

Psycholinguistique de la production orale, aisance et disfluenace en L2

Heather E. Hilton

Université Paris 8, UMR 7023, équipe Langage, Cognition, Développement

Résumé

Les modèles psychologiques de la production orale sont le plus souvent testés par des démarches expérimentales très contrôlées ; il est peu courant de les confronter aux données plus naturelles de la production discursive en temps réel. Dans cet article, je résume le modèle de production le plus répandu (Levelt 1999a), en y incorporant les caractéristiques de la production en L2 proposées par Kormos (2006). Les analyses du corpus PAROLE – un corpus minutieusement annoté, composé de productions en L1 et en L2 – permettent d'identifier les caractéristiques particulières de la production en L2. Nous nous en servirons, donc, pour mieux comprendre les enjeux de la prise de parole en L2, et pour tirer quelques conclusions didactiques concernant la compétence communicative orale.

Abstract

Psycholinguistic models of oral production are usually tested with carefully-controlled experimental protocols, and only rarely are they compared with samples of more naturalistic, discursive processing. In this article, I summarize the most widely-cited L1 production model (Levelt 1999a), incorporating into it the characteristics of L2 production identified by Kormos (2006). Analysis of the PAROLE Corpus – a finely annotated corpus containing productions in both L2 and L1 – will enable us to identify some of the key characteristics of L2 speech, and to discuss some of the pedagogical implications of a psycholinguistic view of oral fluency.

Qu'est-ce qui se passe – au niveau psycholinguistique – quand on parle dans une langue étrangère (L2) ? La réponse à cette question est complexe, bien sûr, car les processus de traitement sont eux-mêmes complexes, mais il est important de pouvoir y répondre dans le domaine de la didactique des langues. Nous ne pouvons pas aider des apprenants à atteindre l'aisance orale en L2 si nous ne comprenons pas nous-mêmes ce sur quoi cette aisance est fondée. Je débute cet article par un résumé rapide des modèles de production développés par les psycholinguistes (et notamment par Levelt et ses collègues au *Max Planck Instituut voor Psycholinguïstiek* aux Pays-Bas) pour la langue maternelle (L1), en y incorporant les particularités de la production en L2, selon le « modèle intégré » de Kormos (Kormos 2006), l'extension la plus récente du modèle de Levelt. Je présenterai ensuite des analyses et des exemples tirés du Corpus PAROLE (Hilton & al. 2008), un

corpus oral de productions en anglais et en français, comportant des productions d'apprenants de ces deux langues ainsi que des productions de 'natifs' anglophones et francophones. Plus précisément, je présenterai les indices temporels de l'aisance orale (en L1 et en L2), comparés aux caractéristiques de la production hésitante – ou disfluente – en L2¹. Dans la discussion, je confronterai le modèle aux réalités observées dans PAROLE, et je conclurai en esquissant quelques implications didactiques d'une telle vision psycholinguistique de la production orale.

1. Modèles de production orale

La figure 1 (cf. page suivante) résume le « schéma du locuteur » (*blueprint of the speaker*) développé par Levelt et ses collègues (Levelt 1989 ; Bock & Levelt 1994 ; Levelt 1999a), et présenté dans Levelt 1999a (p. 97). Selon ce modèle, il y a deux « systèmes » cognitifs à l'œuvre dans la production orale : le système rhétorique ou sémantico-syntaxique, qui effectue la préparation conceptuelle et l'encodage « grammatical » du message préverbal ; et le système phonologique, qui prépare les partitions phonologiques et articulatoires qui donnent forme aux concepts que le locuteur veut exprimer. Ces deux systèmes sont alimentés par des réseaux de connaissances en mémoire à long terme (figurés par les ellipses à droite du schéma) : les connaissances générales, sociales et discursives du locuteur, son lexique mental et le syllabaire gestuel (*syllabary*) de la langue de production. Les ellipses grises représentent le schéma original de Levelt, élaboré pour le traitement langagier en L1 ; les ellipses noires sont dérivées du « modèle intégré » de Kormos, qui incorpore les particularités de l'encodage formel en L2 au schéma de Levelt (Kormos 2006 : 168).

Il y a peu de recherches sur la planification conceptuelle du discours en L1 (Tanenhaus & Brown-Schmidt 2008 : 1116), et encore moins d'information sur les caractéristiques particulières de la planification dans une langue étrangère (Levelt 1999a : 89). Les règles pragmatiques « de base » (*ground rules*) de la communication (Clark 1993 ; Grice 1975, résumé dans Graesser & al. 1997 : 172-173 ; voir aussi Steedman & Johnson-Laird 1980 : 111-112), opèrent de façon automatique (ou quasi-automatique) dans la production – c'est-à-dire, sans effort attentionnel – sauf cas particuliers, tels l'alibi mensonger. Selon ces règles, les énoncés que nous produisons sont vrais et pertinents par rapport au discours qui précède, ils suivent un ordre chronologique et ne se contredisent pas ; les nouveaux éléments, les

¹ Dans la littérature scientifique anglophone, le terme disfluent est utilisé depuis une cinquantaine d'années comme le contraire de fluent (qui qualifie la production aisée). Il y a des seuils temporels définis pour identifier la production orale disfluente en L1 (pour un résumé voir Hilton 2008a : 67). Les critères ne sont pas aussi clairs pour la disfluence en L2, mais ici j'utiliserai l'adjectif disfluent(e) avec un sens temporel, pour qualifier les productions les plus hésitantes de notre corpus non-natif (voir la section deux).

violations chronologiques ou les éléments importants sont « fléchés », selon une variété de procédures discursives (phrases transitionnelles, marqueurs prosodiques et gestuels, etc.). Ces éléments de planification discursive seraient automatisés, et s'enclencheraient sans doute indépendamment de la langue de production – mais il serait intéressant de disposer de recherches interculturelles dans ce domaine.

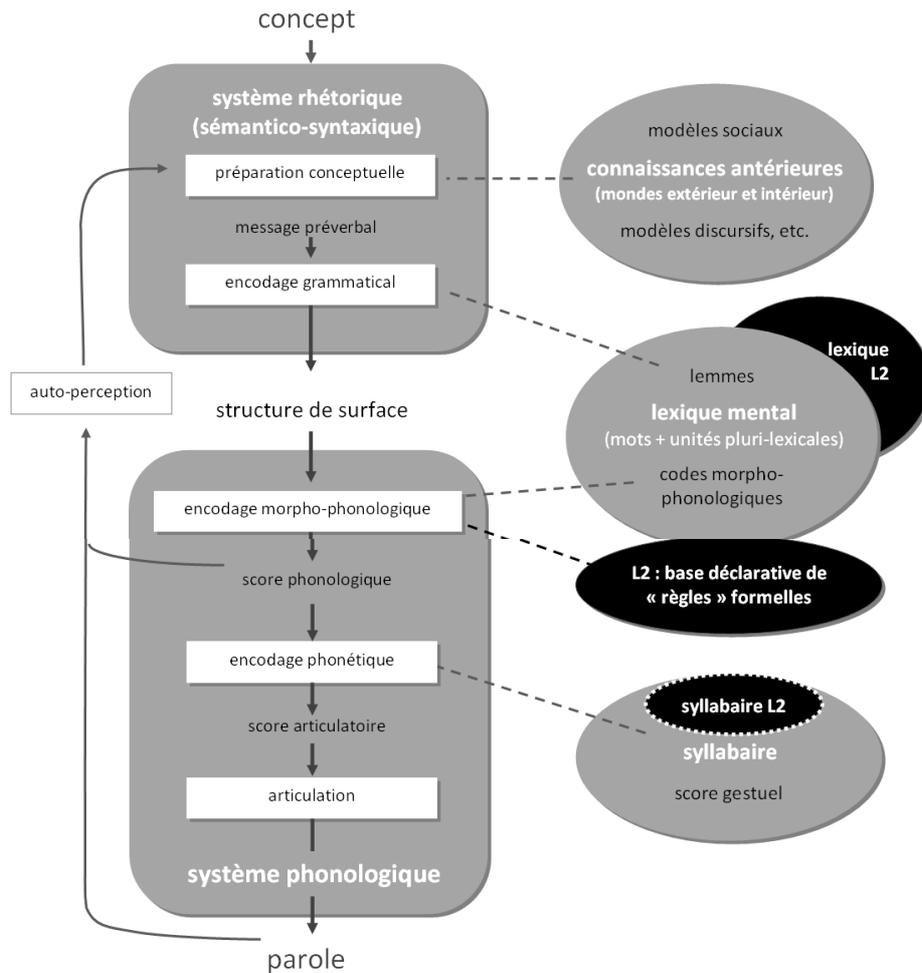


Figure 1 – Schéma des processus de production orale
(Levelt 1999 : 97 ; Kormos 2006 : 168)

Dans la phase plus explicite de la « macro-planification » (*macroplanning*), le locuteur décide ce qu'il va dire et dans quel ordre ; cette phase comprend une évaluation du rôle et des connaissances de l'interlocuteur (et une appréciation des connaissances partagées entre les

participants à l'échange), ainsi que toute adaptation du discours suite aux réactions du/ des interlocuteur/s (Levelt 1999a : 87, 90-91). Le résultat du processus de macro-planification est « le message préverbal » – une structure conceptuelle particulière, constituée de concepts pour lesquels il y a des mots dans la langue de production. Des structures conceptuelles non-lexicales existent dans nos pensées – représentations spatiales, kinésiques, olfactives, peut-être musicales – mais ces types de représentations ne constituent pas des messages préverbaux selon Levelt (1989 : 72-73 ; 1999a : 87-88), car ces derniers sont composés de relations sémantiques pouvant être encodées par des mots (Levelt 1999a : 91). La préparation de la production verbale n'est donc pas indépendante de la langue de production ; la façon dont celle-ci encode la perspective que le locuteur peut adopter sur les concepts à exprimer (*event construal*) semble particulièrement importante, et les possibilités de prise de perspective dans notre L1 influencent la production en L2, même à un niveau avancé (von Stutterheim & al. 2002 ; von Stutterheim 2003). L'adoption par le locuteur d'une perspective sur les concepts à encoder est une étape obligatoire, préalable à la micro-planification :

[... E]ven in the case of naming a single object it is not trivial which lexical concept you should activate to refer to that object. It will depend on the discourse context whether it will be more effective for you to refer to a cat as cat, animal, siamese or anything else. [...] Will it be more effective for me to refer to my sister as my sister or as that lady or as the physicist? It will all depend on shared knowledge and discourse context. This freedom of perspective-taking appears quite early in life and is ubiquitous in conversation. (Levelt 1999b : 226)

Levelt mentionne deux possibilités dans la prise de perspective lors de la macro-planification (Levelt & al. 1999 : 8-9 ; Levelt 1999a : 92) : la perspective « déictique » (l'énonciateur se situant « à l'extérieur » de la situation à encoder) et la perspective « intrinsèque » (l'énonciateur faisant partie de la situation), le choix de l'une de ces deux perspectives reflétant une interprétation pragmatico-sociale de la situation discursive. La prise de perspective lors de la macro-planification en production orale est donc une étape intéressante, et assez peu étudiée dans la recherche en acquisition ou en traitement des langues.

L'adoption d'une perspective sur les concepts à encoder permet le passage à la « micro-planification » (*microplanning*), où la « forme propositionnelle » (Levelt 1989 : 71) du message préverbal est élaborée : *'The human mind organizes the world of experience in categories such as persons, objects, events, actions, states, times, places, directions, and manners. Propositional structures are composed of elements representing entities of these sorts'* (74). Quatre types d'information déterminent la forme propositionnelle du message préverbal (Levelt 1999a : 92-93) : les référents,

leurs rôles thématiques (*argument structure*), d'éventuelles précisions ou modifications (portant soit sur les référents, soit sur leur rôle), et le mode du message (déclaratif, interrogatif, etc.). Encore une fois, cette étape de planification est influencée par les moyens qui existent dans la langue de production pour encoder les différentes dimensions propositionnelles ; tout enseignant de langue a constaté, de même que de nombreux chercheurs en acquisition des langues (par exemple, Hickmann & al. 1998 ; Dimroth 2002 ; ou les articles réunis dans Hendricks 2005), l'influence de la L1 sur la micro-planification en L2. En L1, les reprises et les reformulations peuvent indiquer des changements de perspective, suite sans doute à un processus de monitoring explicite ou semi-explicite (MacWhinney 1999 : 239), mais en général la structuration discursive semble se passer de façon largement implicite (Van Hoek 2003 : 169).

Le message préverbal sert de matériau à traiter (*input*) dans la phase d'encodage grammatical qui génère la « structure de surface » de la production. Cette structure est syntaxique – ordonnée de façon linéaire – mais elle est en grande partie déterminée par le choix des mots nommant les référents, et le rôle thématique attribué à chacun : '*grammatical encoding is like solving a set of simultaneous equations. Each lemma requires particular syntactic constraints from its environment and the emerging syntactic structure should simultaneously satisfy all these constraints*' (Levelt 1999a : 95). Comme le modèle de production schématisé dans la figure 1, les modèles d'activation lexicale en production orale (Roelofs 1997 ; Levelt & al. 1999 ; Indefrey & Levelt 2004) comportent deux étapes : l'activation de « lemmes » par le matériau propositionnel du message préverbal, qui activent à leur tour les formes morpho-phonologiques qui seront articulées en fin de processus. En psycholinguistique, les lemmes sont des représentations lexicales syntaxiquement spécifiées (Abutalebi & Green 2007 : 243) : '*a word's lemma specifies its basic meaning, its syntactic category, its conceptual argument structure, its grammatical profile (e.g. in the case of a verb, whether or not it takes a direct object), and its 'diacritic parameters' of variation (tense, aspect, mood, etc.)*' (Singleton 2000 : 175). Les modèles récents de l'activation lexicale postulent une activation bidirectionnelle ou interactive à l'intérieur du système rhétorique : les concepts activant les lemmes, qui peuvent à leur tour influencer la conceptualisation (Levelt 1999b : 226). L'agencement syntaxique établi dans la phase d'encodage grammatical reflète non seulement le rôle thématique des référents, mais également des stratégies discursives : l'énonciateur se sert de divers procédés syntaxiques pour la mise en relief de certains éléments propositionnels.

Les lemmes activés par l'encodage grammatical ayant déterminé la structure de surface de l'énoncé à venir, le système phonologique peut enclencher l'encodage formel de l'ensemble. Nous voyons dans la figure 1

que le lexique mental sert de pont ou de lien entre les systèmes rhétoriques et phonologiques de la production : les lemmes activent des formes morphologiques et phonologiques, ces *lexèmes* qui correspondent aux ensembles sémantico-syntaxiques à exprimer. Un lexème regroupe trois types d'information (Levelt 1999b : 5) : les morphèmes, le contour prosodique et les segments phonétiques (syllabifiés) du mot. Les systèmes phonologiques et prosodiques étant des systèmes implicitement rôdés et hautement automatisés en L1, on peut prévoir des difficultés d'encodage formel pour l'énonciateur qui produit dans une langue étrangère : non seulement les bases mnésiques fournissant les programmes et les informations nécessaires à l'encodage peuvent être lacunaires ou défaillantes (le lemme ou le lexème nécessaire pour l'encodage de tel objet, événement, état, etc. étant 'sous-spécifié' ou carrément absent, par exemple), mais les automatismes de l'encodage formel en L1 entrent également en compétition avec la formulation en L2 (MacWhinney 1987 ; MacWhinney 1997).

Les modèles d'encodage lexical qui forment la base du « système phonologique » dans le schéma de Levelt ayant été élaborés autour d'études du traitement des mots isolés, nous ne disposons pas de beaucoup de données scientifiques nous permettant de déterminer avec certitude les unités d'encodage formel dans la production discursive. Levelt suggère que l'encodage grammatical peut activer des groupes préfabriqués de mots en mémoire (Levelt 1999a : 95), mais il ne s'attarde pas sur le phénomène. Quelques chercheurs ont postulé que « la combinaison habituelle » des mots est à la base de l'aisance orale (*oral fluency*) en L1 (Goldman-Eisler 1958 : 67), mais l'importance de l'activation de séquences pluri-lexicales a surtout été constatée dans les recherches sur la production orale en L2 (Pawley & Syder 1983 ; Pawley & Syder 2000 ; Wray 2000 ; Wray 2001). En incorporant « le principe idiomatique » (identifié par des linguistes et lexicologues dans les années 1980) à son « modèle intégré » de la production orale, Kormos (2006) étend utilement le modèle psycholinguistique de Levelt. L'hypothèse de la nature pluri-lexicale d'une partie importante² de l'encodage formel doit absolument être examinée de façon scientifique, car elle pourrait expliquer l'extrême efficacité de cet encodage, en parfait accord avec les théories cognitives qui postulent que l'automaticité d'un traitement est basé sur l'activation directe d'« instances » en mémoire (*memory-based theories of automaticity* ; Logan 1988 ; Logan 1991) :

[... T]he best way to explain how users produce nativelike sentences and use the language fluently is that in addition to knowing the rules of the language, they store hundreds of thousands of preconstructed clauses in their memory and draw on them in language use. Thus each word in the

² Erman et Warren (2000) ont déterminé que près de 60 % du discours dans un corpus oral est préfabriqué (58,6 %, plus précisément, dans un corpus d'environ 14.000 mots).

language is likely to be stored many times, once as a single item and many times in memorized chunks. (Nation 2001 : 318)

Les ellipses noires de notre figure 1 illustrent les structures mnésiques spéciales qui alimentent l'encodage formel lors de la production en L2 : un réseau lexical pour cette langue, le plus souvent moins étendu que le lexique mental en L1, et une base déclarative de règles formelles (morpho-syntaxiques, dérivationnelles, phonologiques) qui sont apprises explicitement dans beaucoup de classes de langue. L'existence d'un syllabaire cloisonné pour la L2 n'est pas corroborée par la recherche sur le traitement phonologique en L2 (résumé dans de Bot 1992 : 15-16) ; les phonèmes particuliers à la L2 s'ajoutent au syllabaire déjà en place pour la L1 (l'élargissant donc), mais les phonèmes proches dans les deux langues activent les programmes syllabiques déjà en place pour la L1. J'ai tenté de schématiser ces phénomènes, en ajoutant – à l'intérieur du « syllabaire » – une petite ellipse noire au contour en pointillé, pour évoquer la nature non modulaire des informations phonologiques en L2.

Avant de comparer ce modèle de la production aux phénomènes observés dans un corpus oral, je voudrais résumer nos analyses de ce corpus, afin d'identifier le plus précisément possible les différences entre la production en L1 et en L2. En quoi, précisément, consiste l'aisance à l'oral, comment définir la 'disfluente' en L2 ? Les données rassemblées dans le corpus PAROLE fournissent quelques réponses concrètes à ces questions.

2. Production aisée et disfluente dans le corpus PAROLE

Le corpus PAROLE (Parallèle, Oral en Langue Etrangère) fut constitué à l'Université de Savoie non pas dans le but d'une vérification détaillée des modèles psycholinguistiques de la production, mais plus simplement pour permettre à notre équipe d'identifier les principales caractéristiques de la production en L2. Les données rassemblées peuvent, néanmoins, nous aider à comprendre la production orale en L2 plus globalement, car l'architecture du corpus permet de comparer les apprenants entre eux, mais aussi apprenants et locuteurs natifs d'une langue. Nous présenterons ici nos analyses de la partie anglaise et française du corpus actuellement en ligne (Hilton & al. 2008) : deux tâches dans lesquelles les sujets ont résumé le contenu d'une courte séquence vidéo immédiatement après visionnage, en interaction limitée avec un observateur de l'équipe de recherche. Le corpus non-natif, auquel 33 apprenants d'anglais (24 francophones et 9 germanophones) et 12 apprenants du français (différentes L1) ont contribué, comporte 1 heure 15 de production en L2 (9087 mots) ; le corpus natif, auquel 9 anglophones et 8 francophones ont contribué, comporte 22 minutes de production en L1 (3732 mots). PAROLE a été transcrit, étiqueté et analysé avec les logiciels du *Child Language Data Exchange System* (CHILDES, MacWhinney 2007) ; le découpage des énoncés, l'étiquetage du

corpus, le codage des erreurs et des reprises suivent les conventions de CHILDES, avec, bien sûr, quelques adaptations (décrites dans Hilton 2008c et Hilton 2009). La particularité de ce corpus est le codage minutieux des phénomènes temporels de chaque énoncé : toute hésitation durant plus de 200ms (pauses isolées silencieuses ou vocalisées, ainsi que des ‘groupes d’hésitation’ plus complexes³) a été chronométrée, et sa durée incorporée à la ligne principale de transcription (Hilton 2009 : 648). Le balisage des fichiers son, combiné à ces annotations temporelles, rend possible le calcul du temps total de parole de chaque sujet, son temps d’hésitation, et donc les taux de production (mots par minute, nombre moyen de mots produits en ‘segments fluides’ entre deux hésitations) et d’hésitation (pourcentage du temps de parole passé en hésitation, longueur moyenne ou médiane des hésitations). Dans une version hors ligne du corpus, nous avons également codé la position de chaque hésitation, selon trois possibilités : en début ou fin d’énoncé, en début ou fin de proposition, ou à l’intérieur d’un syntagme (entre les mots qui le constituent). Nous avons également codé et tabulé les unités syntaxiques composant chaque énoncé : proposition principale, proposition subordonnée, phrase non-verbale, ou ce que nous avons décidé d’appeler des ‘propositions support’ (une complétive comme « *On peut voir ...* » ou une proposition existentielle comme ‘*There is a ...*’). Le contenu informationnel de chaque résumé a été tabulé selon un inventaire global de tous les événements nommés dans le corpus au moins une fois ; chaque événement, ainsi que chaque attribut concernant un élément de la situation, constitue une « unité d’information » (Osborne & Hilton 2008).

Les analyses temporelles du corpus nous ont permis d’établir un « indice d’aisance » (IA) quantitatif (Osborne 2007) qui combine trois mesures pour chaque sujet dans un indice de la fluidité – ou aisance temporelle (*temporal fluency*) – de sa production : mots par minute, pourcentage du temps de parole passé en production et longueur moyenne des segments fluides. Cet indice a été utilisé pour identifier de façon objective – sans passer par des évaluations subjectives, difficiles à calibrer pour deux langues différentes – deux extrêmes du corpus non-natif : les 12 apprenants les plus à l’aise en L2 selon ces mesures temporelles (quatrième quartile de l’IA), et les 12 apprenants les moins à l’aise en L2 (premier quartile de l’IA). Le Tableau 1 présente les mesures de production et les indices d’hésitation pour les deux groupes principaux de sujets dans PAROLE (apprenants et natifs, colonnes 2 et 5, respectivement), et pour les sous-groupes identifiés par l’indice d’aisance – les apprenants à l’aise dans la production (colonne 4), et les apprenants très hésitants ou disfluents (colonne 3).

³ Suite d’au moins deux phénomènes d’hésitation ininterrompus par une tentative d’articulation : pause silencieuse suivi d’une pause vocalisée, par exemple ; les groupes peuvent aussi comporter des bruitages paralinguistiques, tels que soupirs, claquements de la langue, etc. Pour plus de détails, voir Hilton 2009.

Tableau 1 – indices d’aisance et de production, corpus PAROLE
(valeurs médianes, avec minima et maxima en italiques)

INDICE		apprenants (n=45)	disfluents (n=12)	fluents (n=12)	natifs (n=17)
indices d’aisance temporelle	mots par minute <i>minima - maxima</i>	105,5	56,6 <i>39,9 – 84,9</i>	136,5 <i>116,3 – 170,4</i>	183,5 <i>135,1 – 239,8</i>
	longueur moyenne des segments fluides (LMSF, en mots)	3,70	2,35 <i>1,9 – 3,0</i>	5,60 <i>4,3 – 8,2</i>	8,30 <i>5,3 – 12,6</i>
	variance LMSF	2,146	0,119	1,370	3,687
	% temps en hésitation	40,6%	58% <i>52,3 – 74,6%</i>	29,5% <i>20,5 – 36,4%</i>	21,2% <i>13,8 – 34,9%</i>
	longueur médiane des hésitations	697ms	976ms <i>656 – 1336</i>	575ms <i>464 – 806</i>	499ms <i>384 – 784</i>
	variance, longueur hésitations	1,734	3,715	0,296	0,191
	hésitation maximum	21,34"	21,34"	6,37"	5,56"
	taux de reprise (pour 1000 mots)	83,3	130,1 <i>47,9 – 220,0</i>	50,8 <i>8,6 – 128,6</i>	39,8 <i>6,0 – 92,6</i>
indices de production	longueur moyenne des énoncés (LME)	11,1	7,6 <i>5,9 – 9,9</i>	13,4 <i>9,6 – 17,2</i>	16,3 <i>12,9 – 27,1</i>
	diversité lexicale (D)	80,91	52,03 <i>41,3 – 73,1</i>	107,42 <i>87,3 – 127,9</i>	137,73 <i>96,7 – 208,1</i>
	taux d’erreur (pour 1000 mots)	93,2	164,9 <i>87 – 284,3</i>	74,1 <i>23,5 – 131,3</i>	10,6 <i>0 – 25,6</i>
	unités syntaxiques par énoncé	1,8	1,3 <i>1,0 – 1,8</i>	2,2 <i>1,7 – 3,1</i>	2,8 <i>2,4 – 4,0</i>
	unités d’information (UI), nombre	20	16 <i>9 – 22</i>	25 <i>19 – 32</i>	25 <i>16 – 34</i>
	unités d’information (UI) par énoncé	1,1	0,8 <i>0,5 – 1,3</i>	1,4 <i>0,9 – 2,1</i>	1,9 <i>1,3 – 3,4</i>
	unités d’information par minute	8,7	4,9 <i>3,2 – 8,5</i>	13,8 <i>8,3 – 16,2</i>	20,8 <i>11,7 – 32,0</i>
	longueur moyenne des UI (en mots)	10,9	12,0 <i>7,6 – 15,5</i>	10,1 <i>8,4 – 15,6</i>	8,4 <i>5,7 – 12,3</i>

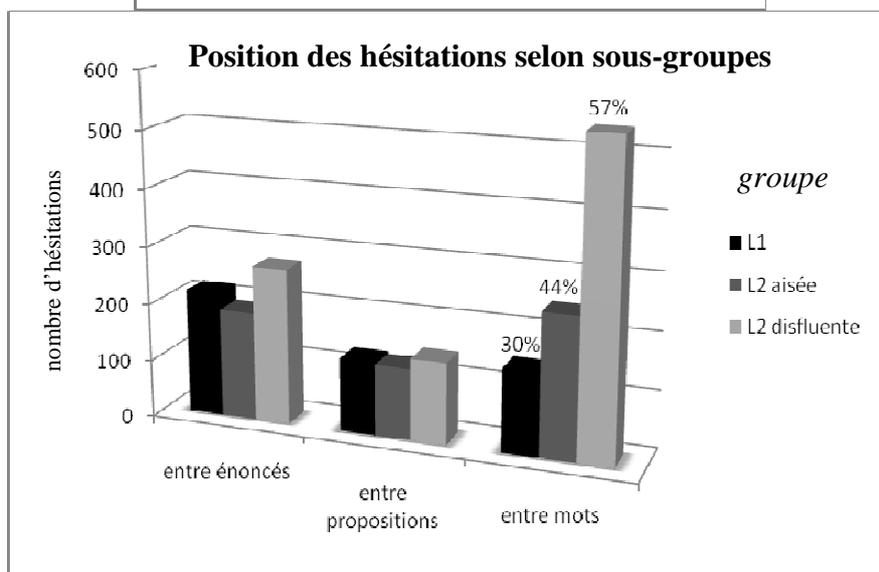
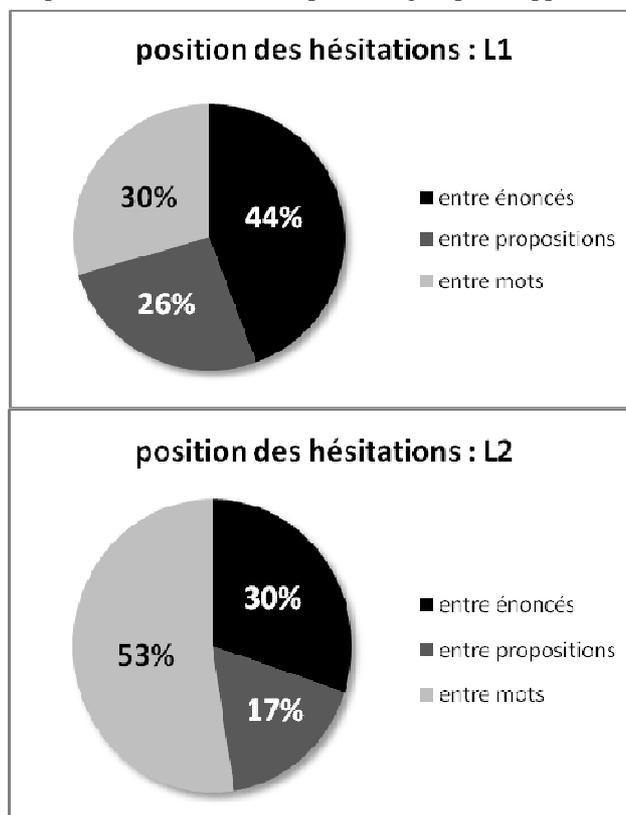
Ce tableau nous donne un aperçu de quelques paramètres de la production non seulement en L2, mais également en L1. On peut, par exemple, constater dans la dernière colonne l'extrême efficacité de la production 'native' : 183 mots, et plus de 20 unités d'information par minute, avec des segments fluides de plus de huit mots entre deux hésitations, une erreur et quatre reprises (répétition, reformulation ou redémarrage) tous les cent mots. En regardant les minima et les maxima pour les différentes mesures, on peut également noter la variation individuelle dans des productions de type monologue descriptif : de 14 % à 35 % de temps d'hésitation, selon les sujets, des énoncés d'une longueur moyenne allant de 13 à 27 mots, etc.

On voit une différence (statistiquement significative⁴) entre la médiane observée chez les apprenants et chez les natifs pour toutes les mesures, ce qui n'est, bien sûr, ni surprenant, ni forcément indésirable. Il est pourtant intéressant de constater les différences temporelles entre la production en L2 et en L1, et de comparer les caractéristiques de la production aisée et disfluente (colonnes 3 et 4). Alors que les sujets les plus à l'aise dans la production en L2 atteignent les mêmes valeurs temporelles et productives que certains natifs (les maxima chez les apprenants fluents coïncidant avec les minima pour les natifs dans le cas des mesures positives, par exemple), le discours des sujets disfluents génère des mesures à part, très éloignées des rythmes temporels de la production native, et notamment un taux de production extrêmement bas – moins d'un mot par seconde, plus de la moitié du temps de production passée en hésitations.

Pour une appréciation plus détaillée des caractéristiques temporelles de la production en L2, la figure 2 résume la distribution des hésitations dans le corpus selon leur situation dans le discours (entre énoncés, entre propositions ou entre les mots à l'intérieur d'une proposition), et les groupes et sous-groupes de sujets.

⁴ Le test de Mann-Whitney démontre une différence significative entre apprenants et natifs pour toutes les mesures (à $p < ,0001$, sauf « longueur moyenne des UI », où $p < ,01$).

Figure 2 – Distribution des hésitations dans PAROLE
(corpus natif et non-natif, et par sous-groupes d'apprenants)



On sait depuis les travaux « pausologiques » des années 1960 et 1970 que les hésitations en L1 se trouvent, très majoritairement, aux « frontières » discursives que sont les énoncés ou les propositions (Hawkins 1971) ; les hésitations intra-propositionnelles sont perçues comme nuisant à la fluidité du discours (Pawley & Syder 2000 : 170). Dans PAROLE, effectivement, 70 % des hésitations dans le corpus ‘natif’ se trouvent devant un ensemble discursif structuré (énoncé ou proposition), et seuls 30 % se situent entre les mots d’une unité syntaxique (premier camembert). Le deuxième camembert montre que plus de la moitié des hésitations dans le corpus L2 se situent à l’intérieur d’une proposition ; cette différence est significative ($\chi^2(4, 3366) = 88.72, p < .0001$). L’histogramme nous montre qu’une proportion élevée d’hésitations à l’intérieur d’une proposition est une caractéristique particulière de la production en L2, ces différences dans la distribution des hésitations d’un sous-groupe à l’autre étant significatives ($\chi^2(4, 2001) = 98.99, p < .0001$). 57 % des hésitations produites par nos sujets disfluents se situent à l’intérieur d’une proposition, contre moins d’un tiers dans les productions en L1. Il est intéressant de constater que la proportion d’hésitations intra-propositionnelles est également plus élevée (44 %) chez les apprenants à l’aise en L2 ; cet indice pourrait être utile aux chercheurs et aux évaluateurs pour distinguer différents niveaux d’aisance en L2.

Une analyse de la fréquence des différents types d’unité syntaxique produits par nos sujets montre une différence entre apprenants et natifs ($\chi^2(6, 1432) = 35.18, p < .0001$), les apprenants dans leur ensemble produisant plus de propositions ‘support’, et les natifs proportionnellement plus de propositions principales et de phrases nominales, alors que les apprenants à l’aise en L2 produisent plus de propositions relatives. Nous reviendrons à ces différences syntaxiques entre les productions en L1 et en L2 dans la discussion, ci-dessous.

3. Discussion : modèles et réalités en production orale

Un corpus oral, même peu interactif comme PAROLE, constitue une base d’informations ‘naturelles’, par rapport aux données rigoureusement expérimentales qui sont traditionnellement utilisées pour tester les modèles psycholinguistiques. Nous ne pourrions pas répondre aux questions les plus détaillées concernant les traitements langagiers en nous basant sur ces données quasi-naturelles, mais nous pouvons néanmoins illustrer un certain nombre de phénomènes, et les confronter aux prévisions du modèle. Si nous prenons les hésitations comme des indices de processus attentionnels, le moment où les automatismes de l’encodage linguistique sont défaillants (Hilton 2011 ; Goldman-Eisler 1957 : 1497 ; Butterworth 1980 : 155-156), alors le codage minutieux des hésitations et des reprises dans PAROLE peut fournir des informations précieuses à mettre en rapport avec le modèle présenté en figure 1.

Il est, bien sûr, prévisible qu'un locuteur rencontre des difficultés d'encodage formel quand il tente de s'exprimer en L2, car sa base linguistique pour cette langue sera toujours moins complète que celle dont il dispose pour l'encodage formel en L1. Depuis longtemps les hésitations intra-propositionnelles sont associées à des problèmes d'encodage lexical (Goldman-Eisler 1958 : 67 ; Maclay & Osgood 1959 ; Fathman 1980 ; Levelt & Maassen 1981 : 250), et il semble, en effet, que les trois hésitations les plus longues du corpus L1 de PAROLE sont attribuables à un effort attentionnel dans le choix de mots :

*N11: #0_842 *a:nd it was just this boy and like <# um #> [#2_512] in a pleated [*] vest and really short shorts [...]* .

[Groupe d'hésitation de 2512ms, suivie d'une erreur lexicale : *pleated* (à plis) pour le mot peu fréquent *argyle*, avec activation partielle, peut-être, du mot associé *plaid*.]

*N11: *and then it cut forward to: <# u:m # &=bouche # uh> [#2_508] like a: [#0_371] I guess an older person &n middle aged [...]* .

[Hésitation de 2508ms, produite par le même sujet anglophone, qui cherchait peut-être à trouver un mot socialement acceptable pour indiquer l'âge d'un homme d'une quarantaine d'années, face à un observateur du même âge.]

*N40: [...] *en arrivant [...] à l'étage [...] voulu: le frigo: e:st [///] <eu:h # eu:h # &=bouche> [#5_564] c'est dur +...*

*N40: *&=rire le frigo redescend [*] [...] au premier étage eu:h [#0_511] et par te:rre et il est lâché [...] de sa: #0_674 nacelle je sais pas .*

[Hésitation de 5564ms qui semble liée à la difficulté – explicitée à la fin de l'énoncé – du sujet à trouver le mot (technique) pour désigner le système utilisé pour attacher un réfrigérateur au crochet d'une grue.]

Nous avons vu qu'une proportion élevée d'hésitations intra-propositionnelles est caractéristique de la production en L2, et même peut-être révélatrice du niveau d'aisance dans cette langue. J'ai effectivement constaté le lien entre les hésitations intra-propositionnelles les plus longues dans PAROLE et des problèmes d'encodage lexical (Hilton 2008b) ; 78 % des hésitations de plus de trois secondes dans le corpus sont suivies soit d'une erreur lexicale, soit d'un mot peu fréquent, soit d'une déclaration ouverte d'incapacité à trouver le bon mot en L2 :

*002: *[We can see] a fridge #0_511 which <u:h # &=bouche #> [#7_664] +...*

*002: *(be)cause I [...] don't know uh [...] how we say uh monter .*

[Hésitation de plus de 7 secondes, suivie de l'aveu d'une incapacité à coder le verbe principal de la proposition.]

La longueur moyenne des segments fluides dans les productions des apprenants disfluents est nettement moindre que les segments de 8 à 12 mots en moyenne observés dans la production des sujets à l'aise dans la langue de production (apprenants et natifs) ; les apprenants du sous-groupe disfluent produisent une hésitation tous les deux ou trois mots :

*001: *okay so uh I [/] u:h [#0_285] I saw a building <# u:h> [#0_511] with a window and <u:h #> [#1_219] there were <u:m # u:h> [#2_131] some uh mens [*] uh [#0_255] looking uh [#0_296] outside .*

On voit, dans cet exemple, que les difficultés d'encodage formel rendent l'élaboration de cet énoncé laborieuse : l'effort attentionnel est constant. Cet effort semble générer ces structures syntaxiques que nous avons identifiées comme caractéristiques de la production non-native : les propositions de soutien, qui permettent de nommer l'un des éléments de la situation à encoder (personne, objet, action, état) – « *J'ai vu un X* » « *Il y avait des Y* » – avant d'y accrocher une proposition subordonnée contenant un nouvel élément d'information. La construction sérielle du discours qui résulte des problèmes d'encodage lexical (le message préverbal ne réussissant pas à activer des représentations lexicales suffisamment spécifiées) génère des unités d'information plus longues (12 mots en moyenne pour une UI chez les apprenants disfluents, contre 8,4 mots pour les natifs), et rendent le discours non-natif globalement moins dense, du point de vue syntaxique et informationnel. Comparez deux énoncés en L2 disfluente (sujets 409 et 001) à l'expression du même concept en L1 (sujet N15) :

*409: *[...] après:s [...] il y a un homme que [*] c'est [*] le [*] enfant [*] mais [...] quand il étai:t &grã [...] &j uh <plus vieux> [//] oui ["] quand il était [*] un adulte [*] .*

*001: *[...] [...] after [*] uh we see: uh [#0_360] [...] the young kid u:h [...] w(h)o have [*] [...] grown up .*

*N15: *[#0_830] so then it shows later on in the boy's life .*

Rappelons-nous que les natifs produisent plus de propositions principales et plus de phrases non-verbales dans PAROLE ; ces dernières permettent d'encoder de nouvelles informations en peu de mots. Ici, un apprenant (004) construit péniblement une proposition relative complexe pour exprimer l'idée qu'un apprenant avancé (025) encode de façon très efficace, par une simple structure possessive, sans doute parce que le mot pour le concept d'appartenance (*to own, the owner*) n'est pas disponible dans le lexique L2 du sujet 004 :

004: [...] the man #1_103 [...] that [/] [...] <who #2_148 is the car> [] [...] is not happy.

*025: and I think the car's owner was screaming [...] +"/.

La mesure algorithmique de la diversité lexicale « D » (Malvern & Richards 1997), qui fait partie des logiciels d'analyse textuelle fournis dans CHILDES, indique que, lexicalement, la production fluide est plus riche : la corrélation entre la longueur moyenne des segments fluides et la mesure D est très élevée ($r = .900$) ; on constate nettement cet effet, bien sûr, dans les exemples donnés ci-dessus. Revenant à notre figure 1, nous pouvons constater le rôle primordial que joue le lexique mental dans l'encodage des idées : étant déjà spécifiés grammaticalement (fonction du mot, genre, nombre, temps, etc.), les lemmes déterminent en grande partie la « structure de surface » de l'énoncé ; l'encodage formel dépend ensuite de la disponibilité des lexèmes, avec leur enveloppe phonologique. La disfluenza en L2 semble liée à de grandes difficultés à mobiliser des représentations lexicales pour encoder ses idées – à un lexique mental lacunaire en L2. Le choix très restreint de lemmes à disposition semble, à son tour, limiter les processus de micro-planification à une énumération sérielle des éléments constitutif du message préverbal. Kormos formule l'hypothèse que la production attentionnée ne peut être que sérielle (2006 : 166), et les données du corpus PAROLE semblent corroborer cette hypothèse.

Les caractéristiques de la production à différents niveaux d'aisance nous permettent de réfléchir, également, à la nature exacte des unités qui sont activées en mémoire lors de l'encodage formel (Hilton 2008a : 82-83 ; Hilton 2011) : en L1, le message préverbal active-t-il des mots isolés, ou plutôt des unités lexicales préfabriquées ? Chez les apprenants disfluenza, l'assemblage formel semble bien être un processus d'activation sérielle de mots isolés. Les locuteurs à l'aise (en L2 ou en L1) arrivent à produire sans hésiter (sans effort attentionnel, donc) des groupes allant de 6-8 à 10-12 mots. Il est intéressant d'examiner les reprises produites par les apprenants, souvent associées à l'activation (postulée par Kormos) de la base de règles grammaticales apprises en classe de langue. Dans ces trois exemples, le sujet conjugué à haute voix un verbe en L2 :

*406: [...] <il v:oir> [/] u:h [#0_528] <il a voir> [/] <uh #> [#0_394] [...] <il a voir> [/] <uh #> [#0_470] <il a vu> [...]

020: [...] the elephant actually slap [] [/] #0_220 slap [/] slaps hi:m #0_493 in the face [...].

*003: [...] but the [/] the fridge <u:h #> [#3_846] Oaux fallen [/] #0_952 non@l1 [...] falls [...] on [...] a car .

Comparons certaines reformulations produites en L1, où le sujet manipule non pas des mots et des morphèmes, mais des groupes de mots, sans hésitation, sans effort d'assemblage à l'intérieur des propositions :

*N13: [...] (be)cause I guess they don't want (t)o: [///] it won't fit up [///] they won't [//] don't want to take it <up the elevator> [//] up the stairs so +/-.

Dans le sillage de Chomsky, nous avons encore tendance, en didactique des langues, à imaginer que les structures syntaxiques propositionnelles sont « générées » activement lors de la production. La recherche menée dans les domaines de la linguistique de corpus et de l'acquisition du langage, ainsi que les données observées dans nos corpus oraux devraient nous inciter à creuser la question de la nature et du rôle des syntagmes préfabriqués dans la production fluide. Les phénomènes observés dans PAROLE ne me permettent que de formuler l'hypothèse d'une activation phraséologique à partir de chaque lemme associé au message préverbal ; cette hypothèse doit, bien sûr, être testée dans des conditions plus rigoureusement expérimentales – à titre d'exemple, voir le travail fascinant de Dąbrowska (2004), qui atteste de l'activation phraséologique des morphèmes inflexionnels en polonais.

4. Conclusions pour la didactique

Sous l'influence de Krashen, et de son Approche naturelle (Krashen & Terrell 1983), nous avons eu tendance, ces trente dernières années en didactique des langues, à croire qu'il suffirait de fournir aux apprenants des activités et des tâches les mettant en situation de communication pour que la compétence productive en L2 se mette en place. L'examen – sans doute un peu fastidieux, mais à mon avis absolument nécessaire – des modèles psycholinguistiques de la production orale nous permet de constater l'extrême importance des traitements automatiques dans la communication verbale des idées. Déjà en 1992, dans son résumé du modèle de Levelt, de Bot a insisté sur la nature hautement automatisée, non seulement des différentes étapes de l'encodage formel, mais également de la mobilisation des connaissances discursives et sociales lors de l'interaction humaine :

Processing is largely automatic. Greatest attention is paid to conceptualizing and some attention is paid to the feedback mechanisms, but the remainder functions without conscious control. Production has to be incremental, parallel, and automatized in order to account for the enormous speed at which language is produced. (de Bot 1992 : 6)

L'automatisme des traitements en L1 – qu'elle soit due à la génération algorithmique de structures complexes, ou à l'activation directe de structures préfabriquées en mémoire – est un sujet presque tabou en didactique des langues, depuis le rejet par Krashen des théories comportementalistes de « l'apprentissage » en faveur d'une « acquisition » plus « naturelle ». Mais

nous constatons, dans le Corpus PAROLE, que la nécessité d'un effort attentionnel aux différents stades de l'encodage formel rend la communication du sens laborieuse, voire extrêmement difficile. Le protocole suivi lors du recueil du corpus ne nous permet pas de statuer sur d'éventuelles possibilités de compensation interactionnelle de ces difficultés, mais nous pouvons, par contre, constater l'extrême efficacité communicative des productions où le lexique mental en L2 est pleinement spécifié, syntaxiquement et phonologiquement (plus d'information encodée en moins de temps). La question qui s'impose, donc – vu l'importance fondamentale des processus automatiques dans l'encodage verbal du sens – est de savoir comment nous pouvons réintroduire un travail visant la mise en place de ces automatismes dans nos classes de langues. Bien évidemment ce travail ne remplacera pas ni ne diminuera l'importance des activités et des tâches communicatives en L2 ; à mon avis, c'est un travail qui peut être utilement effectué dans un environnement informatisé (Hilton 2004 ; Hilton 2007), en préparation des tâches de communication ayant lieu dans l'environnement social de la salle de classe.

Bibliographie

- ABUTALEBI, Jubin & GREEN, David. 'Bilingual language production: The neurocognition of language representation and control', *Journal of Neurolinguistics*, vol. 20, 2007, pp. 242-275.
- BOCK, Kathryn & LEVELT, Willem J.M. 'Language production: Grammatical encoding', pp. 945-983 in Morton A. GERNSBACHER (ed.), *Handbook of Psycholinguistics*, Londres : Academic Press, 1994.
- CLARK, Herbert H. *Arenas of Language Use*. Chicago : University of Chicago Press, 1993.
- DE BOT, Kees. 'A bilingual production model: Levelt's speaking model adapted', *Applied Linguistics*, vol. 13, 1992, pp. 1-24.
- DIMROTH, Christine. 'Topic, assertions and additive words: How L2 learners get from information structure to target language syntax', *Linguistics*, vol. 40, n° 4, 2002, pp. 891-923.
- ERMAN, Britt & WARREN Beatrice. 'The idiom principle and the open choice principle', *Text*, vol. 20, 2000, pp. 29-62.
- FATHMAN, Ann K. 'Repetition and correction as an indication of speech planning and execution processes among second language learners', pp. 77-86 in Hans W. DECHERT & Manfred RAUPACH (eds.), *Towards a Cross-Linguistic Assessment of Speech Production*, Frankfurt : Peter Lang, 1980.
- GOLDMAN-EISLER, Freida. 'Speech analysis and mental processes', *Language and Speech*, vol. 1, 1958, pp. 59-75.

- GOLDMAN-EISLER, Freida. 'Speech production and language statistics', *Nature*, 28 décembre 1957, p. 1497.
- GRAESSER, Arthur C., MILLIS, Keith K. & ZWAAN, Rolf A. 'Discourse comprehension', *American Review of Psychology*, vol. 48, 1997, pp. 163-189.
- GRICE, H. Paul. 'Logic and conversation', pp. 41-58, in Peter COLE & Jerry L. MORGAN (eds.), *Syntax and Semantics: Volume 3, Speech Acts*, San Diego : Academic Press, 1975.
- HAWKINS, P. Roger. 'The syntactic location of hesitation pauses', *Language and Speech*, vol. 14, 1971, pp. 277-88.
- HENDRICKS, Henriette (ed.). *The Structure of Learner Varieties*. Berlin : Mouton de Gruyter, 2005.
- HICKMANN, Maya, HENDRIKS, Henriette & ROLAND, Françoise. 'Référence spatiale dans les récits d'enfants français : perspective inter-langues', *Langue Française*, vol. 118, 1998, pp. 104-23.
- HILTON, Heather E. 'Quels parcours pour l'acquisition lexicale ?', communication, *Atelier Didactique et Acquisition*, Congrès de la SAES, Saint-Quentin-en-Yvelines, Université de Versailles, 16 mai 2004.
- HILTON, Heather E. 'Travailler (en auto-formation TICE-Langues) les savoirs et les compétences phonologiques en anglais', communication, *Journée de travail FLODI*, Grenoble, Université Stendhal, 19 janvier 2007.
- HILTON, Heather E. 'Connaissances, procédures et productions orales en L2', *AILE*, n° 27, 2008 (a), pp. 63-91.
- HILTON, Heather E. 'The link between vocabulary knowledge and spoken L2 fluency', *Language Learning Journal*, vol. 36, n° 2, 2008 (b), pp. 153-66.
- HILTON, Heather E. *Le corpus PAROLE : architecture du corpus et conventions de transcription*. Disponible dans *BilingBank* de *TalkBank*, <http://talkbank.org/>. Pittsburgh PA : Carnegie Mellon University, 2008 (c).
- HILTON, Heather E. 'Annotation and analyses of temporal aspects of spoken fluency', *CALICO Journal*, vol. 26, n° 3, 2009, pp. 644-61.
- HILTON, Heather E. 'What is implicit and what is explicit in L2 speech? Findings from an oral corpus', in Cristina SANZ and Ronald P. LEOW (eds). *Implicit and Explicit Conditions, Processes, and Knowledge in SLA and Bilingualism*. Washington DC : Georgetown University Press, à paraître 2011.
- HILTON, Heather E., OSBORNE, N. John & DERIVE, Marie-Jo. *Corpus PAROLE*. Disponible dans *BilingBank* de *TalkBank*, <http://talkbank.org/>. Pittsburgh : Carnegie Mellon University, 2008.
- INDEFREY, Peter & LEVELT Willem J. M. 'The spatial and temporal signatures of word production components', *Cognition*, vol. 92, 2004, pp. 101-44.
- KORMOS, Judit. *Speech Production and Second Language Acquisition*. Mahwah NJ : Lawrence Erlbaum, 2006.

- KRASHEN, Stephen & TERRELL Tracy D. *The Natural Approach: Language Acquisition in the Classroom*. Hayward CA : Alemany Press, 1983.
- LEVELT, Willem J. M. *Speaking: From Intention to Articulation*. Cambridge MA : MIT Press, 1989.
- LEVELT, Willem J. M. 'Producing spoken language: A blueprint of the speaker', pp. 83-122 in Colin M. BROWN & Peter HAGOORT (eds.), *The Neurocognition of Language*, Oxford : Oxford University Press, 1999 (a).
- LEVELT, Willem J. M. 'Models of word production', *Trends in Cognitive Sciences*, vol. 3, n° 6, 1999 (b), pp. 223-232.
- LEVELT, Willem J. M & MAASSEN, Ben. 'Lexical search and order of mention in sentence production', pp. 221-252 in Wolfgang KLEIN & Willem LEVELT (eds.), *Crossing the Boundaries in Linguistics*, Dordrecht : D. Reidel, 1981.
- LEVELT, Willem J. M., ROELOFS, Ardi & MEYER, Antje S. 'A theory of lexical access in speech production', *Behavioral and Brain Sciences*, vol. 22, 1999, pp. 1-75.
- LOGAN, Gordon D. 'Toward an instance theory of automatization', *Psychological Review*, vol. 95, n° 4, 1988, pp. 492-527.
- LOGAN, Gordon D. 'Automaticity and memory', pp. 347-367 in William E. HOCKLEY & Stephan LEWANDOWSKI (eds.), *Relating Theory and Data*. Hillsdale, NJ : Lawrence Erlbaum, 1991.
- MACLAY, Howard & OSGOOD, Charles E. 'Hesitation phenomena in spontaneous English speech', *Word*, vol. 15, 1959, pp. 19-44.
- MACWHINNEY, Brian. 'The competition model', pp. 249-308 in Brian MACWHINNEY (ed.), *Mechanisms of Language Acquisition*, Hillsdale NJ : Lawrence Erlbaum, 1987.
- MACWHINNEY, Brian. 'Second language acquisition and the competition model', pp. 113-142 in Annette M. B. de GROOT & Judith F. KROLL (eds.), *Tutorials in Bilingualism: Psycholinguistic Perspectives*, Mahwah NJ : Lawrence Erlbaum, 1997.
- MACWHINNEY, Brian. 'The emergence of language from embodiment', pp. 213-246 in Brian MACWHINNEY (ed.), *The Emergence of Language*, Mahwah NJ : Lawrence Erlbaum, 1999.
- MACWHINNEY, Brian. *The CHILDES Project: Tools for Analyzing Talk 2*. Pittsburgh : Carnegie-Mellon University, 2007.
- NATION, I. S. P. *Learning Vocabulary in Another Language*. Cambridge : Cambridge University Press, 2001.
- OSBORNE, N. John. 'Measuring fluency in an oral learner corpus', communication, *Corpus Linguistics 2007*, University of Birmingham, G.B., 29 juillet 2007.

OSBORNE, N. John, & HILTON, Heather E. 'Propositional structure and L2 fluency: findings from a spoken corpus', communication, *EUROSLA Annual Conference*, Aix-en-Provence, Université de Provence, 12 septembre 2008.

PAWLEY, Andrew & HODGETT SYDER, Frances. 'Two puzzles for linguistic theory: Nativelike selection and nativelike fluency', pp. 191-226 in Jack C. RICHARDS & Richard W. SCHMIDT (eds.), *Language and Communication*, Londres : Longman, 1983.

PAWLEY, Andrew & HODGETT SYDER, Frances. 'The one-clause-at-a-time hypothesis', pp. 163-199 in Heidi RIGGENBACH (ed.), *Perspectives on Fluency*, Ann Arbor MI : University of Michigan Press, 2000.

ROELOFS, Ardi. 'The WEAVER model of word-form encoding in speech production', *Cognition*, vol. 64, 1997, pp. 249-84.

SINGLETON, David. *Language and the Lexicon: An Introduction*. Londres : Edward Arnold, 2000.

STEEDMAN, Mark J., & JOHNSON-LAIRD, Philip N. 'The production of sentences, utterances and speech acts: Have computers anything to say?', pp. 11-141 in Brian BUTTERWORTH (ed.), *Language Production : Volume 1, Speech and Talk*, London : Academic Press, 1980.

TANENHAUS, Michael K. & BROWN-SCHMIDT, Sarah. 'Language processing in the natural world', *Philosophical Transactions of the Royal Society of Biological Sciences*, vol. 363, 12 mars 2008, pp. 1105-1122.

VAN HOEK, Karen. 'Pronouns and point of view: Cognitive principles of coreference', pp. 169-194 in Michael TOMASELLO (ed.), *The New Psychology of Language: Cognitive and Functional Approaches to Language Structure*, Volume 2, Mahwah NJ : Lawrence Erlbaum, 2003.

VON STUTTERHEIM, Christiane. 'Linguistic structure and information organisation: The case of very advanced learners', *EUROSLA Yearbook*, 2003, pp. 183-206.

VON STUTTERHEIM, Christiane, NÜSE, Roland & MURCIA SERRA, Jorge. 'Cross-linguistic differences in the conceptualisation of events', *Revue Française de Linguistique Appliquée*, vol. 72, n° 2, 2002, pp. 99-115.

WRAY, Alison. *Formulaic Language and the Lexicon*. Cambridge : Cambridge University Press, 2001.

WRAY, Alison. 'Formulaic sequences in second language teaching: Principle and practice', *Applied Linguistics*, vol. 21, n° 4, 2000, pp. 463-489.