

# Raffinement de systèmes de codage prosodique pour corpus d'apprenants IPFC et ICE-IPAC

Rencontres FLORAL – IPFC  
Paris, le 21 novembre 2016

Jeff Tennant

*Université Western Ontario*

Nadine Herry-Bénit

*Université Paris 8*

Roberto Paternostro

*Université de Genève*

# Plan de la communication

- Objectifs
- Problèmes à résoudre et solutions adoptées
- Systèmes de codage prosodique
- Analyses instrumentales pour appuyer le codage
- Système IPFC et illustration
- Système ICE-IPAC et illustration
- Discussion
- Conclusion et perspectives

# Objectifs

- Établir système de codage de la prosodie pour corpus d'apprenants IPFC et ICE-IPAC (traitables avec Dolmen; Eychenne 2015) permettant de représenter les aspects les plus fondamentaux de la prosodie:
  - Frontières des unités prosodiques
  - Proéminences
  - Contours intonatifs
  - Tempo et pauses
  - Degré de conformité à la prosodie native
- Surmonter difficultés rencontrées lors de tentatives antérieures, p.ex.:
  - Système trop lourd à appliquer dans un temps raisonnable
  - Difficultés dans la définition de cibles natives pour évaluer la conformité de la réalisation des apprenants

# Problèmes à résoudre et solutions adoptées

1. Expertise et temps requis pour faire le codage
  - Formation de base en phonétique indispensable, mais pas besoin d'expertise avancée
  - Outils d'analyse instrumentale pour appuyer le codage, à la portée d'annotateurs ayant eu une formation de base
  - Six champs: pas plus complexe que les autres codages IPFC
2. Comment définir les unités de base auxquelles les codes s'associent?
  - Deux niveaux: « unité tonale » (UT) et « syntagme intonatif » (SI): critères d'identification à raffiner au besoin
  - Aucun cadre théorique spécifique préconisé en phonologie prosodique; on peut parler d'équivalences terminologiques avec certaines approches; mais l'essentiel, c'est de définir des critères facilement applicables

# Problèmes à résoudre et solutions adoptées

3. Comment identifier les proéminences?
  - Accord inter-annotateurs tôt dans le processus de codage
  - Usage éventuel d'Analog (Avanzi et al. 2008) pour résoudre désaccords entre annotateurs
4. Coder les cibles tonales ou les contours intonatifs?
  - Contours dans notre codage: le plus pertinent pour l'analyse de la production des apprenants
  - Courbe  $F_0$  dans Praat et points d'ancrage représentés dans analyse Momel-INSTINT (recommandée)
  - *Codage ToBI facultatif: pour les chercheurs désireux d'avoir des données représentées selon le cadre métrique-autosegmental*

# Problèmes à résoudre et solutions adoptées

5. Comment coder la conformité à la cible native?
  - L'annotateur doit connaître la grammaire prosodique de la langue cible, et reconnaître le degré de variabilité admissible, compte tenu du type d'énoncé
  - Descripteurs explicites des écarts par rapport à la cible; on peut en ajouter au fur et à mesure qu'on relève des cas dans les corpus; éviter jugements de valeur « bon », « très bien », « mauvais »...
6. Codage basé sur la perception ou sur les mesures instrumentales?
  - Perception mais vérification à l'aide d'analyses instrumentales fortement recommandée
  - « Un aller-retour entre l'annotation manuelle et le traitement automatique » Simon et al. (2008)

# Systemes de codage prosodique

- IVTS (Post et al. 2006):
  - 6 tires: commentaires; phonologique H, L, H\*, L\*, H%, L%; phonétique globale %; phonétique locale hL, hLHm, hL, etc.; rythmique/proéminences; orthographique
- ToBI (Delais-Roussarie et al. 2015):
  - 4 tires: tonal; break index; orthographic; comments
- LeaP (Gut 2009):
  - 8 tires: phrase; words; syllables; segments; tone (ToBI); pitch; POS, lemma

# Systemes de codage prosodique

- Delais-Roussarie (2011): Prosotran, transcription automatique, au niveau de la syllabe, de l'évolution de trois paramètres prosodiques:
  - 3 tires: segments, F0, durée, énergie
- PFC: Lacheret et Lyche (2006: 43-44):
  - 1 tire, 6 champs (+ trois du protocole étendu): nombre de syllabes du mot; rang de la syllabe dans le mot; perception de la proéminence; variation de durée syllabique; pauses; place dans le discours (+ proéminence F0 mesurée; contour F0; proéminence intensité mesurée)
- Aucun de ces systèmes ne répond entièrement à nos besoins pour IPFC et ICE-IPAC, mais ils peuvent appuyer et compléter nos codages



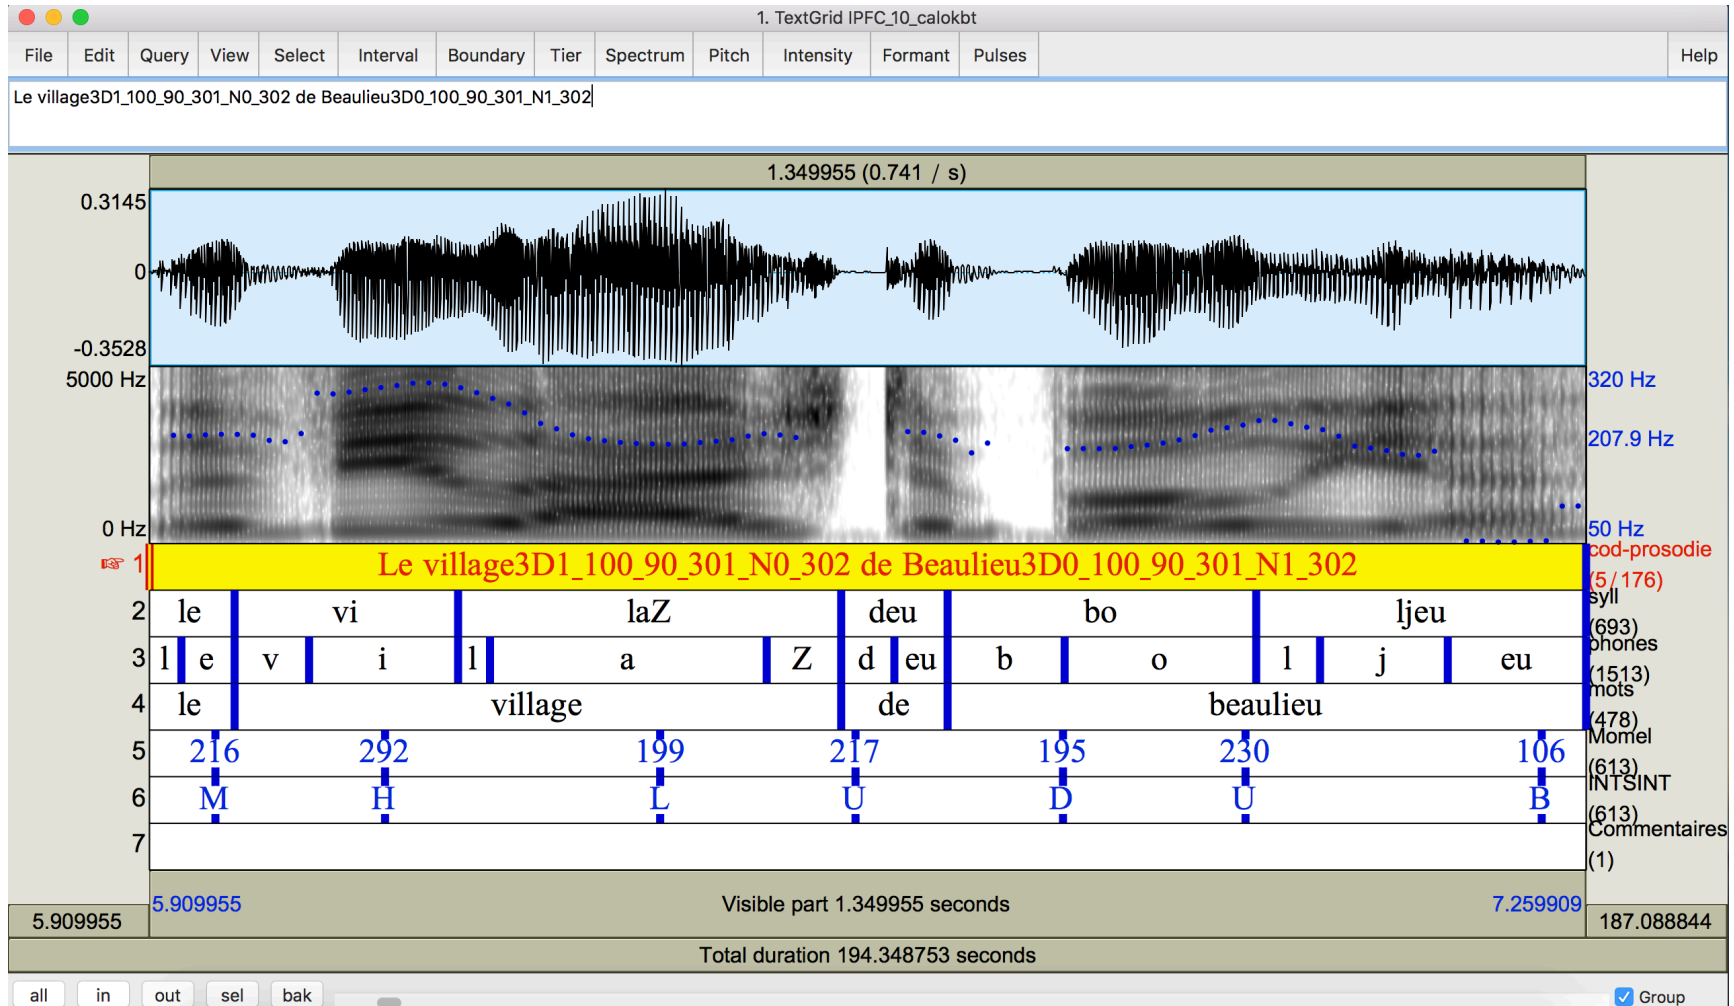
# Analyses instrumentales pour appuyer le codage

- Alignement des mots, phones et syllabes
  - SPPAS (Bigi 2015)
  - EasyAlign (Goldman 2011)
  - SPLaligner (Milne 2013)
- Détection des proéminences
  - Analor (Avanzi et al. 2008)
- Analyse de  $F_0$ 
  - Praat (Boersma et Weenink 2016)
  - Momel-INTSINT sous SPPAS (Hirst 2007, Bigi 2015)
  - Prosogram (Mertens 2004)
  - Winpitch (Martin 2003)

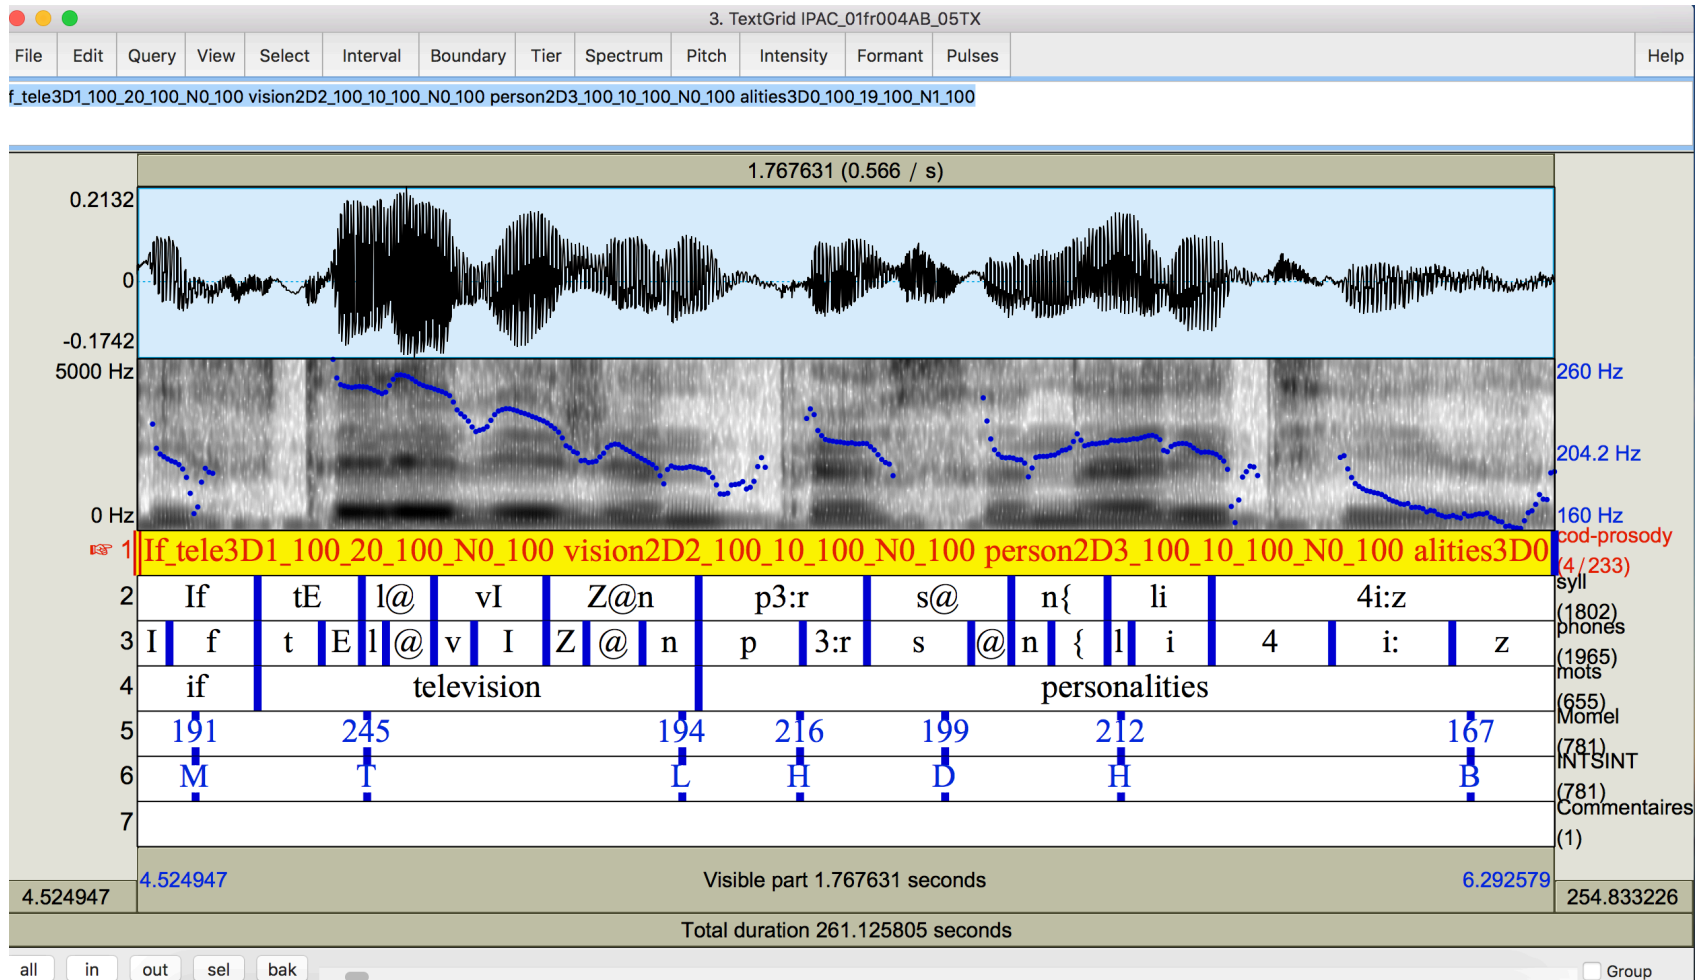
# Champs de codage proposés

1. Nombre de syllabes, type d'énoncé et place de l'UT dans le SI
2. Conformité du découpage en UT
3. Syllabe(s) proéminente(s) (cible)
4. Conformité des proéminences
5. Tempo, pause après UT
6. Conformité du contour tonal

# Illustration IPFC



# Illustration ICE-IPAC



# Discussion

- Avantages du codage proposé:
  - Système qui, à notre avis, représente les éléments indispensables d'un codage prosodique
  - Suit le format des autres codages (I)PFC, possibilité de traiter base de données à l'aide de Dolmen
  - Après une période de test et de calibrage, ne prendra pas plus de temps que les autres codages IPFC
- Ce que le codage ne représente pas pour l'instant:
  - Le registre
  - Alignement précis des tons (mais une analyse ToBI peut être ajoutée et INTSINT donne des indices)
  - Débit mesuré et durées syllabiques

# Conclusion et perspectives

- Bilan:
  - Nous avons établi un codage qui est prêt à appliquer aux corpus IPFC et ICE-IPAC
  - Des raffinements se feront certainement au fur et à mesure que nous ferons le codage
- Prochaines étapes:
  - Appliquer aux corpus et compléter/raffiner, notamment descripteurs du degré de conformité
  - Volontaires pour tester le codage sur IPFC espagnol, allemand, italien, etc.?

# Références

- DISPONIBLES SUR DEMANDE (ET LA LISTE N'AURAIT PAS ÉTÉ LISIBLE À L'ÉCRAN! 😊)