASCII)

Caractère khmer	Romanisation
ក	Ka
ខ	KHa
ី	QI
យ	YA


Romanisation

Mot khmer	Prononciation
ភកិត	Ka Ka I Ta
ភកិល	Ka Ka I Lo
ពោធិ៍ទាម	Ta OO NGo To AA Mo
ពោធិ៍គូង	Ta OO Ta Ta UU Ngo

Dictionnaire de prononciation

Modélisation acoustique à base de graphèmes (2/2)

- Initialisation de modèles acoustiques graphémiques
 - Démarrage aléatoire, démarrage uniforme, ...
 - Segmentation uniforme pour tous les graphèmes [Killer 2003]
 - **Méthode proposée** : initialisation des modèles acoustiques en utilisant une détection de frontières des syllabes



- Modélisation acoustique graphémique dépendante du contexte :
 - Méthode de « singleton » : chaque question linguistique consiste en un seul graphème
 - Méthode à base de relation *graphème-phonème*

Application

- Collecte de données textuelles
- Collecte de parole
- Amorçage des modèles acoustiques (bootstrap)
- **Application au vietnamien et au khmer**


Performance de RAP pour le vietnamien (% syllabes correctes)

Corpus de dialogue


Système source	Distance	Adapt 1h	Adapt 2h
		WA	WA
Français	Connaissance	60.4	63.6
	Données	61.6	63.8
Multilingue (CMU, 7 langues)	Connaissance	64.6	66.3
	Données	63.8	65.3

Même méthodologie appliquée au khmer : système de RAP développé en quelques mois : WA=73.6% sur des phrases lues

Résultats détaillés (Vietnamien)



Résultats détaillés (Vietnamien)



❖ Apprentissage : 2,5 heures – 7 locuteurs


Méthode 1 : Segmentation uniforme pour tous les graphèmes [Killer 2003]

Méthode 2 : Initialisation des MA en utilisant une détection de frontières des syllabes.

Réduction de la complexité des modèles

- Collecte de données textuelles
- Collecte de parole
- Amorçage des modèles acoustiques (bootstrap)
- Application au vietnamien et au khmer
- Réduction de la complexité des modèles**
 - **Utilisation d'unités sous-lexicales pour la modélisation statistique du langage parlé**
 - Séjour à IBM Watson (09/2005=>11/2006)
 - Arabe dialectal (Irakien) : reconnaissance et traduction
 - Langue peu écrite


Exemple de l'arabe standard



Analyse morphologique pour l'arabe dialectal

- Peu de données textuelles disponibles
- Segmenter les mots en préfixe-base-suffixe pour réduire le vocabulaire de l'application *إذا عندك قول لي حتى أروح أصيح أخوان+ي*
 - Et donc réduire la complexité des modèles
- Approche fondée sur les données
 - Apprentissage d'un modèle qui prédit les marques de préfixes et de suffixes à partir d'une chaîne non segmentée
 - Ne pas segmenter les N mots les plus fréquents du corpus d'apprentissage
 - Problème de couverture des modèles de langage n-grammes
 - N => contrôle la taille du vocabulaire

Performances de reconnaissance automatique de parole en irakien



Vers une traduction automatique des langues peu écrites

- Idée : pour une tâche telle que la traduction de parole, la forme écrite f de la langue source pourrait être considérée comme secondaire

$$\begin{aligned}\hat{e} &= \arg \max_e P(e / x) = \arg \max_e \sum_f P(e, f / x) \\ &\approx \arg \max_e \sum_f P(e / f) P(f / x)\end{aligned}$$

$\downarrow \quad \downarrow$


SMT ASR

- Est-il possible de construire un système de traduction de parole à partir d'un corpus parallèle composé d'enregistrements d'une langue peu écrite et de leur traduction en anglais ?


- Hypothèse : enregistrements transcrits en symboles phonétiques

Mots versus Phonèmes

□ Mots



□ Phonèmes



Résultats expérimentaux

- La méthode utilisant les unités phonétiques (*phonèmes*) est pratiquement équivalente en performance à la méthode classique (*mots*)
- 54% phrases jugées correctement traduites (*phonèmes*) contre 58% (*mots*)
 - Potentiel pour les langues peu écrites
 - Potentiel pour réduire le vocabulaire de l'application (sans perte de couverture)
 - Détails publiés dans « Towards speech translation of non written languages» **Laurent Besacier**, Bowen Zhou, Yuqing Gao. IEEE / ACL SLT 2006. Aruba, December 2006.

Bilan

- **Contributions à la reconnaissance automatique de la parole pour les langues peu dotées**
 - Collecte de données textuelles
 - Collecte de parole
 - Amorçage des modèles acoustiques (bootstrap)
 - Application au vietnamien et au khmer
 - Réduction de la complexité des modèles
 - Langues peu écrites
 - Utilisation d'unités sous-lexicales pour la modélisation statistique du langage parlé




Introduction (1)

- In 2005, less than 1 % of the 6000 languages of the world have a high level of computerization, including a broad range of services going from text processing to machine translation...
 - **Under-resourced languages**
 - **Low density languages**
 - A large number of languages in the world do not have an acknowledged written form and only 5 10% of all languages use one of about 25 writing systems
 - => Obvious problems for ASR and MT
-

Introduction (2)

- No or few corpora (text or signal)
- No or few available informations on the language (linguistic or phonetic descriptions)
- No or few standards (character coding, IPA, ...)
- ...



Automatic morphological analysis for Iraqi ASR

- □ Different from a knowledge based approach were prefixes and suffixes of the language are known a priori
 - Iraqi different from MSA : more prefixes and suffixes are informally introduced => Buckwalter morphological analysis did not help
 - Data driven approach using a segmented corpus
 - Use segmented data provided by LDC (100K words)
 - Ex: Endy_bw hAy_bw Al#qTE+p_bw I#ryd_bw
I#nTy_bw
 - Train a model to predict the prefixes and suffixes symbols in an unsegmented stream
 - Implementation using FSM toolkit (char.based algorithm)
-

FSM-based Segmentation

❑ Completely data-driven

- No list of prefixes and suffixes specified.

❑ Train a 5-gram character LM

- 100K words of manually segmented data provided by LDC.
- Represent LM as an FSM.

❑ Create all possible segmentations of a word

- Word “abcd” $\Rightarrow \{abcd, a\#bcd, ab\#cd, abc\#d\}$.
- Represent alternatives as an FSM.

❑ Start from un-segmented LM data

- Segment each sentence using the model
 - ❑ Compose both FSMs and search for best path.
- Reparse LM data to keep top-N words and build new LM

❑ 95.4% word correct on a hand-labeled test set.

- Words might have multiple segmentation.

❑ Decoded output has segmented words

- Blind gluing. Mark prefixes and suffixes with “AI#”

ASR Architecture

□ Acoustic model

- Nine frames of 24-dimensional cepstra reduced to 40 dimensions using LDA+MLLT.
- 33 grapheme models (3 states per phone)
 - Vowelization didn't work well for dialect.
- States are clustered using decision trees.
- GMM built for each leaf.
 - Trained using ML and refined using MPE.
- Rank models on top of the GMMs.

□ Language model

- Trigram LM built using deleted interpolation.

□ The decoder uses a stack-based search algorithm.

ASR: Data and Models

□ Acoustic model

- About 200 hours of training data.
- About 2K leaves and 60K Gaussians.

□ Lexicons

- About 90K unique words in corpus.
- Baseline LM : Un-segmented&cutoff=1:
- Morph. LM : after automatic segmentation, vary N
(more frequent words that are kept unsegmented).

□ LM data of size 1.5M words

- Trigram built using deleted interpolation with 10% held-out data.

□ Iraqi Test set has 15K words and 1.5 hours of speech.

Results for FSM Approach

Iraqi ASR

